

Evaluasi Kinerja Metode *Content-Based Filtering* pada Sistem Rekomendasi Destinasi Wisata dan Rute Pendakian Berbasis Web

Herlawati Herlawati ^{1,*}, Andy Achmad Hendharsetiawan ¹, Bertnardo Mario Uskono ¹,
Acah Acah¹

* Korespondensi: e-mail: herlawati@ubharajaya.ac.id

¹ Informatika; Fakultas Ilmu Komputer; Universitas Bhayangkara Jakarta Raya, Jl. Perjuangan No. 81, Marga Mulya, Bekasi Utara, Bekasi, Jawa Barat, 17143, telp/fax: (021) 88955882; e-mail: herlawati@ubharajaya.ac.id, andy.achmad@dsn.ubharajaya.ac.id, 202210715326@mhs.ubharajaya.ac.id, 202210715110@mhs.ubharajaya.ac.id.

Submitted : 31 Maret 2026
Revised : 16 April 2026
Accepted : 8 Mei 2026
Published : 30 Mei 2026

Abstract

This study aims to evaluate the *Content-Based Filtering* method in a web-based recommendation system for tourist destinations and hiking routes. The study integrates two domains: 1,621 tourist destinations in Bogor and 126 mountain hiking routes across Java. Tourism data were collected through web scraping from Google Maps, while hiking route data were obtained from Gunungbagging.com and Muncak.id. The attributes used include category, location, ticket price, facilities, rating, distance, elevation gain, estimated duration, difficulty level, and recommended user experience. Hiking duration was estimated using the *Naismith Rule*. The system constructs a user profile based on user preferences and computes the similarity between the user profile and item characteristics using Cosine Similarity. For tourism data, a Deep Autoencoder was employed to reduce 54 features into 8 latent dimensions, while the *Haversine Formula* was applied as a *geospatial filter* to account for location proximity. Evaluation using *Precision@10* yielded average scores of 0.80 for hiking route recommendations and 0.85 for tourist destination recommendations. The results indicate that *Content-Based Filtering* effectively produces relevant and precise recommendations that align with user preferences and supports more objective and efficient decision-making.

Keywords: *Content-Based Filtering, Cosine Similarity, Hiking Routes, Recommendation System, Tourism*

Abstrak

Penelitian ini bertujuan mengevaluasi metode *Content-Based Filtering* pada sistem rekomendasi destinasi wisata dan rute pendakian berbasis web. Penelitian mengintegrasikan dua domain, yaitu 1.621 destinasi wisata di Bogor dan 126 rute pendakian gunung di Pulau Jawa. Data wisata diperoleh melalui web scraping dari Google Maps, sedangkan data rute pendakian dikumpulkan dari Gunungbagging.com dan Muncak.id. Atribut yang digunakan meliputi kategori, lokasi, harga tiket, fasilitas, rating, jarak, elevasi, estimasi durasi, tingkat kesulitan, dan rekomendasi pengalaman pengguna. Estimasi durasi pendakian dihitung menggunakan *Naismith Rule*. Sistem membentuk profil pengguna berdasarkan preferensi yang dimasukkan, kemudian menghitung tingkat kemiripan antara profil pengguna dan karakteristik item menggunakan Cosine Similarity. Pada data wisata, Deep Autoencoder digunakan untuk mereduksi 54 fitur menjadi 8 dimensi

laten, sedangkan *Haversine* Formula diterapkan sebagai filter geospasial untuk mempertimbangkan kedekatan lokasi. Evaluasi menggunakan *Precision@10* menunjukkan rata-rata nilai 0,80 pada rekomendasi rute pendakian dan 0,85 pada rekomendasi destinasi wisata. Hasil penelitian menunjukkan bahwa *Content-Based Filtering* efektif menghasilkan rekomendasi yang relevan, presisi, dan sesuai dengan preferensi pengguna serta mendukung pemilihan destinasi dan rute secara lebih objektif dan efisien.

Kata Kunci: *Content-Based Filtering, Cosine Similarity, Pariwisata, Rute Pendakian, Sistem Rekomendasi*

1. Pendahuluan

Aktivitas pendakian gunung semakin diminati sebagai salah satu bentuk wisata alam dan kegiatan luar ruang yang menawarkan pengalaman rekreasi sekaligus tantangan fisik (A. Pratiwi et al., 2023). Di Indonesia, Pulau Jawa menjadi kawasan yang paling populer bagi pendaki karena memiliki banyak gunung dengan karakteristik jalur yang beragam serta akses yang relatif mudah dijangkau (Indrasetianingsih et al., 2025). Setiap rute pendakian memiliki perbedaan dalam hal jarak, elevasi, estimasi durasi, dan tingkat kesulitan, sehingga pemilihan jalur yang sesuai dengan kemampuan dan pengalaman pendaki menjadi faktor penting untuk meningkatkan keselamatan dan kenyamanan selama perjalanan (Suryadi et al., 2025). Informasi mengenai jalur pendakian umumnya tersedia pada blog, forum, media sosial, dan situs resmi pengelola gunung (Aryanto et al., 2025; Nurmala et al., 2024). Namun, penyebaran informasi yang tidak terstruktur mengharuskan pengguna melakukan perbandingan secara manual, yang berpotensi menyebabkan pemilihan rute yang kurang sesuai dan meningkatkan risiko selama pendakian (Indrasetianingsih et al., 2025; Nurmala et al., 2024).

Di sisi lain, sektor pariwisata memiliki kontribusi signifikan terhadap pertumbuhan ekonomi daerah melalui peningkatan pendapatan dan penciptaan lapangan kerja (Wijesekara et al., 2022; Li et al., 2018). Pasca pandemi COVID-19, minat masyarakat untuk berwisata meningkat pesat, termasuk di Bogor yang mencatat kenaikan jumlah kunjungan dari 4,4 juta wisatawan pada tahun 2020 menjadi 10,6 juta pada tahun 2023 (Pemerintah Kabupaten Bogor, 2025). Peningkatan ini diikuti oleh ketimpangan distribusi kunjungan, di mana konsentrasi wisatawan masih terpusat pada destinasi populer seperti kawasan Puncak, Kebun Raya Bogor, dan Taman Safari Indonesia Bogor. Akibatnya, terjadi penumpukan pengunjung dan beban kapasitas layanan yang tidak merata, sementara banyak destinasi potensial di wilayah lain belum memperoleh eksposur yang memadai.

Permasalahan pada kedua domain tersebut menunjukkan kebutuhan akan sistem rekomendasi yang mampu membantu pengguna menemukan destinasi wisata maupun rute pendakian berdasarkan karakteristik konten, bukan semata-mata popularitas. Sistem rekomendasi cerdas telah terbukti efektif dalam mendukung proses pengambilan keputusan dengan menganalisis tingkat kemiripan antara preferensi pengguna dan atribut item (Huda & Wibowo, 2023; Khan & Haroon, 2023). Metode *Content-Based Filtering (CBF)* memiliki

keunggulan dalam menangani kondisi minimnya riwayat interaksi pengguna maupun item baru (*cold-start*), karena rekomendasi dihasilkan berdasarkan kesesuaian fitur objek dengan profil pengguna tanpa bergantung pada data pengguna lain (Aryanto et al., 2025; Salsabilla & Utomo, 2025). Pada penelitian ini, tingkat kemiripan dihitung menggunakan Cosine Similarity, sementara estimasi durasi pendakian diperoleh melalui *Naismith Rule* (Irmischer & Clarke, 2018). Untuk meningkatkan representasi fitur pada data destinasi wisata, digunakan Deep Autoencoder yang mereduksi 54 atribut menjadi 8 dimensi laten, serta *Haversine Formula* untuk mempertimbangkan kedekatan geografis pengguna dengan destinasi tujuan (Pebesma & Bivand, 2023).

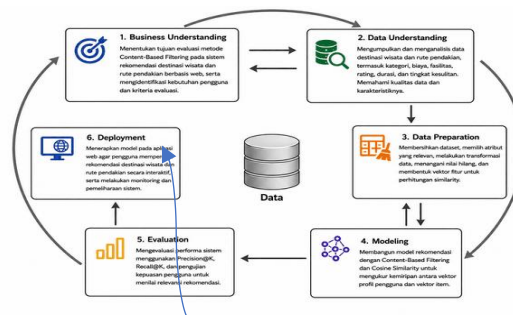
Berdasarkan latar belakang tersebut, penelitian ini bertujuan mengevaluasi penerapan metode *Content-Based Filtering* pada sistem rekomendasi destinasi wisata dan rute pendakian berbasis web. Penelitian ini menggunakan metodologi *Cross-Industry Standard Process for Data Mining (CRISP-DM)* untuk menghasilkan sistem yang mampu memberikan rekomendasi yang relevan, objektif, dan terstruktur sesuai preferensi pengguna, sekaligus mendukung pemerataan kunjungan wisata dan membantu pendaki memilih rute yang aman dan sesuai dengan tingkat kemampuan mereka.

2. Metode Penelitian

Penelitian ini menggunakan metodologi *CRISP-DM* dan metode *Content-Based Filtering* untuk membangun sistem rekomendasi destinasi wisata dan rute pendakian berbasis web. Data destinasi wisata di Bogor dan rute pendakian di Pulau Jawa dikumpulkan, dibersihkan, dan ditransformasikan ke bentuk numerik. Pada domain pariwisata digunakan *Deep Autoencoder* untuk reduksi fitur, sedangkan pada domain pendakian digunakan *Naismith Rule* untuk estimasi durasi. Sistem kemudian menghitung kemiripan menggunakan *Cosine Similarity* dan menerapkan *Haversine Formula* untuk mempertimbangkan kedekatan lokasi. Kinerja model dievaluasi menggunakan *Precision@10* sebelum diimplementasikan ke dalam aplikasi web interaktif.

2.1. Cross Industry Standard Process for Data Mining (CRISP-DM)

CRISP-DM merupakan metodologi yang banyak digunakan dalam penelitian *data mining* dan *data science* karena menyediakan tahapan yang sistematis mulai dari pemahaman masalah hingga implementasi sistem (Schroer et al., 2021).



Sumber: Martinez-Plumed et al (2021)

Gambar 1. Tahapan *CRISP-DM*

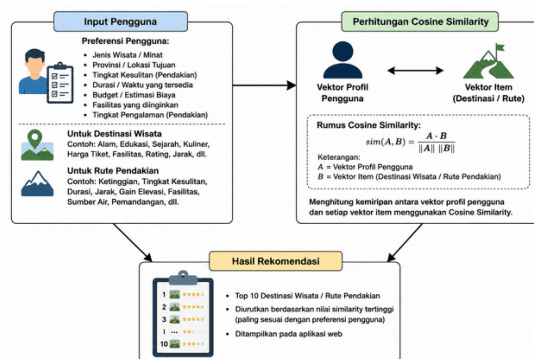
Metodologi *CRISP-DM* terdiri dari enam tahapan utama, yaitu *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, *Evaluation*, dan *Deployment* (Martinez-Plumed et al., 2021).

2.2 Content-Based Filtering

Content-Based Filtering (CBF) merupakan metode sistem rekomendasi yang bekerja dengan membandingkan preferensi pengguna dengan karakteristik item yang tersedia (D. Pratiwi et al., 2025; Salsabilla & Utomo, 2025). Dalam penelitian ini, item yang direkomendasikan berupa rute pendakian gunung yang direpresentasikan menggunakan atribut utama, yaitu elevasi, estimasi durasi pendakian, tingkat kesulitan, dan rekomendasi pengalaman pendaki.

Content-Based Filtering (CBF) merupakan pendekatan dalam sistem rekomendasi yang berfokus pada analisis atribut atau karakteristik dari sebuah objek untuk menghasilkan saran yang relevan bagi pengguna berdasarkan preferensi masukan (Ricci et al., 2022). Prinsip kerja CBF didasarkan pada asumsi bahwa jika seorang pengguna menyukai suatu item dengan karakteristik tertentu, maka pengguna tersebut kemungkinan besar akan menyukai item lain yang memiliki profil fitur serupa (*similarity*). Dalam domain pariwisata, metode ini sangat efektif untuk mempromosikan destinasi alternatif (*hidden gems*) yang kurang terekspos karena proses rekomendasi murni mengevaluasi kesamaan konten atribut statis objek tanpa bergantung pada kepadatan data rating atau riwayat interaksi dari pengguna lain, sehingga mampu mengatasi kendala *item cold-start* secara optimal pada destinasi baru (Yuan & Hernandez, 2023).

Proses *Content-Based Filtering* pada penelitian ini meliputi tiga tahapan utama, yaitu Pembentukan profil pengguna berdasarkan input preferensi, Perhitungan tingkat kemiripan antara profil pengguna dan vektor rute pendakian dan Pengurutan hasil rekomendasi berdasarkan nilai *similarity* tertinggi seperti pada Gambar 2.



Sumber: Hasil Penelitian (2026)

Gambar 2. *Content-Based Filtering*

2.3. Cosine Similarity

Cosine Similarity digunakan sebagai metrik komputasional untuk mengukur tingkat kemiripan karakteristik konten antara dua vektor non-nol dalam ruang hasil kali dalam (*inner product space*) (Murphy, 2022; Yasser et al., 2023). Metrik ini menghitung nilai kosinus sudut di antara vektor preferensi wisatawan dengan vektor representasi laten destinasi wisata target

(Jurafsky & Martin, 2026; Mana & Sasipraba, 2021). Secara matematis, formulasi Cosine Similarity didefinisikan pada persamaan (1):

$$\text{Similarity}(A, B) = \frac{A \cdot B}{\|A\| \|B\|} \quad (1)$$

Keterangan: *Similarity* (A, B) adalah nilai kemiripan kosinus, $A \cdot B$ mewakili hasil perkalian titik (*dot product*) antar-vektor, $\|A\|$ dan $\|B\|$ merupakan magnitudo atau norma *Euclidean* dari masing-masing vector.

3. Hasil dan Pembahasan

Penelitian ini menerapkan tahapan *CRISP-DM* dan metode *Content-Based Filtering* untuk menghasilkan sistem rekomendasi destinasi wisata dan rute pendakian gunung di Pulau Jawa berbasis web.

3.1. Business Understanding

Penelitian ini bertujuan mengembangkan sistem rekomendasi berbasis web untuk memberikan rekomendasi rute pendakian di Pulau Jawa dan destinasi wisata di Bogor menggunakan metode *Content-Based Filtering (CBF)*. Sistem membantu pengguna menemukan pilihan yang sesuai berdasarkan preferensi seperti lokasi, tingkat kesulitan, durasi, kategori, fasilitas, dan rating. Sistem membandingkan preferensi pengguna dengan atribut setiap item untuk menghasilkan rekomendasi yang relevan dan sesuai kebutuhan. Hasil penelitian diharapkan dapat membantu pengambilan keputusan secara lebih efektif sekaligus mendukung pemerataan kunjungan wisata dan pengembangan potensi ekonomi lokal berbasis teknologi.

3.2. Data Understanding

a. Destinasi Wisata

Dataset yang digunakan diperoleh secara mandiri melalui *web scraping* Google Maps menggunakan Selenium, menghasilkan 1.621 data tempat wisata di 46 kecamatan Bogor. Atribut yang ditarik meliputi identitas lokasi, rating, jumlah ulasan, hingga koordinat spasial yang distrukturkan ke dalam *dataframe* Pandas. Inspeksi struktur data dilakukan untuk mendeteksi tipe data dan anomali nilai kosong (*missing values*) seperti yang ditunjukkan pada Gambar 3.

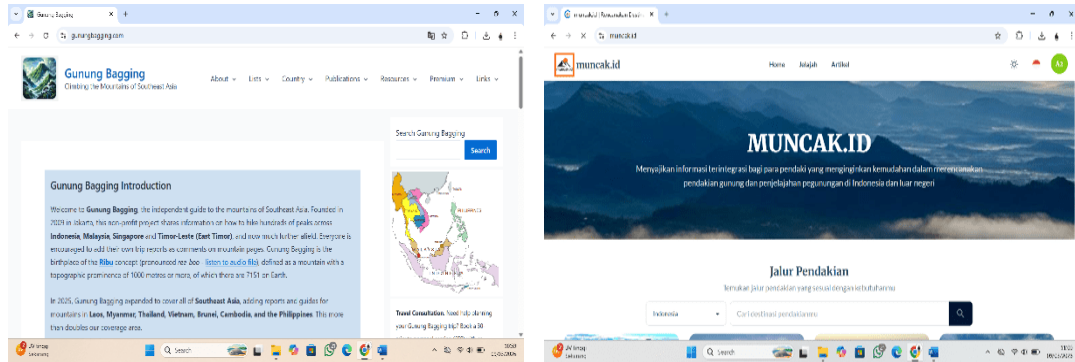
```
[ ] df_raw.info()
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 1621 entries, 0 to 1620
Data columns (total 12 columns):
#   Column                Non-Null Count  Dtype
---  ---                ---
0   nama_tempat_wisata    1621 non-null   object
1   kategori              1621 non-null   object
2   preferensi            1621 non-null   object
3   kecamatan             1621 non-null   object
4   kabupaten_kota       1621 non-null   object
5   rating                1569 non-null   float64
6   jumlah_rating        1569 non-null   float64
7   harga_tiket          0 non-null      float64
8   link                  1621 non-null   object
9   latitude              1621 non-null   float64
10  longitude             1621 non-null   float64
11  link_gambar          1447 non-null   object
dtypes: float64(5), object(7)
memory usage: 152.1+ KB
```

Sumber: Hasil Penelitian(2026)

Gambar 1. Informasi Struktur Data dan Kelengkapan Atribut (*Missing Values*)

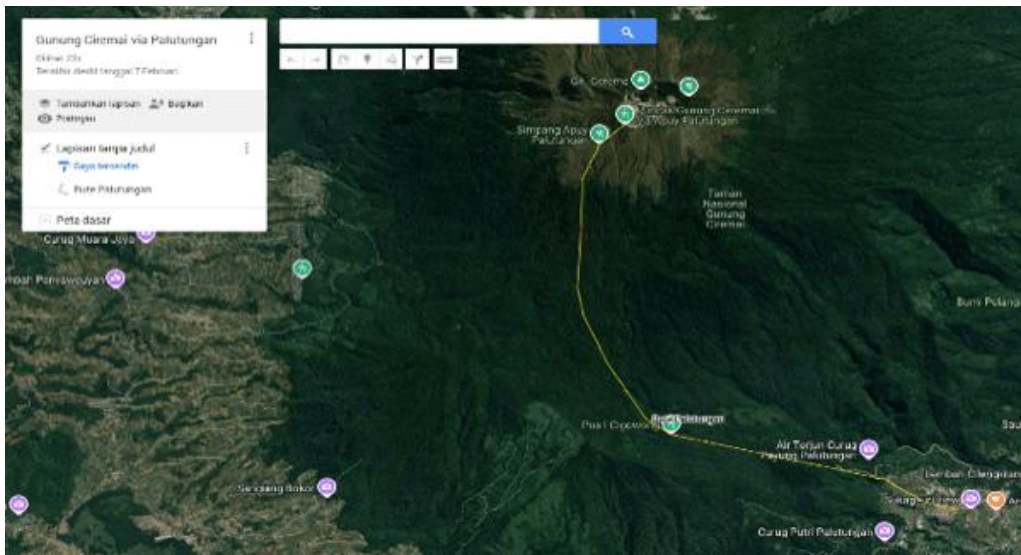
b. Rute Pendakian

Data yang digunakan dalam penelitian ini diperoleh dari dua sumber utama, yaitu Gunungbagging dan Muncak.id. Selain itu, *Google Maps* dan *Google My Maps* digunakan untuk memperoleh informasi tambahan berupa koordinat titik awal pendakian, jarak rute, dan visualisasi jalur pendakian. Gambar 4 menunjukkan sumber data dan visualisasi rute pendakian yang digunakan dalam penelitian.



(a)

(b)



(c)

Sumber: Hasil Penelitian(2026)

Gambar 4. (a) Gunungbagging.com, (b) Muncak.id, (c) Visualisasi Rute pada *Google My Maps*

Dataset penelitian terdiri dari *dataset* gunung dan *dataset* rute pendakian. Dataset gunung memuat 75 data gunung di Pulau Jawa dengan atribut seperti nama, provinsi, koordinat, dan elevasi, sedangkan *dataset* rute pendakian memuat 126 data rute dengan atribut nama rute, koordinat awal, dan jarak tempuh. Kedua *dataset* disimpan dalam format CSV dan digunakan sebagai dasar pembentukan *dataset* akhir.

Pada tahap ini juga dilakukan eksplorasi awal untuk memahami struktur data, memeriksa tipe data, serta mengidentifikasi nilai kosong atau tidak valid sebagai dasar proses pembersihan dan transformasi data pada tahap berikutnya.

3.3. Data Preparation

Tahap Data Preparation bertujuan mengubah data mentah menjadi *dataset* yang bersih dan siap digunakan pada proses rekomendasi. Pada penelitian rute pendakian, data gunung dan rute digabungkan, divalidasi, dibersihkan, dihitung durasinya menggunakan *Naismith Rule*, kemudian dilakukan transformasi dan normalisasi data menggunakan *Min-Max Normalization* untuk perhitungan *Cosine Similarity*.

Pada penelitian destinasi wisata, data hasil web scraping dibersihkan dan diseleksi berdasarkan kualitas data sehingga diperoleh 591 destinasi wisata. Selanjutnya dilakukan feature engineering menggunakan Min-Max Scaling dan One-Hot Encoding untuk menghasilkan matriks numerik terstandarisasi seperti pada Gambar 5. Berdasarkan Gambar 5, data berhasil ditransformasikan menjadi matriks berdimensi 591 × 54 yang digunakan sebagai input layer pada model *Deep Autoencoder*.

	rating_scaled	jumlah_rating_scaled	kategori_Alam	kategori_Budaya	kategori_Rekreasi	kategori_Umum	kecamatan_Badakan	kecamatan_Madang
0	0.7	1.000000	1.0	0.0	0.0	0.0	0.0	
1	0.7	0.671190	0.0	0.0	1.0	0.0	0.0	
2	0.8	0.544925	0.0	0.0	0.0	1.0	0.0	
3	0.4	0.305327	0.0	0.0	1.0	0.0	1.0	
4	0.3	0.269744	1.0	0.0	0.0	0.0	0.0	

Sumber: Hasil Penelitian(2026)

Gambar 2. Struktur Matriks Numerik Akhir Hasil Proses *Scaling* dan *Encoding*

3.4. Modeling

Tahap Modeling menerapkan metode *Content-Based Filtering* untuk menghitung kemiripan antara preferensi pengguna dan karakteristik item. Pada domain pariwisata, digunakan *Deep Autoencoder* untuk mereduksi 54 atribut menjadi 8 fitur laten yang dikombinasikan dengan *Haversine* Formula guna mempertimbangkan kedekatan lokasi pengguna. Seluruh fitur dinormalisasi menggunakan Min-Max Normalization, kemudian tingkat kemiripan dihitung dengan *Cosine Similarity*. Hasil rekomendasi diurutkan berdasarkan skor tertinggi dan sistem menampilkan 10 rekomendasi terbaik sesuai preferensi pengguna. Tahapan *modelling* mencakup beberapa langkah diantaranya yaitu:

a. Perancangan Arsitektur Model

Tahap ini merancang arsitektur *Deep Autoencoder* menggunakan TensorFlow Keras dengan 54 fitur input, lapisan Encoder (32 dan 16 node), Latent Space 8 node, serta Decoder (16 dan 32 node). Model memiliki 4.894 parameter trainable dengan kebutuhan memori 19,12 KB, sehingga efisien dan ringan untuk diimplementasikan pada aplikasi web. Ringkasan arsitektur dan parameter komputasi model ditunjukkan pada Gambar 6.

Layer (type)	Output Shape	Param #
input_layer (InputLayer)	(None, 54)	0
dense (Dense)	(None, 32)	1,760
dense_1 (Dense)	(None, 16)	528
latent_features (Dense)	(None, 8)	136
dense_2 (Dense)	(None, 16)	144
dense_3 (Dense)	(None, 32)	544
dense_4 (Dense)	(None, 54)	1,782

Total params: 4,894 (19.12 KB)
 Trainable params: 4,894 (19.12 KB)
 Non-trainable params: 0 (0.00 B)

Sumber: Hasil Penelitian (2026)

Gambar 3. Ringkasan Parameter Komputasi Model *Deep Autoencoder*

b. Pengaturan *Hyperparameter* dan *Training Model*

Berdasarkan Tabel 1, model dilatih selama 100 *epoch* menggunakan Adam Optimizer dan fungsi kerugian MSE dengan penerapan Early Stopping untuk mencegah overfitting. Hasil pelatihan menunjukkan penurunan loss yang konsisten hingga mencapai training loss 0,0160 dan validation loss 0,0174, sehingga model dinilai memiliki performa dan kemampuan generalisasi yang baik.

Tabel 1. Cuplikan Log Metrik Pelatihan *Deep Autoencoder*

Epoch	Training Loss (MSE)	Training RMSE	Validation Loss (MSE)	Validation RMSE
1	0.2429	0.4929	0.2315	0.4812
10	0.0345	0.1857	0.0326	0.1804
25	0.0252	0.1586	0.0238	0.1542
50	0.0180	0.1342	0.0194	0.1392
75	0.0171	0.1306	0.0181	0.1346
100	0.0160	0.1265	0.0174	0.1319

Sumber: Hasil Penelitian(2026)

Setelah model mencapai konvergensi, lapisan Encoder digunakan untuk menghasilkan representasi laten berdimensi 8 dari 591 data pariwisata. Tingkat kemiripan antar destinasi dihitung menggunakan Cosine Similarity, kemudian sistem menerapkan *Haversine Formula* untuk menyaring lokasi berdasarkan radius tertentu sebelum menampilkan rekomendasi terbaik (Top-K) pada aplikasi.

3.5. Evaluation

Tahap Evaluation dilakukan menggunakan metrik *Precision@10* untuk mengukur relevansi 10 rekomendasi teratas yang dihasilkan sistem terhadap preferensi pengguna. Ground truth dibentuk dengan pendekatan rule-based filtering berdasarkan provinsi dan batas maksimal durasi pendakian. Skenario pengujian ditunjukkan pada Tabel 2.

Tabel 2. Skenario Pengujian

Test Case	Province	Difficulty	Max Duration (Jam)	Experience
1	Jawa Barat	2	6	2
2	Jawa Tengah	1	4	1

Sumber: Hasil Penelitian (2026)

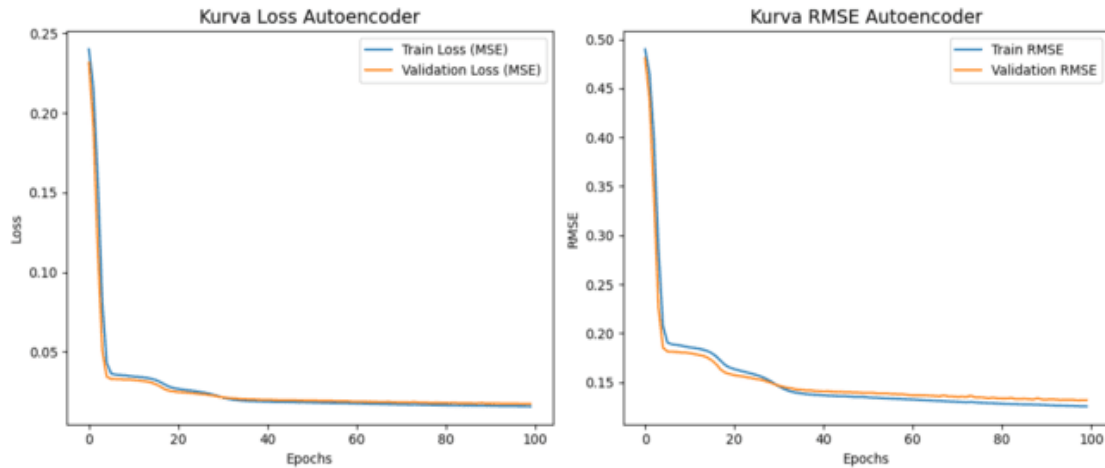
Pengujian dilakukan pada dua skenario menggunakan metode *Content-Based Filtering* dengan Cosine Similarity. Hasil evaluasi menunjukkan nilai *Precision@10* sebesar 1,0 pada skenario pertama dan 0,6 pada skenario kedua, dengan rata-rata 0,8. Hasil ini menunjukkan bahwa sistem mampu memberikan rekomendasi rute pendakian yang relevan dan cukup akurat sesuai preferensi pengguna. Hasil evaluasi untuk masing-masing skenario ditunjukkan pada Tabel 3.

Tabel 3. Test Case

Test Case	<i>Precision@10</i>
1	1.0
2	0.6
Rata-rata	0.8

Sumber: Hasil Penelitian (2026)

Setelah tahap pemodelan selesai, dilakukan evaluasi kinerja model menggunakan metrik *Mean Squared Error (MSE)*, *Root Mean Squared Error (RMSE)*, dan *Precision@10*. Hasil pelatihan menunjukkan kurva train loss dan validation loss menurun secara konsisten hingga mencapai nilai stabil di sekitar 0,02, yang menandakan model mampu belajar dengan baik tanpa mengalami overfitting. Nilai *RMSE* akhir sebesar 0,13 menunjukkan bahwa arsitektur Deep Autoencoder mampu mempertahankan karakteristik penting data saat mereduksi 54 fitur menjadi 8 dimensi ruang laten. Untuk meninjau jalannya proses pembelajaran model secara mendalam, visualisasi kurva *Loss (MSE)* dan kurva *RMSE* digabungkan pada Gambar 7.



Sumber: Hasil Penelitian(2026)

Gambar 4. Kurva Historis Metrik Evaluasi *Training* dan *Validation (Loss MSE & RMSE)*

Fitur laten hasil ekstraksi dievaluasi menggunakan *Precision@10* dengan radius geografis 10 km dan menghasilkan rata-rata akurasi sebesar 85%. Kategori Alam, Rekreasi, dan Umum mencapai presisi 100%, sedangkan kategori Budaya memiliki presisi lebih rendah karena keterbatasan jumlah destinasi serupa dalam radius pencarian. Secara keseluruhan, sistem mampu menghasilkan rekomendasi yang relevan dan sesuai dengan preferensi serta lokasi pengguna.

Tabel 4. Hasil Pengujian *Precision@10* dengan Batas Radius 10 Km

No	Target Destinasi (Input)	Kategori Target	Rekomendasi Diberikan (k)	Jumlah Rekomendasi Relevan	<i>Precision@10</i>
1	Kebun Raya Bogor	Alam	10	10	100%
2	Taman Safari Indonesia Bogor	Rekreasi	10	10	100%
3	Masjid Atta'Awun Puncak	Umum	10	10	100%
4	Taman Budaya Sentul City	Budaya	10	4	40%
Rata-Rata Keseluruhan					85,00%

Sumber: Hasil Penelitian (2026)

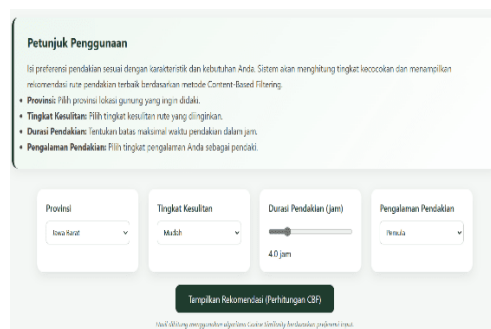
Pengujian dieksekusi menggunakan empat sampel destinasi acak yang mewakili masing-masing kelompok kategori utama dalam pangkalan data, dengan rekapitulasi pengujian yang disajikan pada Tabel 4.

3.6. Deployment

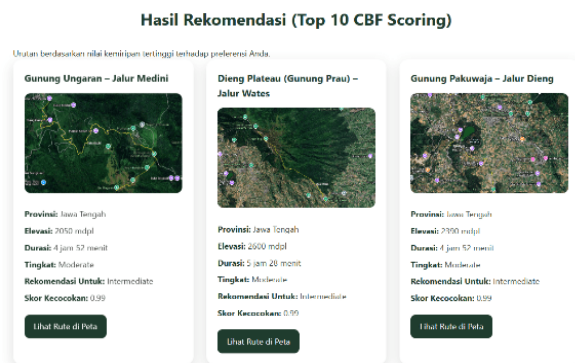
Pada tahap *deployment* tentang rute pendakian, Sistem telah berhasil di-deploy pada platform *Hugging Face Spaces* dan dapat diakses secara online melalui <https://acah21-mountjawa.hf.space/>. Sistem dikembangkan menggunakan bahasa pemrograman Python dengan framework FastAPI, sedangkan antarmuka dibangun menggunakan HTML, CSS, JavaScript, dan Jinja2. Sistem memiliki empat halaman utama, yaitu Home, Destination, Nature, dan About. Detail halaman Destination ditunjukkan pada Gambar 8. Gambar 8(a) menampilkan navigation bar dan hero section yang berisi judul serta deskripsi fitur rekomendasi rute pendakian. Gambar 8(b) menunjukkan form input preferensi pengguna seperti provinsi, tingkat kesulitan, durasi pendakian, dan pengalaman pendaki. Selanjutnya, Gambar 8(c) menampilkan 10 rekomendasi rute berdasarkan similarity score, sedangkan Gambar 8(d) menampilkan visualisasi rute pada peta interaktif untuk membantu pengguna memahami lokasi pendakian secara geografis.



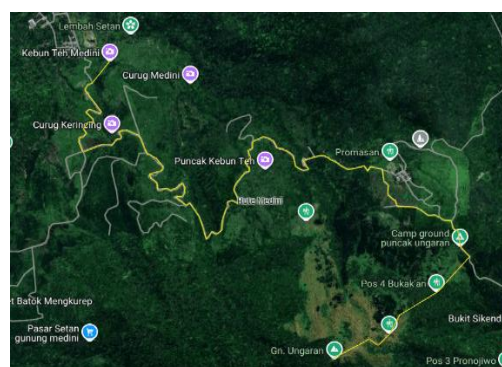
(a)



(b)



(c)



(d)

Sumber: <https://acah21-mountjawa.hf.space/>.

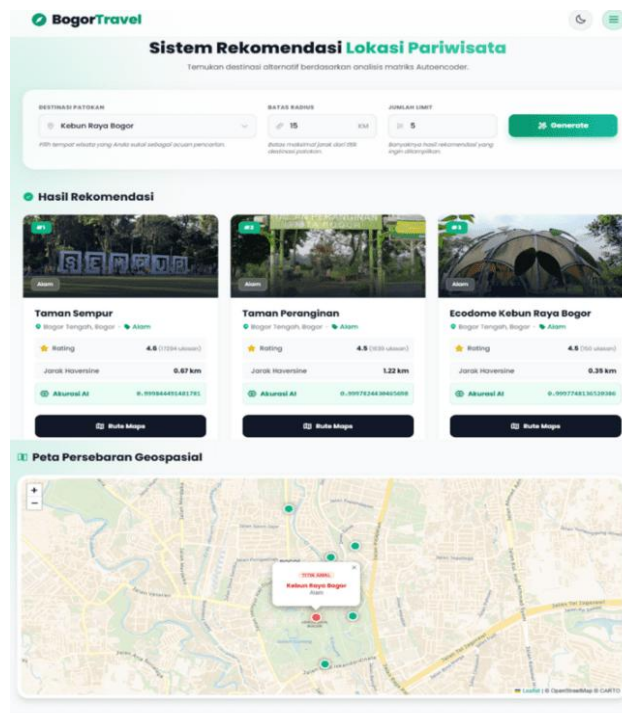
Gambar 8. (a) Hero Section Destination, (b) Form Input, (c) Hasil Rekomendasi, (d) Visualisasi Rute Pendakian

Secara keseluruhan, hasil *deployment* menunjukkan bahwa sistem rekomendasi rute pendakian telah berhasil diimplementasikan dan dapat digunakan secara langsung melalui web untuk membantu pengguna menemukan rute pendakian yang sesuai dengan preferensi mereka.

Pada tahap *deployment*, sistem rekomendasi lokasi pariwisata di Bogor telah berhasil diimplementasikan ke dalam *platform web* menggunakan bahasa pemrograman *Python* dengan *framework Flask*, serta melibatkan bahasa pendukung seperti *HyperText Markup Language (HTML)*, *Cascading Style Sheets (CSS)*, dan *JavaScript (JS)*. Proses penerapan ini diawali dengan melakukan serialisasi komponen komputasi berupa arsitektur jaringan saraf *Encoder (.h5)* dan matriks kemiripan *Cosine Similarity (.pkl)* menggunakan penyimpanan biner agar dapat dimuat oleh peladen secara instan tanpa perlu melatih ulang model dari awal. Aplikasi *web* ini dijalankan secara penuh menggunakan infrastruktur komputasi awan *Hugging Face Spaces* yang dapat diakses publik secara global melalui tautan <https://marioukono-bogor-travel.hf.space>. Hasil penerapan komponen utama dari antarmuka sistem tersebut disajikan pada Gambar 9.



(a)



(b)

Sumber: Hasil Penelitian (2026)

Gambar 9. (a) Tampilan Menu Beranda Utama, (b) Alur Kontrol Parameter Masukan (*Input*) Rekomendasi

Berdasarkan Gambar 9, menu beranda (a) memuat informasi edukatif sebaran pariwisata, sementara panel kontrol (b) memfasilitasi pengaturan parameter masukan (*destinasi, radius, Top-K*) secara *real-time*. Saat tombol *generate* ditekan, peladen mengeksekusi komputasi ruang laten *Autoencoder* dan filter geografis *Haversine Formula* untuk menyajikan rekomendasi *hidden gems*. Sebagai finalisasi utilitas, antarmuka *web* dienkapsulasi menjadi aplikasi Android (.apk) berbasis *WebView* melalui Android Studio (<https://papiunos-bogortravel.hf.space>). Pengujian membuktikan seluruh komponen visual adaptif secara responsif (*responsive design*) pada layar ponsel pintar, sekaligus menuntaskan siklus metodologi *CRISP-DM* menjadi produk digital siap pakai yang berdampak praktis bagi sebaran pariwisata daerah.

4. Kesimpulan

Berdasarkan hasil penelitian, metode *Content-Based Filtering* dengan *Cosine Similarity* terbukti efektif dalam menghasilkan rekomendasi destinasi wisata dan rute pendakian yang sesuai dengan preferensi pengguna. Sistem menggunakan data 126 rute pendakian di Pulau Jawa dan 1.621 destinasi wisata di Bogor. Pada domain pariwisata, performa sistem ditingkatkan menggunakan Deep Autoencoder dan *Haversine Formula* untuk mempertimbangkan kemiripan konten dan kedekatan lokasi. Hasil evaluasi menunjukkan nilai *Precision@10* sebesar 0,80 pada rekomendasi rute pendakian dan 0,85 pada rekomendasi destinasi wisata, yang menandakan bahwa sistem mampu menghasilkan rekomendasi yang relevan dan akurat. Model telah diimplementasikan pada aplikasi berbasis web menggunakan *FastAPI* dan *Flask*, serta dapat dijalankan pada perangkat *Android* melalui *WebView*. Penelitian selanjutnya disarankan untuk memperluas *dataset*, menambahkan faktor kontekstual seperti cuaca dan status gunung, serta mengembangkan metode *Hybrid Recommendation System* untuk meningkatkan kualitas rekomendasi.

Daftar Pustaka

- Aryanto, A. D., Primadewi, A., & Prabowo, N. A. (2025). Rekomendasi Wisata Kabupaten Magelang menggunakan Metode *Content-Based Filtering* dan Location-Based Service. *JURNAL FASILKOM*, 15(1), 172–178. <https://doi.org/10.37859/jf.v15i1.8156>
- Aryanto, A. D., Primadewi, A., & Prabowo, N. A. (2025). Rekomendasi Wisata Kabupaten Magelang menggunakan Metode *Content-Based Filtering* dan Location-Based Service. *Jurnal Fasilkom*, 15(1), 172–178. <https://doi.org/10.37859/jf.v15i1.8156>
- Huda, M. T., & Wibowo, A. P. (2023). Recommendation system for mobile applications tour guide and travel services using demographic filtering and content-based filtering methods based on android. *Journal of World Science*, 2(11), 1837–1856. <https://doi.org/10.58344/jws.v2i11.479>
- Indrasetianingsih, A., Hermanto, E. M. P., Ilham, M., Rahmawati, N., & Hariyanti, I. A. (2025). Perancangan Aplikasi Informasi Pendakian Gunung Di Indonesia Berbasis Android Dengan Menggunakan Metode Prototype. *LPPM Nusa Mandiri*, 19(2), 146–153. <https://doi.org/DOI:>

- <https://doi.org/10.33480/inti.v19i1.5601>
- Irmischer, I. J., & Clarke, K. C. (2018). Measuring and modeling the speed of human navigation. *Cartography and Geographic Information Science*, 45(2), 177–186. <https://doi.org/10.1080/15230406.2017.1292150>
- Jurafsky, D., & Martin, J. H. (2026). *Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition, with Language Models* (3rd ed.).
- Khan, N., & Haroon, M. (2023). Trends and techniques used in tourist recommender system: A review. *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*. <https://doi.org/10.32628/CSEIT23902105>
- Li, K. X., Jin, M., & Shi, W. (2018). Tourism as an important impetus to promoting economic growth: A critical review. *Tourism Management Perspectives*, 26, 135–142. <https://doi.org/10.1016/j.tmp.2017.10.002>
- Mana, S. C., & Sasipraba, T. (2021). Research on Cosine Similarity and Pearson Correlation Based Recommendation Models. *Journal of Physics: Conference Series*, 1770(1), 12014. <https://doi.org/10.1088/1742-6596/1770/1/012014>
- Martinez-Plumed, F., Contreras-Ochando, L., Ferri, C., Hernandez-Orallo, J., Kull, M., Lachiche, N., Ramirez-Quintana, M. J., & Flach, P. (2021). CRISP-DM Twenty Years Later: From Data Mining Processes to Data Science Trajectories. *IEEE Transactions on Knowledge and Data Engineering*, 33(8), 3048–3061. <https://doi.org/10.1109/TKDE.2019.2962680>
- Murphy, K. P. (2022). *Probabilistic machine learning: an introduction*. MIT press.
- Nurmala, N., Hastono, T., & Janah, S. N. (2024). Sistem Pendukung Keputusan Penentuan Dakian Gunung Di Pulau Jawa Menggunakan Fuzzy Logic Mamdani. *Journal Software, Hardware and Information Technology*, 4(1), 35–48. <https://doi.org/10.24252/shift.v4i1.114>
- Pebesma, E., & Bivand, R. (2023). *Spatial Data Science: With Applications in R*. Chapman and Hall/CRC. <https://doi.org/10.1201/9780429459016>
- Pemerintah Kabupaten Bogor. (2025). *Pj. Bupati Bogor Ajak PHRI Jadikan Pariwisata Sebagai Motor Utama Pembangunan*. Portal Resmi Kabupaten Bogor.
- Pratiwi, A., Iftillah, C. T., & Norhikmah, N. (2023). Sistem Pakar Rekomendasi Pendakian Gunung di Jawa Tengah menggunakan Algoritma Fuzzy Tsukamoto Berbasis Website. *Faktor Exacta*, 16(3). <https://doi.org/10.30998/faktorexacta.v16i3.17685>
- Pratiwi, D., Asrianda, A., & Rosnita, L. (2025). Penerapan Metode Content-Based Filtering dalam Sistem Rekomendasi Objek Wisata di Aceh Tamiang. *Jurnal Ilmu Komputer Dan Informatika*, 4(2), 85–96. <https://doi.org/10.54082/jiki.169>
- Ricci, F., Rokach, L., & Shapira, B. (2022). *Fairness in recommender systems*. *Recommender Systems Handbook*. Springer US, New York, NY.
- Salsabilla, C., & Utomo, D. W. (2025). Pekalangan Regency Tourism Recommendation System with Content based Filtering. *Sistemasi: Jurnal Sistem Informasi*, 14(1), 262–270. <https://doi.org/10.32520/stmsi.v14i1.4839>

- Schröer, C., Kruse, F., & Gómez, J. M. (2021). A systematic literature review on applying *CRISP-DM* process model. *Procedia Computer Science*, 181(2019), 526–534. <https://doi.org/10.1016/j.procs.2021.01.199>
- Suryadi, I., Hardan Gutama, D., Danianti, D., & Subhan Yazid, A. (2025). Sistem Rekomendasi Tempat Wisata Alam Di Gunung Kidul Menggunakan Algoritma Content Based Filtering Berbasis Web. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(2), 3324–3331. <https://doi.org/10.36040/jati.v9i2.13344>
- Wijesekara, C., Tittagalla, C., Jayathilaka, A., Ilukpotha, U., Jayathilaka, R., & Jayasinghe, P. (2022). Tourism and economic growth: A global study on Granger causality and wavelet coherence. *Plos One*, 17(9), e0274386. <https://doi.org/10.1371/journal.pone.0274386>
- Yasser, M., Hussain, K. F., & Ali, S. A. (2023). Comparative Analysis of Similarity Methods in High-Dimensional Vectors: A Review. *2023 International Conference on Artificial Intelligence Science and Applications in Industry and Society (CAISAIS)*, 1–6. <https://doi.org/10.1109/CAISAIS59399.2023.10270776>
- Yuan, H., & Hernandez, A. A. (2023). User Cold Start Problem in Recommendation Systems: A Systematic Review. *IEEE Access*, 11, 136958–136977. <https://doi.org/10.1109/ACCESS.2023.3338705>