

Tourism Recommendation System for Labuan Bajo Using Hybrid TF-IDF and Sentence-BERT with Semantic Feature Boosting

Luluk Baitti Kusumaningrum ^{1*}, Arif Nur Rohman ^{2*}

^{*} Sistem Informasi, Universitas Amikom Yogyakarta
lulunew120@gmail.com ¹, arifrahman@amikom.ac.id ²

Article Info

Article history:

Received 2026-05-26

Revised 2026-09-11

Accepted 2026-10-14

Keyword:

Labuan Bajo,
Semantic Feature Boosting,
Sentence-BERT,
TF-IDF,
Tourism Recommendation System.

ABSTRACT

The heterogeneous tourism landscape of Labuan Bajo, ranging from marine excursions to cultural sites, is often inadequately captured by conventional retrieval systems due to vocabulary mismatch. The reliance on rigid lexical matching leads to a failure in grasping the search intent of tourists who use terminology that differs from, yet is semantically equivalent to, destination descriptions. This study addresses this limitation by developing a hybrid recommendation model enhanced with a Semantic Feature Boosting approach. The proposed methodology integrates lexical feature extraction based on TF-IDF (1,2 n-grams) and deep semantic representation using the Sentence-BERT model (paraphrase-multilingual-MiniLM-L12-v2). Both vector representations are combined through an adaptive weighting scheme (0.6 for TF-IDF and 0.4 for Sentence-BERT) to compute destination relevance based on cosine similarity. Empirical evaluation across ten query scenarios representing diverse tourist needs demonstrates robust performance: Mean Precision@5 = 0.90, Mean Recall@5 = 0.81, Mean Average Precision@5 = 0.89, and Mean NDCG@5 = 0.93. Statistical significance testing (Wilcoxon signed-rank, $p < 0.05$) confirms that the hybrid approach outperforms *Pure* lexical and *Pure* semantic baselines. This comprehensive evaluation demonstrates that the integration of semantic features significantly enhances the system's ranking quality and ability to understand diverse search contexts. Thus, the proposed approach proves effective in generating more precise and adaptive recommendations for complex tourism landscapes, while providing a methodological contribution to recommendation systems responsive to natural language variations.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Labuan Bajo merupakan salah satu destinasi pariwisata super prioritas Indonesia yang mengalami pertumbuhan pesat beberapa tahun terakhir [1]. Hal tersebut ditandai dengan melonjaknya jumlah kunjungan wisatawan. Tidak hanya itu, keragaman aktivitas wisata dan destinasi juga ikut berkembang. Perkembangan ini tidak luput disertai meningkatnya ketersediaan informasi wisata dalam jumlah besar melalui berbagai platform digital, yang umumnya disajikan dalam bentuk konten tekstual seperti deskripsi destinasi, ulasan wisatawan, dan fasilitas. Namun, pada faktanya informasi yang semakin melimpah tersebut tidak selalu memudahkan wisatawan dalam menentukan destinasi

yang sesuai dengan preferensi personal [2]. Wisatawan sering mengalami information overload, yaitu kesulitan memilah informasi yang relevan akibat banyaknya pilihan yang tersedia [3], [4]. Kondisi ini menyebabkan proses pengambilan keputusan menjadi kurang efisien dan berpotensi menurunkan kualitas pengalaman wisata, terutama ketika sistem pendukung keputusan belum mampu memanfaatkan informasi tekstual secara optimal dan kontekstual [5].

Sejumlah penelitian terdahulu telah mengembangkan sistem rekomendasi wisata di Labuan Bajo menggunakan pendekatan K-Nearest Neighbor (KNN) dengan skema atribut diskrit yang berbeda. Penelitian pertama menggunakan tiga atribut yaitu aktivitas, jenis wisata, dan kategori harga dengan

18 data dan $K=5$ sehingga memperoleh akurasi 83,33% [3]. Penelitian lain menggunakan empat atribut berbeda yaitu aktivitas, jenis kapal, lama perjalanan, dan jenis wisata dengan skala data yang lebih kecil yaitu enam data latih dan tiga data uji pada $K=3$ [3], [4]. Meskipun pendekatan tersebut menunjukkan performa yang cukup baik pada data terbatas, terdapat keterbatasan fundamental pada representasi fitur yang digunakan, yaitu seluruh atribut bersifat kategorikal dan terbatas pada kategori yang telah ditentukan sebelumnya (closed set), sehingga jarak antardata hanya dapat dihitung berdasarkan kecocokan kategori yang sudah didefinisikan di awal. Ketergantungan terhadap desain atribut yang tertutup ini menyebabkan sistem bersifat kaku (rigid) dan tidak mampu menangkap preferensi wisatawan yang diekspresikan dalam bahasa alami, seperti "pantai yang sepi" atau "wisata dengan nuansa budaya lokal". Akibatnya, ruang representasi sistem menjadi terbatas pada kategori yang telah ditentukan, sehingga potensi variasi preferensi pengguna tidak dapat dimodelkan secara utuh.

Keterbatasan lain yang menonjol dari pendekatan berbasis atribut diskrit tersebut adalah terabaikannya informasi tekstual yang kaya makna, seperti narasi deskripsi destinasi dan ulasan wisatawan. Pendekatan content-based filtering berbasis TF-IDF telah digunakan untuk mengatasi hal ini dengan memanfaatkan data teks dan terbukti efektif dalam menonjolkan kata kunci yang menjadi ciri khas suatu destinasi melalui pembobotan statistik [5], [6]. Namun, karena TF-IDF bekerja murni berdasarkan frekuensi dan distribusi kemunculan kata, pendekatan ini pada dasarnya hanya mampu mengenali kesamaan pada level leksikal: dua destinasi dengan karakteristik serupa namun dideskripsikan dengan kosakata yang berbeda akan dianggap tidak mirip oleh sistem, suatu permasalahan yang dikenal sebagai vocabulary mismatch. Di sisi lain, pendekatan embedding semantik seperti Sentence-BERT telah dibuktikan secara empiris mampu mengatasi permasalahan tersebut pada domain pencarian dokumen akademik, di mana pendekatan berbasis Sentence-BERT menghasilkan rata-rata precision dan recall yang jauh lebih tinggi (0,88 dan 0,65) dibandingkan pencarian berbasis kata kunci murni (0,24 dan 0,12) [7]. Temuan ini mengindikasikan bahwa representasi semantik memiliki potensi besar untuk diadopsi pada domain pariwisata, meskipun perlu digarisbawahi bahwa karakteristik query pada domain pariwisata yang umumnya berupa kata kunci pendek seperti nama destinasi, jenis aktivitas, atau lokasi berbeda dari karakteristik query dokumen akademik yang diuji pada penelitian tersebut. Namun, integrasi pendekatan leksikal dan semantik dalam sistem rekomendasi wisata Labuan Bajo masih belum banyak dieksplorasi.

Berdasarkan kondisi tersebut, permasalahan utama dalam penelitian ini adalah ketidakseimbangan antara presisi leksikal dan generalisasi semantik yang berdampak pada kualitas pemeringkatan dan relevansi rekomendasi wisata. Oleh karena itu, penelitian ini mengevaluasi kualitas rekomendasi menggunakan metrik Precision@5, Recall@5, MAP@5, dan NDCG@5. Berdasarkan celah penelitian

tersebut, penelitian ini mengusulkan sistem rekomendasi wisata Labuan Bajo berbasis *content-based filtering* yang mengombinasikan TF-IDF dan *semantic feature boosting* menggunakan Sentence-BERT. Pendekatan ini mengintegrasikan kekuatan pencocokan kata kunci dan pemahaman semantik untuk menghasilkan rekomendasi yang lebih relevan serta meningkatkan kualitas pemeringkatan destinasi wisata, sekaligus memastikan efisiensi komputasi agar sistem tetap responsif saat menyajikan hasil secara *real-time* [8].

II. METODE

A. Objek dan Sumber Data Penelitian

Penelitian ini menggunakan dataset sekunder domain pariwisata yang terdiri atas 51 destinasi wisata di kawasan Labuan Bajo dan sekitarnya, Kabupaten Manggarai Barat, Nusa Tenggara Timur. Dataset dikembangkan menggunakan pendekatan *hybrid data collection*, yang mengintegrasikan ekstraksi data melalui Google Maps/Google Places API serta pengumpulan informasi dari berbagai sumber pariwisata daring yang kredibel seperti TripAdvisor, platform biro perjalanan wisata resmi, situs web resmi Dinas Pariwisata, dll. Setiap entitas destinasi direpresentasikan sebagai satu unit data dengan atribut utama meliputi nama wisata, kategori, deskripsi, tipe destinasi, aktivitas wisata, dan lokasi geografis terstruktur. Pendekatan ini digunakan untuk memastikan bahwa dataset memiliki representasi informasi spasial dan tekstual yang lengkap, sehingga sesuai untuk pemodelan sistem rekomendasi berbasis teks dan analisis kesamaan semantik.


Seluruh data melalui tahapan data preprocessing yang mencakup data cleaning, deduplikasi, dan normalisasi teks untuk mengurangi noise serta menyamakan variasi penulisan antarsumber. Selain itu, dilakukan proses content enrichment berbasis multi-sumber pariwisata daring, di mana informasi dari berbagai platform wisata digunakan untuk melengkapi dan menstandarisasi deskripsi destinasi agar lebih informatif dan konsisten. Proses ini juga mencakup content curation terkontrol, yaitu penyelarasan informasi agar tetap sesuai dengan fakta objek wisata tanpa mengubah makna asli data. Dataset CSV digunakan sebagai input metode TF-IDF dan Sentence-BERT untuk perhitungan *cosine similarity* pada sistem.

TABEL 1
RINGKASAN DATASET PENELITIAN

Aspek Dataset	Keterangan
Jumlah destinasi	51 destinasi wisata
Wilayah	Labuan Bajo dan sekitarnya, NTT
Sumber data	Google Maps/Google Places API + sumber pariwisata daring kredibel
Metode pengumpulan	Hybrid data collection (API extraction + web sources)
Atribut utama	Nama, Kategori, Deskripsi, Tipe, Aktivitas, Lokasi
Data preprocessing	Data cleaning, deduplikasi, normalisasi teks
Content enrichment	Multi-source synthesis + curation
Format data	CSV

B. Kerangka Alur Penelitian


Untuk mempermudah pelaksanaan penelitian dan memberikan gambaran alur kerja yang sistematis, penulis menyusun kerangka kerja penelitian sebagaimana ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian

Penelitian ini diawali dengan tahap pengumpulan data berupa data tekstual destinasi wisata Labuan Bajo yang diperoleh dari sumber resmi pariwisata dan platform digital. Tahap selanjutnya adalah studi literatur untuk mengkaji konsep sistem rekomendasi pariwisata, *content-based filtering*, TF-IDF, Sentence-BERT, serta teknik pengukuran kemiripan. Berdasarkan hasil studi tersebut, dilakukan perancangan sistem yang mencakup alur rekomendasi, skema pengolahan data, dan integrasi fitur statistik serta semantik. Tahap implementasi sistem meliputi pra-pemrosesan data, ekstraksi fitur, perhitungan kemiripan, dan penyajian rekomendasi. Tahap akhir adalah pengujian sistem untuk mengevaluasi kinerja dan kesesuaian sistem dengan tujuan penelitian.

C. Skema Sistem Rekomendasi Wisata



Gambar 2. Skema Sistem

Skema sistem diawali dengan pengumpulan data destinasi wisata Labuan Bajo yang diperoleh dari sumber pariwisata

terpercaya. Data yang dikumpulkan berupa informasi tekstual, seperti nama destinasi, kategori wisata, dan deskripsi destinasi, kemudian melalui tahap pra-pemrosesan untuk membersihkan dan menstandarkan teks. Selanjutnya, fitur diekstraksi menggunakan TF-IDF dan Sentence-BERT, kemudian dikombinasikan melalui semantic feature boosting untuk menghasilkan representasi fitur yang lebih kaya. Berdasarkan representasi tersebut, sistem menghitung tingkat kemiripan antara preferensi pengguna dan destinasi wisata guna menghasilkan rekomendasi yang relevan, yang selanjutnya dievaluasi untuk mengukur kualitas rekomendasi yang dihasilkan.

D. Pra-pemrosesan Data Teks

Pra-pemrosesan data teks merupakan tahap awal yang penting dalam penelitian ini untuk memastikan kualitas data sebelum dilakukan ekstraksi fitur. Tahap ini bertujuan untuk mengurangi noise, meningkatkan konsistensi teks, serta menyiapkan data agar dapat diproses secara optimal oleh dua pendekatan yang digunakan, yaitu TF-IDF berbasis representasi leksikal dan Sentence-BERT berbasis representasi semantik [9]. Oleh karena itu, strategi pra-pemrosesan tidak diterapkan secara seragam, melainkan disesuaikan dengan karakteristik masing-masing metode agar tidak mengurangi kualitas representasi teks.

Tahapan pra-pemrosesan yang digunakan dalam penelitian ini meliputi:

1. *Case Folding*, yaitu mengubah seluruh teks menjadi huruf kecil (lowercase) untuk mengurangi variasi penulisan yang dapat menyebabkan inkonsistensi dalam pencocokan kata maupun representasi vektor.
2. *Punctuation Removal*, yaitu proses pembersihan teks dari tanda baca, angka, dan simbol yang tidak memiliki kontribusi signifikan terhadap makna semantik maupun leksikal dalam konteks deskripsi destinasi wisata.
3. *Stopword Removal*, yaitu penghapusan kata-kata umum yang tidak memiliki nilai informasi tinggi seperti “dan”, “yang”, “di”, dan “ke”, yang khusus diterapkan pada pipeline TF-IDF untuk meningkatkan kualitas pembobotan kata.
4. *Stemming*, yaitu proses konversi kata ke bentuk dasar dengan menghilangkan imbuhan untuk mereduksi variasi leksikal. Proses ini hanya diterapkan pada pendekatan TF-IDF untuk mengoptimalkan pencocokan kata kunci eksak. Sebaliknya, Sentence-BERT tidak menggunakan stemming agar struktur linguistik alami dan informasi kontekstual yang kaya di dalam kalimat tetap terjaga utuh selama proses pembentukan *embedding*.

Tahap pra-pemrosesan ini menghasilkan dua bentuk representasi teks, yaitu teks terstandarisasi untuk TF-IDF dan teks kontekstual untuk Sentence-BERT, sehingga masing-masing metode dapat bekerja sesuai karakteristiknya dalam menangkap kesamaan antardestinasi wisata secara leksikal maupun semantik.

E. Ekstraksi Fitur Menggunakan TF-IDF

TF-IDF digunakan untuk mentransformasikan data teks menjadi vektor numerik melalui pemberian bobot pada setiap kata berdasarkan frekuensi lokal dan distribusinya pada seluruh dokumen [10]. Dalam penelitian ini, TF-IDF digunakan untuk merepresentasikan destinasi wisata berdasarkan kata kunci penting yang muncul dalam deskripsi teks [11]. Nilai Term Frequency (TF) dihitung dengan rumus:

$$tf_{i,j} = \frac{f_{i,j}}{d_j}$$

di mana $f_{i,j}$ adalah jumlah kemunculan kata ke- i pada dokumen ke- j , dan d_j adalah total kata dalam dokumen ke- j . Nilai Inverse Document Frequency (IDF) dihitung dengan rumus:

$$idf_i = \log\left(\frac{N+1}{df_i+1}\right) + 1$$

dengan N adalah jumlah total dokumen dalam koleksi, dan df_i menyatakan jumlah dokumen yang mengandung kata ke- i . Bobot akhir TF-IDF diperoleh dengan:

$$w_{i,j} = tf_{i,j} \times idf_i$$

Nilai $w_{i,j}$ menunjukkan tingkat kepentingan kata ke- i dalam dokumen ke- j dibandingkan dengan dokumen lainnya dalam koleksi. Representasi TF-IDF ini efektif dalam menonjolkan kata kunci spesifik yang membedakan satu destinasi wisata dengan destinasi lainnya [12].

F. Ekstraksi Fitur Semantik Menggunakan Sentence-BERT

Ekstraksi fitur semantik dilakukan dengan mentransformasikan deskripsi korpus dan kueri pengguna ke dalam dense vector berdimensi 384 melalui model pre-trained Sentence-BERT paraphrase-multilingual-MiniLM-L12-v2. Model ini dipilih karena mendukung Bahasa Indonesia secara native, dioptimalkan untuk tugas semantic similarity, serta menawarkan keseimbangan antara akurasi semantik dan efisiensi komputasi yang sesuai untuk kebutuhan sistem real-time. Proses ini bekerja dengan merata-ratakan representasi token kontekstual dari lapisan terakhir jaringan BERT menggunakan strategi MEAN-pooling untuk menghasilkan satu vektor kalimat tunggal yang utuh. Pendekatan berbasis koordinat vektor kontinu ini secara inheren sangat tangguh dalam mengatasi derau linguistik kueri dunia nyata tanpa memerlukan kamus manual ataupun prapemrosesan sekunder yang kaku. Pertama, kesalahan ejaan (typo) kecil seperti "traking" atau "poto") berhasil dimitigasi melalui algoritma tokenisasi subword (WordPiece) yang bertumpu pada potongan unit makna terkecil alih-alih keutuhan kata luar. Kedua, fenomena bahasa campuran (code-switching Indonesia-Inggris seperti kueri "spot foto sunset") dan penggunaan sinonim lokal (seperti kata "fajar" untuk "sunrise") otomatis teratasi berkat integrasi ruang vektor bersama dalam arsitektur lintas bahasa, yang secara matematis memetakan istilah-istilah yang berbeda kata

tersebut pada koordinat geometris yang saling berdekatan karena kesamaan konteks maknanya.

G. Semantic Feature Boosting

Guna mengoptimalkan presisi rekomendasi wisata, penelitian ini mengusulkan integrasi strategi semantic feature boosting. Pendekatan ini diadopsi untuk melampaui keterbatasan analisis tekstual konvensional dengan cara menggali kedalaman makna serta konteks deskripsi destinasi secara lebih komprehensif [8]. Secara teknis, pendekatan yang diusulkan mengintegrasikan representasi vektor leksikal TF-IDF dan representasi semantik Sentence-BERT melalui mekanisme weighted feature-level concatenation. Pendekatan ini memungkinkan sistem mempertimbangkan kecocokan kata kunci sekaligus kesamaan makna secara kontekstual dalam proses perankingan destinasi wisata. Dengan demikian, rekomendasi yang dihasilkan tidak hanya relevan secara leksikal, tetapi juga mampu menangkap hubungan semantik antardeskripsi destinasi. Proses semantic feature boosting dilakukan dengan menggabungkan representasi vektor yang dihasilkan oleh TF-IDF dan Sentence-BERT menggunakan skema pembobotan terkontrol. Vektor gabungan tersebut kemudian digunakan untuk menghitung skor kemiripan menggunakan persamaan berikut:

$$V_{hybrid} = [\alpha \cdot V_{TFIDF}; \beta \cdot V_{SBERT}]$$

$$HybridScore(q, d) = \cos(V_{hybrid(q)}, V_{hybrid(d)})$$

Penentuan bobot pada mekanisme *semantic feature boosting* dilakukan melalui studi empiris menggunakan *sensitivity analysis* terhadap beberapa skenario pembobotan TF-IDF dan Sentence-BERT, yaitu 0,5:0,5; 0,6:0,4; 0,7:0,3; 0,8:0,2; dan 0,9:0,1. Setiap konfigurasi dievaluasi menggunakan metrik Precision@5, Recall@5, MAP@5, dan nDCG@5 pada sejumlah kueri yang merepresentasikan kebutuhan pencarian wisatawan. Dengan demikian, bobot yang digunakan tidak ditentukan secara manual, melainkan diperoleh melalui proses evaluasi eksperimental untuk menemukan konfigurasi yang memberikan kualitas rekomendasi terbaik.

Hasil pengujian menunjukkan bahwa konfigurasi $\alpha = 0,6$ dan $\beta = 0,4$ menghasilkan performa yang paling konsisten dibandingkan konfigurasi lainnya. Temuan ini menunjukkan bahwa pencarian destinasi wisata masih sangat dipengaruhi oleh kata kunci spesifik yang digunakan pengguna, sehingga representasi leksikal perlu diberikan kontribusi yang lebih besar. Namun, kontribusi semantik tetap diperlukan untuk menangkap kesamaan makna antardeskripsi destinasi yang tidak dapat diidentifikasi hanya melalui pencocokan kata. Oleh karena itu, konfigurasi $\alpha = 0,6$ dan $\beta = 0,4$ dipilih karena mampu memberikan keseimbangan terbaik antara ketepatan pencocokan kata kunci dan pemahaman konteks semantik, sehingga menghasilkan rekomendasi yang lebih relevan dan stabil pada berbagai skenario pengujian.

H. Perhitungan Similarity dan Rekomendasi

Pengukuran kemiripan antara preferensi pengguna dan destinasi wisata dilakukan menggunakan metode *cosine similarity*. Metode ini digunakan untuk menghitung nilai kosinus antara dua vektor guna mengukur tingkat kemiripan antaritem yang dirumuskan sebagai berikut [13]:

$$\text{sim}(q, d_j) = \frac{q \cdot d_j}{\|q\| \times \|d_j\|}$$

di mana q merupakan vektor preferensi pengguna dan d_j adalah vektor representasi destinasi wisata ke- j . Nilai *cosine similarity* berada pada rentang 0 hingga 1. Semakin mendekati nilai 1, maka tingkat kemiripan antara preferensi pengguna dan destinasi wisata semakin tinggi [5]. Destinasi dengan nilai kemiripan tertinggi kemudian direkomendasikan kepada pengguna.

I. Evaluasi Sistem

Evaluasi sistem dilakukan untuk mengukur kemampuan sistem rekomendasi dalam menghasilkan destinasi wisata yang relevan sesuai kebutuhan pengguna. Pengujian dilakukan menggunakan metrik Precision@K, Recall@K, Mean Average Precision (MAP), dan Normalized Discounted Cumulative Gain (NDCG). Evaluasi dilakukan berdasarkan *ground-truth relevance judgment* yang telah ditentukan secara manual untuk setiap skenario kueri.

Precision at K mengukur proporsi item relevan yang berhasil direkomendasikan oleh sistem dalam sejumlah K rekomendasi teratas[14]. Metrik ini menunjukkan tingkat ketepatan sistem dalam menyajikan item yang benar-benar sesuai dengan preferensi pengguna dari seluruh item yang direkomendasikan [15]. Precision at K dapat dihitung menggunakan persamaan berikut:

$$\text{Precision@K} = \frac{\text{Jumlah item relevan dalam K rekomendasi}}{\text{Total item yang direkomendasikan (K)}}$$

Nilai Precision yang tinggi menunjukkan bahwa sebagian besar rekomendasi yang diberikan sistem memiliki relevansi yang baik, sehingga mencerminkan kualitas rekomendasi yang dihasilkan.

Recall@K mengukur kemampuan sistem dalam menemukan seluruh item relevan yang tersedia. Semakin tinggi nilai Recall, semakin banyak item relevan yang berhasil direkomendasikan. Recall@K dihitung menggunakan persamaan berikut [16]:

$$\text{Recall@K} = \frac{\text{Jumlah Item Relevan dalam Top - K}}{\text{Total Item Relevan}}$$

dengan:

- Jumlah Item Relevan dalam Top-K = banyaknya destinasi relevan yang muncul pada K rekomendasi teratas.

- Total Item Relevan = seluruh destinasi yang dianggap relevan berdasarkan *ground-truth relevance judgment*.

Mean Average Precision (MAP) digunakan untuk mengevaluasi kualitas pemeringkatan rekomendasi dengan mempertimbangkan posisi kemunculan item relevan pada daftar hasil rekomendasi. Nilai MAP diperoleh dari rata-rata nilai Average Precision (AP) pada seluruh kueri pengujian. MAP dihitung menggunakan persamaan [16]:

$$\text{MAP} = \left(\frac{1}{|Q|} \right) \sum_{q=1}^{|Q|} \text{AP}_q$$

dengan:

- MAP= Mean Average Precision.
- $|Q|$ = Jumlah kueri pengujian
- q = Indeks kueri ke - q
- AP_q = Nilai Average Precision kueri ke - q

Normalized Discounted Cumulative Gain (NDCG) merupakan metrik yang digunakan untuk mengevaluasi kualitas pemeringkatan hasil rekomendasi berdasarkan relevansi item dan posisinya dalam daftar rekomendasi. Metrik ini banyak digunakan pada sistem rekomendasi dan *information retrieval* karena mampu memberikan bobot yang lebih besar pada item relevan yang muncul pada posisi atas. Nilai NDCG berada pada rentang 0 hingga 1, di mana nilai yang semakin mendekati 1 menunjukkan bahwa urutan rekomendasi yang dihasilkan semakin mendekati urutan ideal.

Perhitungan NDCG diawali dengan menghitung nilai Discounted Cumulative Gain (DCG) yang mengakumulasi skor relevansi setiap item berdasarkan posisinya dalam daftar rekomendasi [17]. DCG dihitung menggunakan persamaan berikut :

$$\text{DCG@K} = \sum_{i=1}^K \frac{2^{\text{rel}_i} - 1}{\log_{2(i+1)}}$$

dengan:

- K = Jumlah rekomendasi yang dievaluasi
- i = Posisi item pada daftar rekomendasi
- rel_i = Nilai relevansi item pada posisi ke - i

Selanjutnya dihitung nilai Ideal Discounted Cumulative Gain (IDCG), yaitu nilai DCG maksimum yang diperoleh apabila seluruh item relevan berada pada urutan terbaik. Perhitungan IDCG ditunjukkan pada persamaan:

$$\text{IDCG@K} = \sum_{i=1}^K \frac{2^{\text{rel}_i^*} - 1}{\log_{2(i+1)}}$$

dengan:

- rel_i^* = Nilai relevansi item pada urutan ideal

- K : Jumlah rekomendasi yang dievaluasi
- i : Posisi item pada daftar rekomendasi

Nilai NDCG diperoleh dengan membandingkan nilai DCG terhadap nilai IDCG sebagaimana ditunjukkan pada persamaan:

$$NDCG@K = \frac{DCG@K}{IDCG@K}$$

Dengan menggunakan metrik Precision@K, Recall@K, MAP, dan NDCG, evaluasi dapat dilakukan secara komprehensif terhadap kualitas hasil rekomendasi yang dihasilkan sistem. Precision dan Recall digunakan untuk mengukur ketepatan serta kelengkapan item relevan yang berhasil direkomendasikan, sedangkan MAP dan NDCG digunakan untuk mengevaluasi kualitas pemeringkatan hasil rekomendasi. Kombinasi keempat metrik tersebut memberikan gambaran yang lebih menyeluruh mengenai performa sistem rekomendasi wisata yang dikembangkan.

III. HASIL DAN PEMBAHASAN

Sistem rekomendasi wisata Labuan Bajo dibangun melalui tahapan pra-pemrosesan data, ekstraksi fitur menggunakan TF-IDF dan Sentence-BERT, serta penggabungan fitur melalui semantic feature boosting untuk menghasilkan rekomendasi destinasi yang relevan. Bagian ini menyajikan hasil implementasi setiap tahapan metode yang diusulkan, mulai dari penyusunan dataset, ekstraksi representasi tekstual, hingga evaluasi performa sistem.

TABEL 2
DATA WISATA

NO	Nama Wisata
1	Pulau Komodo
2	Pulau Padar
3	Pink Beach
4	Pulau Rinca
5	Gua Batu Cermin
6	Bukit Sylvia
7	Pulau Kanawa
8	Pulau Kelor
9	Pulau Sebayur
10	Pulau Manjarite
11	...
51	Nera Lounge

Tabel 2 menyajikan daftar destinasi wisata yang digunakan sebagai dataset penelitian. Dataset tersebut dirancang untuk merepresentasikan keragaman karakteristik pariwisata Labuan Bajo, meliputi wisata bahari, pulau, pantai, air terjun, desa wisata, dan wisata budaya. Keragaman ini penting karena memungkinkan sistem mengevaluasi tingkat kemampuannya dalam membedakan preferensi pengguna pada berbagai kategori destinasi yang memiliki karakteristik deskriptif yang berbeda. Selain berfungsi sebagai sumber data utama, dataset ini juga menjadi dasar pembentukan representasi leksikal dan semantik yang digunakan dalam proses rekomendasi. Keberagaman atribut tekstual pada setiap destinasi memungkinkan TF-IDF mengidentifikasi kata

kunci yang dominan, sementara Sentence-BERT menangkap hubungan makna yang lebih kontekstual. Dengan demikian, kualitas dan variasi dataset memiliki peran penting dalam menghasilkan rekomendasi yang relevan dan sesuai dengan preferensi pengguna.

A. Pra-Pemrosesan Data

TABEL 3
HASIL PRA PEMROSESAN DATA

N o	Nama Wisata	Teks Gabungan (Contoh)	Teks Bersih Leksikal (TF-IDF)	Teks Bersih Semantik (SBERT)
1	Pulau Komodo	Pulau Komodo Alam konservasi habitat komodo...	pulau komodo alam konservasi habitat komodo...	pulau komodo alam konservasi habitat komodo...
2	Pulau Padar	Pulau Padar panorama tiga teluk...	pulau padar panorama tiga teluk...	pulau padar panorama tiga teluk...
3	Pink Beach	Pantai pasir merah muda laut jernih...	pink beach pasir merah muda laut jernih...	pink beach pasir merah muda laut jernih...
4	Pulau Rinca	Pulau Rinca Alam Pulau habitat komodo dengan jalur trekking alam liar...	pulau rinca alam pulau habitat komodo jalur trekking alam liar...	pulau rinca alam pulau habitat komodo jalur trekking alam liar...
5	Gua Batu Cermin	Gua Batu Cermin, Alam, Gua	gua batu cermin alam gua..	gua batu cermin alam gua...

Hasil pra-pemrosesan pada Tabel 3 menunjukkan bahwa penerapan dua jalur pemrosesan yang berbeda menghasilkan representasi teks yang lebih sesuai dengan kebutuhan masing-masing metode ekstraksi fitur. Pada jalur TF-IDF, proses *stopword removal* dan *stemming* berhasil mengurangi kata-kata tidak informatif serta menyatukan variasi bentuk kata guna meningkatkan kemampuan identifikasi karakteristik destinasi. Sebaliknya, pada jalur Sentence-BERT, teks dipertahankan dalam bentuk alami tanpa *stemming* agar konteks linguistik dan hubungan makna antar-kata tetap terjaga. Temuan tersebut mengindikasikan bahwa kualitas rekomendasi tidak hanya ditentukan oleh algoritma, tetapi juga oleh kesesuaian proses pra-pemrosesan terhadap karakteristik model. Jika *stemming* diterapkan pada seluruh data, informasi kontekstual yang dibutuhkan Sentence-BERT berpotensi berkurang, sedangkan tanpa normalisasi yang memadai TF-IDF akan menghasilkan representasi yang lebih *sparse* dan kurang diskriminatif. Oleh karena itu, penggunaan dua jalur pra-pemrosesan menjadi landasan penting dalam *semantic feature boosting* karena memungkinkan TF-IDF mempertahankan kekuatan pencocokan kata kunci, sementara Sentence-BERT tetap mampu menangkap hubungan semantik antar-destinasi.

B. Ekstraksi Fitur TF-IDF

TABEL 4
SAMPel EKSTRAKSI FITUR TF-IDF

Nama Destinasi Wisata	Top Fitur 1	Top Fitur 2	Top Fitur 3
Pulau Komodo	pulau (0,401)	pulau komodo (0,369)	komodo (0,187)
Pulau Padar	pulau (0,385)	padar (0,355)	pulau padar (0,355)
Pink Beach	pink (0,360)	pink beach (0,360)	beach (0,283)
Pulau Rinca	pulau (0,376)	pulau rinca (0,313)	rinca (0,313)
Gua Batu Cermin	gua (0,404)	batu (0,250)	alami celah (0,149)

Proses ekstraksi fitur TF-IDF menghasilkan 845 fitur unik dari 51 dokumen wisata dengan total 2357 elemen non-zero dan tingkat sparsity sebesar 94,53%. Tingginya sparsity menunjukkan bahwa sebagian besar fitur tidak muncul secara bersamaan pada setiap dokumen, sehingga representasi yang terbentuk cenderung spesifik terhadap karakteristik masing-masing destinasi. Kondisi ini mengindikasikan bahwa deskripsi wisata dalam dataset memiliki keragaman kosakata yang cukup tinggi dan mampu menghasilkan representasi leksikal yang diskriminatif. Temuan tersebut sejalan dengan penelitian sebelumnya [5] yang menunjukkan bahwa TF-IDF efektif dalam mengidentifikasi karakteristik utama destinasi wisata melalui term-term yang paling dominan pada deskripsi objek wisata. Namun, pendekatan tersebut masih bergantung pada kesamaan kosakata sehingga hubungan antardestinasi ditentukan terutama oleh kemunculan kata yang sama.

Hasil pada Tabel 4 memperlihatkan bahwa fitur dengan bobot tertinggi secara konsisten merepresentasikan identitas utama masing-masing destinasi. Pulau Komodo didominasi oleh term yang berkaitan langsung dengan entitas komodo, Pulau Padar oleh term yang merepresentasikan identitas geografisnya, Pink Beach oleh term yang menggambarkan objek wisata pantai yang khas, sedangkan Gua Batu Cermin didominasi oleh term yang berkaitan dengan karakteristik geologinya. Pola tersebut menunjukkan bahwa TF-IDF berhasil mengekstraksi fitur yang memiliki daya pembeda tinggi antardestinasi sehingga setiap objek wisata memperoleh representasi leksikal yang unik. Akan tetapi, representasi tersebut belum mampu menangkap kesamaan makna apabila dua destinasi memiliki karakteristik serupa tetapi dideskripsikan menggunakan kosakata yang berbeda. Oleh karena itu, penelitian ini mengintegrasikan Sentence-BERT melalui mekanisme semantic feature boosting untuk melengkapi kekuatan TF-IDF.

C. Ekstraksi Semantik Sentence-Bert

Representasi fitur semantik dalam arsitektur hibrida dikonstruksikan menggunakan model deep learning transformer Sentence-BERT. Berbeda dengan pembobotan leksikal berbasis TF-IDF yang menghasilkan matriks jarang (sparse matrix), Sentence-BERT mentransformasikan

informasi kontekstual dari deskripsi destinasi pariwisata Labuan Bajo ke dalam ruang vektor kontinu dan padat (dense embedding) berdimensi $d = 384$. Sebagai bukti formalitas representasi matematis dari luaran model, sampel degradasi nilai koordinat latent dimension dari ruang vektor Sentence-BERT disajikan pada Tabel 5. Karena angka-angka pada Tabel 5 berbentuk dimensi abstrak yang tidak dapat diinterpretasikan langsung secara visual, diperlukan pengujian Information Retrieval (IR) murni menggunakan kueri penalar tanpa entitas nama tempat eksplisit untuk memvalidasi akurasi penajajaran makna (semantic alignment).

TABEL 5
SAMPel DISTRIBUSI NILAI KOORDINAT LATEN DENSE EMBEDDING SENTENCE-BERT

No	Nama Destinasi Wisata	dim1	dim2	dim3	dim4	...
1	Pulau Komodo	- 0.08133	0.08816	0.13694	0.17756	...
2	Pulau Padar	0.06381	- 0.15027	0.24146	0.10997	...
3	Pink Beach	- 0.00879	- 0.26649	0.43422	0.18312	...
4	Pulau Rinca	0.01873	- 0.06184	0.19192	0.15189	...
5	Gua Batu Cermin	- 0.15285	0.29127	0.19186	0.17092	...

TABEL 6
SAMPel PENGUJIAN ALIGNMENT SEMANTIK SENTENCE-BERT TERHADAP KUEIR ABSTRAK

No	Kueri Uji Semantik (Maksud Pengguna)	Destinasi Paling Mirip (Top-1)	Cosine Similarity Sentence-BERT
1	Pantai pasir putih	Pantai Waecicu	0.66057
2	Habitat komodo	Loh Buaya	0.58109
3	Trekking savana	Bukit Lontar	0.46154

Hasil yang ditunjukkan pada Tabel 5 dan Tabel 6 sejalan dengan penelitian sebelumnya [7] yang menyatakan bahwa model berbasis transformer seperti Sentence-BERT mampu menghasilkan representasi semantik yang lebih baik dibandingkan pendekatan berbasis frekuensi seperti TF-IDF dalam tugas information retrieval. Hal ini disebabkan oleh kemampuan Sentence-BERT dalam membentuk contextualized embedding yang tidak hanya bergantung pada kemunculan kata, tetapi juga pada hubungan makna antarkata dalam suatu konteks.

Dalam penelitian ini, hal tersebut terlihat dari keberhasilan model dalam memetakan kueri abstrak seperti “Pantai pasir putih” ke “Pantai Waecicu” serta “habitat komodo” ke “Loh Buaya”. Hasil ini menunjukkan bahwa representasi embedding yang dihasilkan mampu menangkap kesamaan

makna pada level konseptual, bukan hanya kesamaan leksikal. Dengan demikian, Sentence-BERT efektif digunakan sebagai semantic encoder dalam sistem rekomendasi berbasis teks karena mampu mengatasi permasalahan vocabulary mismatch dan meningkatkan relevansi hasil pencarian berdasarkan konteks. Namun demikian, hasil ini juga mengindikasikan bahwa pendekatan berbasis dense embedding memiliki kecenderungan untuk menghasilkan kedekatan semantik yang sangat spesifik, sehingga perlu dikombinasikan dengan pendekatan berbasis lexical matching seperti TF-IDF agar tetap menjaga keseimbangan antara akurasi makna dan konsistensi identitas entitas destinasi.

D. Semantic Feature Boosting

Hasil implementasi semantic feature boosting menunjukkan bahwa integrasi TF-IDF (845 dimensi) dan Sentence-BERT (384 dimensi) dalam ruang fitur hibrida berdimensi 1.229 tidak dapat dipahami hanya sebagai penjumlahan struktural, tetapi sebagai proses fusi representasi dengan mekanisme kontribusi berbasis pembobotan ($\alpha = 0.6$, $\beta = 0.4$) yang ditentukan melalui sensitivity analysis. Secara kritis, TF-IDF berperan sebagai lexical anchor yang menjaga identitas eksplisit dan presisi kata kunci destinasi, sedangkan Sentence-BERT bertindak sebagai semantic encoder yang memperluas cakupan makna melalui representasi kontekstual. Kombinasi keduanya menghasilkan ruang fitur yang lebih adaptif terhadap variasi query, baik yang bersifat literal maupun abstrak, sehingga meningkatkan kemampuan sistem dalam menangani vocabulary mismatch sekaligus menjaga stabilitas referensi entitas.

Namun demikian, dominasi kontribusi TF-IDF pada konfigurasi optimal mengindikasikan bahwa karakteristik data masih cenderung keyword-driven, sehingga peran representasi semantik belum sepenuhnya mendominasi proses penentuan relevansi, melainkan berfungsi sebagai penguat konteks yang melengkapi informasi leksikal dalam proses perankingan destinasi wisata. Temuan ini menunjukkan bahwa pendekatan hibrida lebih efektif dibandingkan penggunaan representasi tunggal karena mampu memanfaatkan keunggulan masing-masing metode dalam merepresentasikan informasi destinasi wisata. Selain meningkatkan kemampuan sistem dalam memahami maksud kueri pengguna, integrasi fitur leksikal dan semantik juga berkontribusi terhadap peningkatan kualitas pemeringkatan rekomendasi yang ditunjukkan oleh nilai metrik evaluasi yang lebih baik. Dengan demikian, semantic feature boosting dapat dianggap sebagai mekanisme yang berhasil menjembatani kesenjangan antara pencocokan kata secara eksplisit dan pemahaman makna kontekstual dalam sistem rekomendasi wisata berbasis konten.

E. Perhitungan Cosine Similarity

Berdasarkan data empiris pada Tabel 7, ruang fitur hibrida TF-IDF dan Sentence-BERT menunjukkan pola pemeringkatan yang bersifat dinamis sesuai dengan

karakteristik semantik kueri. Pada kueri bertipe lokasi eksplisit (“pantai di Labuan Bajo”), sistem menghasilkan kluster destinasi yang terpusat pada kategori pantai dengan rentang nilai *cosine similarity* 0,41–0,47. Hal ini mengindikasikan bahwa komponen TF-IDF berperan sebagai *lexical anchor* yang menjaga stabilitas identifikasi dokumen melalui kecocokan kata kunci literal, sehingga objek dengan representasi token yang sesuai cenderung memperoleh skor lebih tinggi dalam ruang vektor.

TABEL 7
SAMPEL COSINE SIMILARITY RUANG FITUR HIBRIDA TF-IDF DAN SENTENCE-BERT

Kueri Uji (Query)	Top-5 Destinasi Wisata	Skor Cosine Similarity
Pantai di Labuan Bajo	Pantai Waecicu	0.47553
	Pantai Pedes	0.47199
	Pantai Klumpang	0.45966
	Beach Views	0.45901
	Mercusuar Labuan Bajo	0.41971
Tarian lokal daerah manggarai	Desa Wisata Melo	0.33826
	Desa Adat Wae Rebo	0.19216
	Hutan Kota Labuan Bajo	0.16625
	Labuan Bajo	0.15624
	Mercusuar Labuan Bajo	0.15601
Tempat wisata budaya dan desa adat	Desa Adat Wae Rebo	0.61491
	Desa Wisata Melo	0.52312
	Labuan Bajo	0.27799
	Labuan Bajo Harbour	0.22756
	Divers Paradise Komodo	0.18627


Pada kueri bertipe kultural abstrak (“tarian lokal daerah Manggarai”), sistem tetap mampu merekomendasikan destinasi relevan seperti Desa Adat Wae Rebo meskipun tidak terdapat kecocokan leksikal langsung. Fenomena ini menunjukkan bahwa Sentence-BERT berperan dalam menangkap kedekatan konseptual berbasis konteks budaya, sehingga mampu memetakan hubungan semantik lintas kata yang tidak eksplisit (vocabulary mismatch). Namun demikian, variasi nilai *cosine similarity* yang relatif lebih rendah pada beberapa kandidat menunjukkan bahwa perluasan ruang semantik juga dapat menghasilkan kedekatan parsial yang bersifat aproksimatif, sehingga tidak seluruh kandidat memiliki tingkat relevansi yang sama kuat.

Pada kueri bertipe kontekstual (“tempat wisata budaya dan desa adat”), sistem menunjukkan performa paling stabil dengan nilai similarity tertinggi pada Desa Adat Wae Rebo (0.61491). Kondisi ini mencerminkan terjadinya semantic-lexical convergence, di mana TF-IDF menguatkan pencocokan frasa eksplisit “desa adat”, sementara Sentence-BERT memperluas representasi makna pada konsep budaya secara kontekstual. Sinergi ini menunjukkan bahwa model *hybrid* bekerja secara komplementer dalam menangani kueri

multi-intent dengan keseimbangan antara presisi leksikal dan generalisasi semantik.


F. Implementasi

Implementasi sistem rekomendasi wisata Labuan Bajo menggunakan pendekatan *Semantic Feature Boosting* (TF-IDF dan Sentence-BERT) bertujuan menyajikan rekomendasi destinasi yang relevan dan kontekstual. Sistem ini menggunakan arsitektur *client-server* untuk memisahkan antarmuka (*frontend*) dan pemrosesan algoritma (*backend*), sehingga komputasi fitur serta perhitungan *similarity* dapat berjalan lebih efisien di sisi server. Pemisahan beban kerja komputasi ini terbukti berhasil menjaga efisiensi sistem dengan catatan waktu respons rata-rata sebesar 91,96 ms per kueri. Hasil implementasi membuktikan bahwa integrasi representasi leksikal dan semantik berhasil meningkatkan relevansi pencarian sesuai preferensi pengguna.




Gambar 3. Halaman Pencarian

Gambar 3 menunjukkan halaman pencarian utama yang berfungsi sebagai media interaksi antara pengguna dan sistem rekomendasi. Melalui halaman ini, pengguna dapat memasukkan kata kunci yang merepresentasikan preferensi wisata yang diinginkan. Kata kunci tersebut kemudian diproses menggunakan representasi hibrida TF-IDF dan Sentence-BERT untuk mengidentifikasi destinasi yang memiliki tingkat relevansi tertinggi. Keberadaan antarmuka yang sederhana mendukung proses pencarian yang lebih efisien, sekaligus memastikan bahwa preferensi pengguna dapat diterjemahkan secara optimal ke dalam mekanisme rekomendasi berbasis semantik. Antarmuka dirancang dengan tampilan visual destinasi wisata Labuan Bajo untuk meningkatkan daya tarik dan keterlibatan pengguna, serta dilengkapi dengan form input kata kunci yang sederhana dan mudah digunakan. Desain ini bertujuan untuk memudahkan pengguna dalam menyampaikan preferensi awal mereka terhadap destinasi wisata yang diinginkan, sekaligus mendukung efisiensi proses pencarian informasi.



Gambar 4. Halaman Rekomendasi

Halaman rekomendasi menampilkan halaman rekomendasi destinasi wisata yang dihasilkan berdasarkan kata kunci pencarian pengguna, yaitu “desa”. Berdasarkan hasil perhitungan, destinasi Desa Wisata Melo dan Desa Adat Wae Rebo memperoleh nilai *similarity* tertinggi yang menunjukkan tingkat kesesuaian semantik yang signifikan terhadap kata kunci pencarian. Kondisi tersebut mengindikasikan bahwa sistem mampu memprioritaskan rekomendasi yang lebih relevan dan mengurangi munculnya destinasi yang kurang sesuai dengan kebutuhan pencarian.



Gambar 5. Detail Wisata

Gambar 5 memperlihatkan halaman detail destinasi wisata yang diakses ketika pengguna memilih salah satu rekomendasi. Halaman ini menyajikan informasi lengkap mengenai destinasi, meliputi deskripsi wisata, kategori, aktivitas yang tersedia, serta lokasi destinasi. Penyajian informasi secara terperinci ini bertujuan untuk membantu pengguna dalam memahami karakteristik destinasi secara menyeluruh sehingga dapat mendukung pengambilan keputusan wisata yang lebih tepat dan sesuai dengan preferensi pengguna.

G. Evaluasi

Evaluasi sistem rekomendasi dilakukan terhadap korpus 51 destinasi wisata Labuan Bajo menggunakan 10 skenario kueri *natural language* yang merepresentasikan beragam kebutuhan wisata, mencakup kategori bahari, trekking, kuliner, fotografi, dan geowisata. Pendekatan ini digunakan karena belum tersedia *benchmark* publik maupun dataset relevansi standar untuk sistem rekomendasi wisata Labuan Bajo berbasis bahasa alami. Oleh karena itu, relevansi destinasi pada setiap skenario kueri ditentukan melalui proses *ground-truth* relevance judgment berdasarkan kesesuaian antara maksud kueri (*query intent*) dan karakteristik destinasi wisata. Penilaian ditentukan oleh peneliti utama, kemudian ditinjau bersama rekan untuk memastikan konsistensi dan objektivitas penilaian. Penentuan relevansi dilakukan melalui pemadanan atribut (*attribute-based matching*), yaitu mengacu pada deskripsi destinasi, kategori wisata, tipe destinasi, aktivitas utama, dan informasi lokasi yang tersedia pada dataset hasil kurasi dari sumber pariwisata resmi dan platform informasi wisata terpercaya. Untuk menjaga konsistensi evaluasi, seluruh skenario kueri dinilai menggunakan kriteria relevansi yang sama dan disusun sebelum proses pengujian model dilakukan sehingga tidak bergantung pada keluaran sistem yang dievaluasi. Selanjutnya, hasil *relevance judgment* dipetakan ke dalam skor biner (1 untuk relevan dan 0 untuk tidak relevan) sebagai dasar perhitungan metrik *Precision@5*, *Recall@5*, *MAP@5*, dan *NDCG@5*.

Kerangka evaluasi diperluas menjadi empat metrik sekaligus, yaitu: *Precision@5*, *Recall@5*, *AP@5*, dan *NDCG@5* karena satu metrik tunggal tidak mampu menggambarkan kualitas sistem rekomendasi secara menyeluruh. *Precision* mengukur ketepatan hasil teratas, *Recall* mengukur kelengkapan cakupan *ground-truth*, *AP@5* mengukur akurasi kumulatif per kueri, dan *NDCG@5* mengukur kualitas urutan peringkat yang merupakan dimensi paling krusial bagi pengalaman pengguna. Penelitian sebelumnya oleh Panjaitan et al. [3] yang menerapkan KNN pada rekomendasi wisata Labuan Bajo hanya melaporkan akurasi *confusion matrix* sebesar 83,33% terhadap 18 data terstruktur tanpa metrik berbasis peringkat, sehingga tidak dapat merepresentasikan kualitas urutan rekomendasi yang dihasilkan. Keterbatasan metodologi tersebut gagal menangkap preferensi pengguna yang sangat bergantung pada relevansi objek di posisi teratas (*top-heavy preference*). Oleh sebab itu, penelitian ini hadir untuk mengisi *research gap* tersebut melalui pendekatan evaluasi berbasis perangkingan informasi standar internasional. Hasil pengujian detail per skenario kebutuhan kueri menggunakan metode hibrida yang diusulkan dirangkum dalam Tabel 8.

Berdasarkan Tabel 8, *Proposed Hybrid Method* mencapai Mean *Precision@5* = 0,90, Mean *Recall@5* = 0,81, Mean *AP@5* (*MAP@5*) = 0,89, dan Mean *NDCG@5* = 0,93 pada 10 kueri pengujian. Seluruh kueri pengujian ini sengaja dirancang bervariasi untuk merepresentasikan kluster kebutuhan wisatawan yang berbeda baik secara literal, abstrak, mengandung *typo*, maupun *bilingual* guna

meminimalkan risiko bias spesifik dan memastikan stabilitas pemeringkatan model hibrida secara menyeluruh.

TABEL 8
SAMPEL UJI PROPOSED HYBRID METHOD (K=5 KORPUS = 51 DESTINASI))

N o	Kueri Kebutuhan Wisata / Natural Language Search	Precisi on@5	Recall @5	AP@5	NDCG @5
1	Snorkeling dan diving di perairan dengan penyu hijau dan terumbu karang	1,00	0,83	1,00	1,00
2	Tempat pendakian bukit dengan pemandangan lanskap kota dan teluk dari ketinggian	1,00	0,63	1,00	1,00
3	Tempat bersantai kuliner makanan dengan panorama laut dan matahari terbenam	1,00	0,83	1,00	1,00
4	Pulau kecil untuk snorkeling dengan air laut jernih	0,80	0,80	0,80	0,87
...	...	---	---	---	---
10	Spot fotografi dengan panorama keindahan kota	1,00	0,63	1,00	1,00

Penurunan minor menjadi 0,80 pada beberapa skenario kueri bukan disebabkan oleh kegagalan sistem, melainkan konsekuensi logis dari *high semantic density* pada korpus pariwisata Labuan Bajo yang memicu pergeseran peringkat pada posisi marginal (K=5). Kendati demikian, pencapaian nilai *Mean NDCG@5* yang menyentuh angka 0,93 mengonfirmasi bahwa kemampuan pengurutan (*ranking quality*) model hibrida ini sangat ideal dalam menempatkan item paling relevan pada posisi teratas. Hal ini membuktikan bahwa sinergi hibrida antara pembobotan statistik TF-IDF dan pengayaan fitur semantik Sentence-BERT berhasil menciptakan sistem yang tidak hanya sensitif terhadap kecocokan kata kunci literal, tetapi juga kebal dan adaptif terhadap variasi gangguan leksikal input pengguna.

TABEL 9
UJI ABLATION STUDY DAN PERBANDINGAN 4 METODE (K=5 KORPUS = 51 DESTINASI))

Metode	Mean Precision @5	Mean Recall @5	MAP @5	Mean NDCG @5	Avg Latency(ms)
Pure TF-IDF (Leksikal Murni)	0,70	0,63	0,68	0,76	5,55
Pure BM25 (Leksikal Tingkat Lanjut)	0,68	0,61	0,65	0,74	3,70
Pure Sentence-BERT (Semantik Murni)	0,74	0,68	0,73	0,81	86,22
Proposed Hybrid Method (TF-IDF + Sentence-BERT)	0,90	0,81	0,89	0,93	91,96
Hybrid vs. Sentence-BERT (baseline terbaik)	+0,16	+0,13	+0,17	+0,12	+5,74

Ablation study pada Tabel 9 membuktikan kontribusi masing-masing komponen secara terukur melalui perbandingan empat metode pada kondisi eksperimen yang identik. Temuan paling kritis menunjukkan bahwa *Pure Sentence-BERT* ($Mean\ NDCG@5 = 0,81$) berhasil mengungguli metode leksikal murni seperti *Pure TF-IDF* (0,76) dan *Pure BM25* (0,74) pada seluruh metrik evaluasi. Metode TF-IDF + Sentence-BERT terbukti mengungguli seluruh *baseline* pada semua metrik dengan mencapai $MAP@5 = 0,89$ dan $Mean\ NDCG@5 = 0,93$. Kombinasi TF-IDF + Sentence-BERT ini menghasilkan peningkatan performa yang signifikan, yakni sebesar +0,12 poin pada metrik kualitas urutan ($NDCG@5$) dan +0,17 poin pada akurasi sistem ($MAP@5$) dibandingkan dengan *Pure Sentence-BERT* sebagai *baseline* terbaik. Keberhasilan ini mengonfirmasi bahwa penggabungan representasi leksikal *Pure TF-IDF* mampu menutupi kelemahan *Pure Sentence-BERT* dalam memproses istilah non-baku atau kesalahan penulisan, sehingga menghasilkan sistem rekomendasi yang tidak hanya presisi secara makna, tetapi juga tangguh (*robust*)

terhadap gangguan teks input. Evaluasi terhadap efisiensi waktu komputasi menunjukkan bahwa metode TF-IDF + Sentence-BERT memerlukan waktu respons rata-rata (*Avg Latency*) sebesar 91,96 ms per kueri. Meskipun penambahan komponen *deep learning* ini meningkatkan latensi secara signifikan dibandingkan metode leksikal murni seperti *Pure TF-IDF* (5,55 ms) dan *Pure BM25* (3,70 ms), selisih waktu yang sangat marginal yaitu hanya sebesar +5,74 ms jika dibandingkan dengan *Pure Sentence-BERT* (86,22 ms) membuktikan bahwa proses hibridisasi fitur leksikal tidak memberikan beban komputasi tambahan yang berarti bagi sistem.

TABEL 10
ANALISIS SIGNIFIKANSI STATISTIK WILCOXON ($\alpha = 0,05$)

Perbandingan Pasangan (Pairwise)	Mean NDCG Baseline	Mean NDCG Hybrid	Wilcoxon W-Stat	P-Value	Kesimpulan Ilmiah ($\alpha=0,05$)
TF-IDF + Sentence-BERT vs Pure TF-IDF	0,7585	0,9339	28,0	0,00781	signifikan (H_0 Ditolak)
TF-IDF + Sentence-BERT vs Pure BM25	0,7401	0,9339	28,0	0,00781	signifikan (H_0 Ditolak)
TF-IDF + Sentence-BERT vs Pure Sentence-BERT	0,8147	0,9339	34,5	0,01172	signifikan (H_0 Ditolak)

Analisis signifikansi statistik menggunakan *Wilcoxon signed-rank test* pada Tabel 10 secara kokoh membuktikan bahwa superioritas metode TF-IDF + S-BERT bukan merupakan anomali variasi data atau artefak numerik semata, melainkan sebuah lompatan performa yang valid secara matematis. Pemilihan uji non-parametrik ini didasarkan pada karakteristik 10 kueri pengujian yang tidak memenuhi asumsi distribusi normalitas karena keterbatasan ukuran sampel. Seluruh perbandingan berpasangan menghasilkan *p-value* yang berada jauh di bawah ambang batas kritis $\alpha=0,05$, yaitu $p = 0,00781$ terhadap *Pure TF-IDF* serta *Pure BM25*, dan $p = 0,01172$ terhadap *Pure Sentence-BERT*. Penolakan terhadap Hipotesis Nol pada ketiga skenario tersebut memberikan landasan ilmiah yang kuat bahwa peningkatan nilai $Mean\ NDCG@5$ pada metode TF-IDF + S-BERT bersifat signifikan dalam meningkatkan kualitas pengurutan bukan sekadar kebetulan akibat variasi kueri yang diujikan.

IV. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem rekomendasi wisata Labuan Bajo berbasis *content-based filtering* yang mengintegrasikan representasi leksikal TF-IDF dan representasi semantik Sentence-BERT melalui

mekanisme *semantic feature boosting* untuk mengatasi permasalahan *vocabulary mismatch* yang selama ini membatasi sistem rekomendasi berbasis pencocokan kata kunci murni. Melalui skema pembobotan adaptif yang diperoleh dari *sensitivity analysis* ($\alpha = 0,6$ untuk TF-IDF dan $\beta = 0,4$ untuk Sentence-BERT), sistem yang diusulkan terbukti mampu menyeimbangkan ketepatan pencocokan kata kunci secara eksplisit dengan pemahaman makna kontekstual, sehingga dapat menangkap maksud pencarian wisatawan baik yang diekspresikan secara literal maupun secara abstrak dalam bahasa alami. Hasil pengujian terhadap 51 destinasi wisata pada 10 skenario kueri menunjukkan performa yang sangat baik, dengan Mean Precision@5 sebesar 0,90, Mean Recall@5 sebesar 0,81, MAP@5 sebesar 0,89, dan Mean NDCG@5 sebesar 0,93, yang mengonfirmasi bahwa metode *hybrid* mampu menghasilkan kualitas pemeringkatan rekomendasi yang konsisten dan relevan. *Ablation study* lebih lanjut memperkuat temuan ini dengan menunjukkan bahwa metode *hybrid* secara konsisten mengungguli baseline *Pure* TF-IDF, *Pure* BM25, maupun *Pure* Sentence-BERT pada seluruh metrik evaluasi, sementara pengujian *Wilcoxon signed-rank* menegaskan bahwa peningkatan tersebut signifikan secara statistik ($p < 0,05$) pada seluruh perbandingan berpasangan. Secara keseluruhan, penelitian ini memberikan kontribusi metodologis berupa kerangka integrasi fitur leksikal dan semantik yang dapat diadaptasi pada domain pariwisata lain dengan karakteristik data tekstual serupa, serta membuka peluang pengembangan lebih lanjut melalui perluasan ukuran dataset dan skenario kueri, pengembangan fitur personalisasi berbasis preferensi pengguna, serta pelaksanaan studi pengguna (*user study*) secara langsung guna memvalidasi kepuasan dan dampak praktis sistem dalam skenario dunia nyata.

DAFTAR PUSTAKA

- [1] S. Nur, S. Sahibu, and M. Razak, "Aspect-Based Sentiment Analysis of Tourist Attractions in Labuanbajo Using the Transformer Model as a Recommendation for Improving Service Quality," 2026. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [2] Nadya Syahfitri Damanik, Safwandi, and Fajriana, "Sistem Rekomendasi Dan Pemetaan Destinasi Wisata Alam Terbaik Di Berastagi Menggunakan Metode Technique For Order Preference By Similarity To Ideal Solution (TOPSIS) Berbasis Web," *Rabit : Jurnal Teknologi dan Sistem Informasi Univrab*, vol. 10, no. 2, pp. 294–304, Jul. 2025, doi: 10.36341/rabit.v10i2.6044.
- [3] C. H. P. Panjaitan, L. J. Pangaribuan, and C. I. Cahyadi, "Analisis Metode K-Nearest Neighbor Menggunakan Rapid Miner untuk Sistem Rekomendasi Tempat Wisata Labuan Bajo," *Remik*, vol. 6, no. 3, pp. 534–541, Aug. 2022, doi: 10.33395/remik.v6i3.11701.
- [4] C. H. P. Panjaitan, "Penerapan Metode K-Nearest Neighbor Untuk Sistem Rekomendasi Paket Wisata Laut Labuan Bajo," *Jurnal Elektronika dan Teknologi Informasi (JETI)*, vol. 3, no. 1, pp. 1–7, Mar. 2022, doi: 10.5201/jet.v3i1.240.
- [5] S. Oyadila, D. Abdullah, and A. Razi, "Implementasi Content-Based Filtering Dengan TF-IDF Dan Cosine Similarity Untuk Sistem Rekomendasi Destinasi Wisata Di Aceh Tengah," *Rabit : Jurnal Teknologi dan Sistem Informasi Univrab*, vol. 10, no. 2, pp. 1329–1339, Jul. 2025, doi: 10.36341/rabit.v10i2.6532.
- [6] V. Rolanda, T. S. Gunawan, and Wanayumini, "Content-Based Filtering Recommendation System Using Categories Search Engine," *International Journal of Research in Vocational Studies (IJRVOCAS)*, vol. 2, no. 4, pp. 120–125, Jan. 2023, doi: 10.53893/ijrvocas.v2i4.177.
- [7] M. Abdul, H. Fathuddin, E. Prakarsa Mandyartha, and A. L. Nurlaili, "Penerapan Sentence-Bert dan Cosine Similarity untuk Pencarian Semantik Dokumen Skripsi dalam Format PDF," *R2J*, vol. 8, no. 1, 2025, doi: 10.38035/rj.v8i1.
- [8] C. Pramarta *et al.*, "Pengembangan Sistem Rekomendasi Melalui Pendekatan Web Semantik Dan Simple Additive Weighting (Saw)," [Online]. Available: <https://doi.org/10.31598/sintechjournal.v5i2.1216>
- [9] M. Abbad, R. Alfath, and A. N. Rohman, "Content-Based Filtering Recommendation System for E-Commerce Products Using Sentence-BERT and Cosine Similarity," 2026. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [10] C. Salsabilla *et al.*, "Sistemasi: Jurnal Sistem Informasi Sistem Rekomendasi Wisata Kabupaten Pekalongan Dengan Content Based Filtering Pekalongan Regency Tourism Recommendation System with Content based Filtering," 2025. [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [11] J. Fauzi, U. Albab, and A. N. Rohman, "Recommendation System Yogyakarta Tourism Using TF-IDF and Cosine Similarity Methods with Word Normalizer," 2026. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [12] S. Puspa Andina, E. Sakti Pramukantoro, and W. Yahya, "Studi Kinerja TF-IDF dan IndoBERT dalam Rekomendasi Resep Berbasis Mobile dengan Arsitektur Microservice," 2025. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [13] A. Y. Timur, "Sistem Rekomendasi Lagu Indonesia Menggunakan Metode Content-Based Filtering Dan Cosine Similarity," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 13, no. 1, Jan. 2025, doi: 10.23960/jitet.v13i1.5949.
- [14] R. Fauzan, A. V. Vitaningsih, D. Cahyono, A. L. Maukar, and Y. A. B. Suprio, "Penerapan Algoritma Klasifikasi pada Machine Learning untuk Deteksi Phishing," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 5, no. 2, pp. 531–540, Mar. 2025, doi: 10.57152/malcom.v5i2.1968.
- [15] E. Halimatussa'diyah and S. K. Dini, "Implementasi Metode Content-Based Filtering Dengan Pendekatan Euclidean Distance Dalam Sistem Rekomendasi Produk Skincare," *Rabit : Jurnal Teknologi dan Sistem Informasi Univrab*, vol. 10, no. 2, pp. 763–783, Jul. 2025, doi: 10.36341/rabit.v10i2.6371.
- [16] R. Wardhani and Arif Nur Rohman, "Sistem Rekomendasi Film Berbasis Content-Based Filtering Menggunakan Naive Bayes," *Rabit : Jurnal Teknologi dan Sistem Informasi Univrab*, vol. 11, no. 1, pp. 1809–1817, Jan. 2026, doi: 10.36341/rabit.v11i1.7534.
- [17] F. Devi Maharani and S. Rohman Cholil, "A Multi-Criteria Decision Approach to Livability Assessment Using Hybrid FUCOM-VIKOR," 2026. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>