

PENERAPAN METODE CONTENT-BASED FILTERING DALAM SISTEM REKOMENDASI BAN MOTOR BERBASIS WEBSITE

Timotius Fergiwana Noel Sabekti, Nibras Faiq Muhammad, Vihi Atina

Teknik Informatika, Universitas Duta Bangsa Surakarta

Jl. Bhayangkara No.55 Kota Surakarta, Jawa Tengah, Indonesia

Irgie.noel@gmail.com

ABSTRAK

Keselamatan dan performa berkendara sangat bergantung pada kompatibilitas ban yang terpasang. Akan tetapi, tingginya variasi produk di pasaran kerap membuat konsumen mengalami kebingungan hingga salah membeli, sebagaimana fenomena yang kerap terjadi di Bengkel Simle. Studi ini mengarahkan fokusnya pada pengembangan sistem rekomendasi daring (web) untuk ban motor yang mengadopsi pendekatan Content-Based Filtering (CBF) dipadukan dengan Cosine Similarity. Karakteristik setiap produk dipetakan ke dalam enam parameter vektor, meliputi cengkeraman, umur pakai, kenyamanan, ketepatan medan, efisiensi biaya, dan penilaian pengguna. Mekanisme penyaringan awal diterapkan berdasarkan dimensi ban dan anggaran, diikuti dengan perhitungan kemiripan vektor serta penentuan peringkat. Evaluasi dilaksanakan memakai dua kondisi uji dengan preferensi kontras. Temuan menunjukkan bahwa rancangan sistem ini bersifat responsif terhadap perubahan keinginan pengguna, dengan capaian skor kemiripan puncak mencapai 92,4%. Dengan demikian, pendekatan ini terbukti mampu memfasilitasi pengguna dalam menemukan pilihan ban yang paling relevan terhadap spesifikasi dan kebutuhan mereka.

Kata kunci : sistem rekomendasi, content-based filtering, cosine similarity, ban motor, vektor fitur

1. PENDAHULUAN

Pasar sepeda motor di Tanah Air terus menunjukkan tren peningkatan yang menjanjikan. Data Asosiasi Industri Sepeda Motor Indonesia (AISI) mencatat bahwa rata-rata distribusi unit secara konsisten menembus angka lima juta per tahun, menempatkan Indonesia di posisi teratas di kawasan Asia Tenggara. Lonjakan ini berbanding lurus dengan kebutuhan akan komponen pendukung, khususnya ban. Sebagai satu-satunya titik kontak kendaraan dengan permukaan jalan, kualitas ban secara langsung menentukan tingkat keamanan serta kenyamanan pengendara. Spesifikasi yang tepat berpotensi memaksimalkan daya cengkeram sekaligus memperpanjang usia pakai komponen tersebut [1].

Meski demikian, realita di lapangan menunjukkan adanya hambatan tersendiri. Konsumen, terutama yang belum memahami aspek teknis, kerap dibingungkan oleh beragam kriteria pemilihan seperti diameter pelek, tingkat kekerasan compound, hingga desain alur yang harus disesuaikan dengan topografi jalan. Belum lagi, hadirnya puluhan merek dengan ratusan varian—mulai dari IRC, FDR, Michelin, hingga Pirelli—justru memicu fenomena information overload, di mana konsumen kesulitan menetapkan pilihan secara objektif [2].

Kesenjangan antara ketersediaan produk dan kemampuan konsumen dalam memilih teridentifikasi secara langsung melalui pengamatan di Bengkel Simle. Bengkel tersebut kerap menangani keluhan pelanggan yang membeli ban melalui platform daring tanpa memverifikasi kecocokannya. Ketidaksesuaian yang muncul sangat beragam, seperti kesalahan dimensi (contohnya membeli ban 90/90-14 untuk pelek 17 inci), ketidakmampuan menyesuaikan tipe

ban dengan karakteristik motor (seperti penggunaan ban sport untuk kendaraan harian), hingga pembengkakan biaya di luar rencana. Pola pembelian impulsif yang digerakkan oleh promosi penjual ini mengabaikan pertimbangan teknis. Konsekuensinya tidak sekadar merugikan aspek finansial, melainkan juga mengancam keselamatan karena ban yang terpasang kemungkinan melanggar standar rekomendasi pabrikan.

Untuk menjembatani kesenjangan informasi tersebut, pendekatan sistem rekomendasi dihadirkan sebagai solusi filtrasi yang mampu menyajikan opsi paling relevan. Secara umum, terdapat tiga paradigma utama dalam mekanisme ini: Collaborative Filtering (CF), Content-Based Filtering (CBF), serta model hybrid [3][4].

Riset ini mengadaptasi pendekatan CBF dengan pertimbangan bahwa metode ini menilai kesesuaian berdasarkan karakteristik intrinsik item terhadap profil pengguna. Keunggulannya, CBF tidak bergantung pada database historis pengguna lain, sehingga kebal terhadap permasalahan cold-start pada item baru. Pengukuran kedekatan yang dipilih adalah Cosine Similarity karena sifatnya yang scale-invariant, memungkinkan perbandingan adil lintas dimensi fitur yang memiliki rentang nilai berbeda [7][8].

Sebagai lapisan keamanan tambahan, diterapkan pula mekanisme hard filter yang berfungsi memvalidasi kompatibilitas fisik (ukuran) dan batasan finansial sebelum proses perhitungan kemiripan berjalan [6].

Mengacu pada konteks permasalahan di atas, kajian ini secara spesifik bertujuan untuk merancang dan membangun sebuah sistem rekomendasi ban motor berbasis web. Sistem tersebut akan

mengintegrasikan metode CBF dan Cosine Similarity, di mana setiap produk ban direpresentasikan dalam bentuk vektor numerik berdimensi enam. Melalui pemetaan ini, diharapkan sistem mampu menjadi alat bantu keputusan yang efektif bagi konsumen, memandu mereka menemukan spesifikasi ban yang paling akurat selaras dengan tipe motor, medan yang sering dilewati, gaya berkendara, serta kemampuan daya beli mereka.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Beberapa penelitian terdahulu telah mengimplementasikan sistem rekomendasi dengan pendekatan CBF dan *Cosine Similarity* pada berbagai domain. Zhou et al. [16] melakukan survei komprehensif mengenai sistem rekomendasi berbasis *deep learning* dan menemukan bahwa pendekatan CBF tetap menjadi salah satu metode yang paling relevan, terutama untuk domain di mana data perilaku pengguna terbatas. Di domain otomotif, penelitian yang dilakukan oleh Uta et al. [17] mengimplementasikan sistem rekomendasi berbasis pengetahuan (*knowledge-based*) yang menunjukkan bahwa representasi fitur berbasis pengetahuan domain mampu meningkatkan kualitas rekomendasi secara signifikan dibandingkan pendekatan generik.

Pada domain yang lebih spesifik, Amer et al. [18] mengkaji berbagai teknik *similarity measure* dalam sistem rekomendasi dan menyimpulkan bahwa pemilihan teknik *similarity* yang sesuai sangat bergantung pada karakteristik data dan representasi fitur yang digunakan.

Penelitian mereka menunjukkan bahwa pengembangan *similarity measure* yang lebih efektif secara konsisten mampu meningkatkan akurasi rekomendasi. Sementara itu, penelitian di bidang *trustworthy recommender systems* oleh Ge et al. [19] mendemonstrasikan bahwa integrasi aspek kepercayaan (*trust*) dengan fitur *domain-specific* menghasilkan rekomendasi yang lebih andal dan dapat dipercaya oleh pengguna.

Untuk domain rekomendasi produk otomotif secara khusus, penelitian oleh Cai et al. [20] menunjukkan bahwa pendekatan berbasis *cosine similarity* dengan data perilaku pengguna mampu memberikan rekomendasi desain otomotif yang relevan berdasarkan preferensi kelompok pengguna.

2.2. Sistem Rekomendasi

Sistem rekomendasi merupakan sebuah *subclass* dari sistem filtrasi informasi yang bertugas untuk memprediksi rating atau preferensi pengguna terhadap suatu item [9].

Secara umum, sistem rekomendasi dapat dikategorikan menjadi tiga tipe utama berdasarkan pendekatan yang digunakan, yaitu *Collaborative Filtering* (CF), *Content-Based Filtering* (CBF), dan sistem rekomendasi *hybrid*. Pendekatan CF memanfaatkan data perilaku pengguna sebelumnya,

seperti rating dan riwayat pembelian, untuk mengidentifikasi pola kesamaan antar pengguna atau antar item. Teknik CF terbagi menjadi dua metode, yaitu *user-based* yang mencari pengguna dengan preferensi serupa, dan *item-based* yang mencari item dengan pola respons serupa dari pengguna [10].

Pendekatan CBF, di sisi lain, merekomendasikan item berdasarkan kesesuaian antara deskripsi konten item dengan profil preferensi pengguna. Metode ini tidak memerlukan data dari pengguna lain, sehingga dapat bekerja secara efektif bahkan untuk item baru yang belum memiliki rating dari pengguna manapun (*cold-start problem* untuk item). Dalam implementasinya, CBF merepresentasikan setiap item sebagai sekumpulan fitur atau atribut yang kemudian dibandingkan dengan profil pengguna menggunakan fungsi kesamaan tertentu [11][12]. Keunggulan utama CBF adalah kemampuannya untuk memberikan rekomendasi yang transparan dan dapat dijelaskan, karena setiap rekomendasi dapat ditelusuri kembali ke fitur-fitur spesifik yang cocok dengan preferensi pengguna.

2.3. Cosine Similarity

Content-Based Filtering (CBF) merupakan pendekatan rekomendasi yang merekomendasikan item berdasarkan kemiripan konten antara item dengan preferensi pengguna. Dalam implementasi klasik CBF, representasi konten seringkali menggunakan teknik seperti TF-IDF (*Term Frequency-Inverse Document Frequency*) untuk domain berbasis teks. Namun, untuk domain yang tidak berbasis teks seperti produk fisik, representasi item dapat dilakukan menggunakan vektor fitur numerik yang menggambarkan karakteristik-karakteristik penting dari item tersebut [13].

Cosine Similarity adalah salah satu metode pengukuran kemiripan (*similarity measure*) yang paling banyak digunakan dalam sistem rekomendasi berbasis konten. Metode ini menghitung kosinus dari sudut antara dua vektor dalam ruang fitur multidimensional. Nilai *Cosine Similarity* berkisar antara -1 hingga 1, dimana nilai 1 menunjukkan bahwa kedua vektor memiliki arah yang identik, nilai 0 menunjukkan bahwa vektor bersifat ortogonal (tidak berkaitan), dan nilai -1 menunjukkan arah yang berlawanan. Dalam konteks sistem rekomendasi, semakin tinggi nilai *cosine similarity*, semakin besar kesesuaian antara preferensi pengguna dan karakteristik item [14]. Formula *Cosine Similarity* ditunjukkan pada Persamaan (1).

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

Pada Persamaan (1), A merepresentasikan vektor preferensi pengguna dan B merepresentasikan vektor fitur item (ban motor). Operasi $A \cdot B$ merupakan dot product (perkalian titik) yang menghitung jumlah perkalian elemen-elemen yang bersesuaian dari kedua vektor. Sedangkan $\|A\|$ dan $\|B\|$ masing-masing merupakan norma *Euclidean* dari vektor A dan B.

Norma Euclidean dari suatu vektor dihitung menggunakan Persamaan (2).

$$||A|| = \sqrt{\sum_{i=1}^n A^2} \text{ persamaan (2)}$$

Hasil perhitungan Cosine Similarity menghasilkan nilai dalam rentang 0.0 hingga 1.0, yang kemudian dikonversi menjadi persentase untuk ditampilkan pada antarmuka pengguna. Nilai yang lebih tinggi menunjukkan kesesuaian yang lebih besar antara preferensi pengguna dan karakteristik ban motor yang direkomendasikan.

2.4. Penerapan Hard Filter dan Fitur Domain-Specific

Dalam praktik rekomendasi, tidak semua kesesuaian dapat diukur melalui kemiripan vektor. Terdapat batasan fisik atau logis yang bersifat mutlak, yang dalam literatur dikenal sebagai pendekatan *Constraint-Based Recommendation* [6].

Pada domain ban motor, batasan ini berupa kompatibilitas ukuran ban dengan motor serta batasan *budget*. Mekanisme hard filter diperlukan untuk memastikan rekomendasi yang dihasilkan tidak hanya mirip secara teori, tetapi juga dapat dipasang secara fisik [6].

Selain itu, penggunaan fitur *domain-specific* dalam merepresentasikan vektor item telah terbukti meningkatkan relevansi hasil dibandingkan fitur generik [3].

Pengetahuan khusus domain, seperti hubungan antara tipe *compound* dengan daya tahan, atau pola alur dengan kondisi jalan, perlu dikodekan secara eksplisit ke dalam representasi vektor agar sistem mampu melakukan pencocokan yang bermakna [3] [12].

2.5. Rekomendasi pada Domain Otomotif

Penerapan sistem rekomendasi di industri otomotif telah berkembang, mencakup rekomendasi kendaraan, suku cadang, hingga asuransi [10].

Namun, untuk sub-domain spesifik seperti ban motor, literatur yang memfokuskan pada metode CBF masih sangat terbatas. Sebagian besar sistem yang ada di domain ini mengandalkan pendekatan MCDM tradisional seperti WSM untuk perbandingan [15].

Hal ini membuka celah penelitian untuk mengimplementasikan pendekatan CBF yang mengukur kemiripan fitur secara vektorial pada domain ban motor, yang notabene memiliki atribut teknis yang sangat kaya dan terstruktur [10].

3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan *design science research* yang berfokus pada pembangunan dan evaluasi artefak teknologi informasi berupa sistem rekomendasi. Metode yang digunakan mencakup kajian literatur untuk membangun fondasi teori, perancangan vektor fitur berbasis pengetahuan domain, serta implementasi algoritma *Content-Based Filtering* (CBF). Bagian ini menjelaskan jenis dan

sumber data, metode pengumpulan data, serta tahapan penelitian secara terperinci.

3.1. Jenis dan Sumber Data

Data yang digunakan dalam penelitian ini terdiri dari dua jenis, yaitu data sekunder dan data primer hasil konversi (*encoding*). Data sekunder meliputi spesifikasi teknis produk ban motor dan spesifikasi motor yang bersumber dari situs resmi produsen (seperti *IRC*, *FDR*, *Michelin*, *Corsa*, *Bridgestone*, dan lain-lain), katalog produk, serta portal otomotif. Data primer berupa nilai numerik pada vektor fitur yang diperoleh melalui proses *encoding* pengetahuan domain (*domain knowledge encoding*) oleh peneliti berdasarkan preferensi dari mekanik bengkel.

Metode pengumpulan data dalam penelitian ini menggunakan langkah-langkah sebagai berikut:

a. Observasi

Observasi dilakukan dengan mengamati langsung proses pelayanan bengkel, terutama bagian penerimaan keluhan pelanggan. Observasi membantu memahami pola pengambilan keputusan secara nyata, mengidentifikasi atribut yang sering dijadikan pertimbangan dan memastikan atribut dalam sistem sesuai dengan praktik lapangan.

b. Wawancara

Wawancara dilakukan secara informal dengan mekanik untuk mengetahui kriteria teknis yang menjadi pertimbangan dalam menentukan ban yang sesuai.

c. Studi dokumentasi

Dilakukan untuk mengumpulkan data spesifikasi ban motor secara komprehensif, meliputi ukuran ban, tipe ban (*tubeless* atau *tube type*), kategori ban (*sport*, *touring*, *scooter*, *cub*, *dual sport*), tipe *compound* (*soft*, *medium*, *hard*), pola alur (*tread pattern*), harga pasar, dan rating pengguna. Data spesifikasi motor juga dikumpulkan melalui metode ini.

3.2. Tahapan Penelitian

Penelitian ini menggunakan pendekatan *Research and Development* (R&D) yang berfokus pada pengembangan dan evaluasi sebuah sistem rekomendasi ban motor. Pendekatan ini dipilih karena sesuai dengan tujuan penelitian yang mengutamakan pembangunan prototipe sistem yang fungsional serta analisis keefektifan metode yang digunakan. Secara keseluruhan, tahapan penelitian dalam studi ini terdiri dari lima tahap utama yang dilaksanakan secara berurutan, yaitu pengumpulan data, perancangan sistem, implementasi sistem, pengujian sistem, dan evaluasi.

Tahapan Penelitian dilakukan dengan langkah-langkah sebagai berikut :

a. Pengumpulan Data

Tahap pertama penelitian ini adalah pengumpulan data yang dilakukan melalui observasi dan dokumentasi terhadap spesifikasi produk ban

motor dan sepeda motor di pasaran Indonesia. Proses pengumpulan data ban motor dilakukan dengan mengidentifikasi 18 merek ban motor yang aktif dijual di Indonesia, kemudian mengambil data 50 varian ban yang mencakup variasi merek, ukuran, *compound*, dan pola alur. Setiap ban motor didokumentasikan dengan atribut-atribut berikut: merek, model, ukuran (lebar dan diameter), tipe *compound* (*soft*, *medium*, *hard*), pola alur (*street*, *sport*, *touring*, *off-road*), harga pasar dalam Rupiah, rating pengguna (skala 1-5), serta kesesuaian pola alur terhadap empat kondisi jalan, yaitu *smooth asphalt*, *rough asphalt*, *gravel*, dan *mixed*.

b. Perancangan Sistem

Tahap kedua adalah perancangan sistem yang mencakup desain representasi vektor fitur, formula perhitungan *Cosine Similarity*, serta arsitektur sistem secara keseluruhan. Pada tahap ini, setiap ban motor direpresentasikan sebagai vektor fitur numerik enam dimensi yang dinormalisasi ke dalam rentang nilai 0.0 hingga 1.0. Pemilihan enam dimensi ini didasarkan pada analisis faktor-faktor kunci yang mempengaruhi preferensi pengguna dalam memilih ban motor.

c. Implementasi Sistem

Tahap ketiga adalah implementasi sistem rekomendasi ban motor ke dalam bentuk aplikasi web menggunakan beberapa teknologi modern. Kerangka kerja utama yang digunakan adalah *Next.js 16* dengan *App Router*, yang menyediakan fitur *Server-Side Rendering* (SSR) dan optimisasi performa secara bawaan. Pemilihan *Next.js 16* didasarkan pada kemampuannya dalam membangun aplikasi web yang cepat, *scalable*, dan memiliki pengalaman pengguna yang optimal melalui fitur seperti *automatic code splitting*, *image optimization*, dan *routing* berbasis file system.

Basis data yang digunakan adalah *Firestore*, sebuah NoSQL database yang menyediakan sinkronisasi data secara *real-time*, skalabilitas yang tinggi, dan kemudahan integrasi dengan aplikasi web modern. Data ban motor disimpan dalam koleksi *tires* dengan *field* merek, model, ukuran, *compound*, *treadPattern*, harga, rating, dan nilai kesesuaian terhadap setiap kondisi jalan. Data sepeda motor disimpan dalam koleksi *motorcycles* dengan *field* merek, tipe, kapasitas mesin, dan ukuran ban standar depan serta belakang. *TypeScript* digunakan sebagai bahasa pemrograman utama untuk memastikan keamanan tipe data (*type safety*) dan meningkatkan kualitas kode, sementara *Tailwind CSS v4* digunakan sebagai *utility-first CSS framework* untuk membangun antarmuka pengguna yang responsif dan konsisten secara visual.

d. Pengujian Sistem

Tahap keempat merupakan pengujian sistem menggunakan skenario pencarian ban yang

spesifik. Pengujian dilakukan dengan 2 skenario, yaitu dengan motor, keadaan, dan range harga yang sama tapi dengan preferensi yang berbeda. Hasil rekomendasi dari sistem kemudian dianalisis untuk melihat kesesuaian ban yang direkomendasikan dengan preferensi pengguna.

e. Evaluasi

Tahap kelima merupakan evaluasi terhadap sistem rekomendasi yang telah dibangun. Evaluasi dilakukan untuk mengukur sejauh mana sistem mampu memberikan rekomendasi yang relevan sesuai dengan preferensi pengguna serta memverifikasi kebenaran proses perhitungan yang dilakukan oleh sistem. Evaluasi dilakukan dengan membandingkan hasil rekomendasi dari dua skenario pengujian yang memiliki preferensi berbeda namun menggunakan motor dan kondisi jalan yang sama. Hal ini bertujuan untuk memastikan bahwa perubahan nilai preferensi pengguna pada slider menghasilkan perubahan yang signifikan pada perbandingan ban yang direkomendasikan, sehingga sistem terbukti responsif terhadap perbedaan preferensi pengguna.

4. HASIL DAN PEMBAHASAN

4.1. Hasil Pengumpulan Data

Tahap pengumpulan data telah berhasil menghimpun dataset yang mencakup 50 ban motor dari 18 merek berbeda dan 56 unit motor dari 5 merek utama. Proses pengumpulan data dilakukan melalui observasi terhadap website resmi produsen, *platform e-commerce*, dan dokumentasi spesifikasi produk. Tabel 1 menyajikan ringkasan statistik dataset yang berhasil dikumpulkan dalam penelitian ini.

Tabel 1. Dataset

Parameter	Nilai
Jumlah ban motor	50
Jumlah merek ban	18
Jumlah sepeda motor	56
Jumlah merek sepeda motor	5 (Honda, Yamaha, Suzuki, Kawasaki, TVS)
Dimensi vektor fitur	6
Tipe kondisi jalan	4 (<i>smooth asphalt</i> , <i>rough asphalt</i> , <i>gravel</i> , <i>mixed</i>)
Tipe sepeda motor	Skutik, Bebek, Sport

Dari Tabel 1 dapat dilihat bahwa dataset mencakup variasi yang cukup komprehensif untuk merepresentasikan variasi produk ban motor di pasar Indonesia. Kehadiran 18 merek ban yang berbeda, mulai dari merek lokal seperti IRC dan FDR hingga merek premium seperti *Michelin* dan *Pirelli*, memberikan keragaman yang memadai untuk menguji kemampuan sistem rekomendasi dalam menangani preferensi pengguna yang beragam. Distribusi merek ban dalam dataset disajikan pada Tabel 2.

Tabel 2. Distribusi merek ban motor dalam dataset

Merek	Jumlah Varian	Kategori
IRC	6	Lokal - Ekonomis
FDR	5	Lokal - Ekonomis
Corsa	4	Lokal - Menengah
Michelin	4	Premium
Bridgestone	3	Premium
Pirelli	3	Premium
Mizzle	3	Lokal - Ekonomis
Dunlop	3	Menengah
Maxxis	3	Menengah
Federal	2	Lokal - Ekonomis
GT Radial	2	Menengah
Metzeler	2	Premium
Lainnya (6 merek)	10	Bervariasi


Data sepeda motor yang berhasil dikumpulkan terdiri dari 56 unit dengan distribusi berdasarkan merek sebagai berikut: Honda (22 unit), Yamaha (18 unit), Suzuki (8 unit), Kawasaki (5 unit), dan TVS (3 unit). Variasi tipe motor mencakup skutik (28 unit), bebek (16 unit), dan sport (12 unit), dimana setiap tipe motor memiliki spesifikasi ukuran ban standar yang berbeda-beda. Data ukuran ban standar ini menjadi kunci dalam mekanisme hard filter untuk memastikan kompatibilitas antara ban yang direkomendasikan dengan motor yang digunakan pengguna. Seluruh data yang telah dikumpulkan disimpan dalam *Firestore* dengan struktur koleksi yang terorganisir, memungkinkan proses *query* dan *filter* yang efisien pada saat sistem berjalan.

4.2. Hasil Perancangan Sistem

Hasil perancangan sistem menghasilkan desain arsitektur yang terdiri dari tiga komponen utama, yaitu komponen data (*Firestore*), komponen logika bisnis (modul *TypeScript*), komponen antarmuka pengguna (komponen *React*), dan dengan flowchart seperti pada gambar 1.

Dari Gambar 1 dapat dilihat bahwa alur sistem dimulai dari input pengguna berupa pemilihan motor dan kondisi jalan, pengaturan preferensi melalui enam slider, dan penetapan budget range secara opsional. Selanjutnya sistem melakukan hard filter berdasarkan ukuran ban dan budget. Ban yang lolos filter kemudian dikonversi menjadi vektor fitur 6D, dihitung *Cosine Similarity* terhadap vektor preferensi pengguna, diurutkan berdasarkan nilai similarity tertinggi, dan ditampilkan sebagai rekomendasi Top 5.

Komponen logika bisnis menjalankan seluruh proses perhitungan rekomendasi, termasuk konversi vektor fitur, penerapan *hard filter*, perhitungan *Cosine Similarity*, dan pengurutan hasil. Komponen antarmuka pengguna menyediakan form *input* interaktif berupa pemilihan motor, kondisi jalan, slider preferensi, dan rentang anggaran, serta menampilkan hasil rekomendasi dalam format tabel yang dilengkapi dengan detail vektor fitur. Detail vektor fitur bisa dilihat pada tabel 3.



Gambar 1. Flowchart sistem

Tabel 3. Komponen Vektor Fitur Ban

Dimensi	Rentang Nilai	Metode Penghitungan
Grip	0.0 - 1.0	Berdasarkan compound & pola alur
durability	0.0 - 1.0	Ketahanan berdasarkan tipe compound
Comfort	0.0 - 1.0	Kontribusi pola alur & compound
road_match	0.0 - 1.0	Kesesuaian pola alur & kondisi jalan
price_inverse	0.0 - 1.0	Inversi harga normalisasi
Rating	0.0 - 1.0	Rating pengguna dinormalisasi (skala maks. 5)

Dari Tabel 3 dapat dilihat bahwa setiap dimensi vektor merepresentasikan aspek penting dari karakteristik ban motor. Dimensi grip menggambarkan kemampuan cengkraman ban pada permukaan jalan, yang dihitung berdasarkan kombinasi skor compound dan pola alur ban. Dimensi *durability* mencerminkan ketahanan atau daya tahan

ban, dimana *compound* keras memiliki nilai lebih tinggi (1.0) dibandingkan *compound* lunak (0.2).

Dimensi *comfort* mengukur tingkat kenyamanan berkendara berdasarkan kontribusi dari pola alur dan *compound* ban. Dimensi *road_match* menghitung kesesuaian antara pola alur ban dengan kondisi jalan yang dipilih pengguna. Dimensi *price_inverse* merupakan inversi dari harga ban yang dinormalisasi, sehingga ban dengan harga lebih terjangkau mendapatkan nilai lebih tinggi. Terakhir, dimensi *rating* menampung *rating* pengguna yang dinormalisasi terhadap skala maksimum 5.

Representasi vektor fitur enam dimensi yang dirancang pada tahap perancangan telah berhasil memetakan karakteristik kunci dari setiap ban motor ke dalam format numerik yang dapat diproses oleh algoritma *Cosine Similarity*. Normalisasi nilai ke rentang 0.0 hingga 1.0 pada setiap dimensi memastikan bahwa tidak ada dimensi yang mendominasi perhitungan hanya karena memiliki rentang nilai yang lebih besar. Mekanisme *hard filter* yang dirancang juga berfungsi sebagai tahap pra-pemrosesan yang efektif, mampu mengurangi jumlah ban yang perlu diproses dari 50 menjadi rata-rata 8-15 ban yang kompatibel, tergantung pada ukuran pelg motor dan batas anggaran yang ditetapkan pengguna. Hal ini secara signifikan mengurangi beban komputasi dan meningkatkan efisiensi sistem secara keseluruhan.

4.3. Hasil Implementasi Sistem

Implementasi sistem rekomendasi ban motor telah berhasil diwujudkan dalam bentuk aplikasi web yang berjalan pada lingkungan *Next.js 16* dengan *Firebase Firestore* sebagai *backend*. Tabel 4 menyajikan ringkasan teknologi yang digunakan dalam implementasi sistem.


Tabel 4. Teknologi Implementasi Sistem

Komponen	Teknologi	Fungsi
Framework	Next.js 16 (App Router)	Kerangka kerja web application dengan SSR
Database	Firebase Firestore	NoSQL database untuk penyimpanan data ban dan motor
Bahasa	TypeScript	Keamanan tipe data dan kualitas kode
UI Framework	Tailwind CSS v4	Antarmuka pengguna responsif
Hosting	Vercel	Deploy dan hosting aplikasi web


Antarmuka pengguna yang diimplementasikan menyediakan pengalaman interaksi yang intuitif bagi pengguna seperti *landing page* pada gambar 2.

Setelah pengguna menekan tombol untuk memulai rekomendasi, sistem menampilkan formulir input yang terdiri dari dua panel utama. Panel kiri berisi input untuk memilih motor, kondisi jalan, dan budget, sedangkan panel kanan berisi slider untuk menyesuaikan preferensi pada enam parameter. Detail

tampilannya dapat dilihat pada gambar 3 menunjukkan formulir yang telah terisi dengan skenario pengujian.

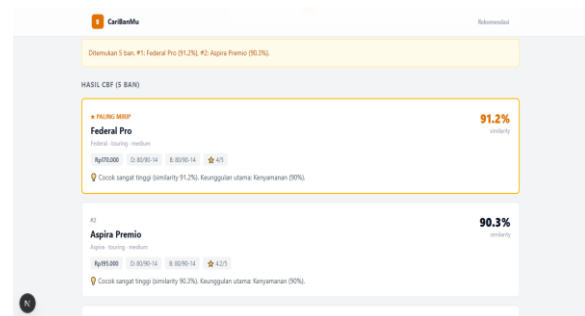


Gambar 2. Tampilan landing page sistem CariBanMu




Gambar 3. Tampilan Form Input

Pada gambar 3, pengguna dapat memasukkan nama motor, kondisi jalan, range harga(opsional), dan mengatur preferensi ban yang diinginkan dengan slider yang ada di sebelah kanan. Dan hasil dari rekomendasi akan muncul setelah pengguna menekan tombol dapatkan rekomendasi yang dapat dilihat pada gambar 4 dan gambar 5.




Gambar 4. Hasil Rekomendasi



Gambar 5. Hasil Rekomendasi peringkat 3-5

Pada gambar 4 dan 5, pengguna dapat melihat peringkat dari 5 ban hasil rekomendasi dengan nilai *similarity* nya. Hasil dari rekomendasi telah

diurutkan berdasarkan kemiripan sebelum ditampilkan di sisi pengguna. Pengguna juga dapat melihat detail ban setelah menekan nama ban motor yang muncul. Detail nya bisa dilihat pada gambar 6.



Gambar 6. Detail ban

Halaman detail ban memberikan informasi seperti vektor fitur, ukuran ban, kecocokan dan kelebihan dari ban tersebut.

4.4. Hasil Pengujian Sistem

Pengujian sistem dilakukan dengan dua skenario uji yang memiliki preferensi pengguna berbeda-beda. Tujuannya adalah untuk mengevaluasi kemampuan sistem dalam memberikan rekomendasi yang bervariasi dan sesuai dengan preferensi masing-masing pengguna. Setiap skenario menggunakan motor Honda Beat Pop 2024 dengan kondisi jalan aspal halus, namun dengan perbedaan pada rentang budget dan nilai preferensi slider.

4.5. Pengguna Budget Terbatas

Pengguna yang mengutamakan kenyamanan dan rating. Pada skenario ini mensimulasikan pengguna yang mengutamakan kenyamanan berkendara dan rating pengguna sebagai pertimbangan utama. Pengguna menggunakan motor Honda Beat Pop 2024 pada kondisi jalan aspal halus dengan budget Rp150.000 hingga Rp175.000. Kenyamanan dan rating mendapat bobot tertinggi (1.0), sedangkan parameter lainnya diberikan bobot sedang (0.5). Skenario ini menunjukkan bagaimana preferensi terhadap kenyamanan dan rating mempengaruhi perancangan ban

Tabel 5. Input skenario 1

Parameter	Nilai
Motor	Honda Beat Pop 2024 (110cc)
Ukuran Ban Depan	80/90-14
Ukuran Ban Belakang	90/90-14
Kondisi Jalan	Aspal Halus
Budget Minimum	Rp100.000
Budget Maksimum	Rp175.000
Grip / Cengkeraman	0.5
Daya Tahan	1.0
Kenyamanan	0.5
Kesesuaian Jalan	0.5
Harga Terjangkau	1.0
Rating Pengguna	0.5

Berdasarkan Tabel 5, vektor preferensi pengguna yang terbentuk adalah $U = [0.5, 1.0, 0.5, 0.5, 1.0, 0.5]$ dengan norma vektor $\|U\| = 1.732$.

Tabel 6. Hasil hard filter skenario 1

Nama Ban	Tipe	Harga	Status Filter
Federal Pro	Touring / Medium	Rp170.000	Lolos
Aspira Premio	Touring / Medium	Rp195.000	Dihapus (>budget)
Swallow SB118X	Scooter / Medium	Rp155.000	Lolos
IRC RX-02	Touring / Medium	Rp185.000	Dihapus (>budget)
IRC Duro SD	Scooter / Medium	Rp150.000	Lolos

Dari tabel 6 dapat dilihat bahwa ada 3 ban lolos filter (Federal Pro, Swallow SB118X, IRC Duro SD), 2 ban dieliminasi. Ban yang lolos filter selanjutnya menjadi kandidat untuk proses perhitungan *Cosine Similarity*. Dengan masing masing memiliki vektor fitur seperti pada tabel 7.

Tabel 7. Vektor fitur dari ban

Nama Ban	Grip	Daya Tahan	Kenyamanan	Kesesuaian Jalan	Harga Inv.	Rating
Federal Pro	0.55	0.60	0.90	0.88	0.78	0.80
Swallow SB118X	0.45	0.60	0.80	0.80	0.81	0.80
IRC Duro SD	0.45	0.60	0.80	0.80	0.82	0.84

Tabel 7 menunjukkan vektor fitur enam dimensi untuk setiap ban kandidat yang lolos hard filter. Nilai grip dihitung dari rata-rata *compound grip* dan *pattern grip*, daya tahan berdasarkan *compound durability*, kenyamanan dari rata-rata *pattern comfort* dan *compound comfort*, kesesuaian jalan berdasarkan matriks skor kondisi jalan, harga menggunakan *inverse normalization*, dan rating dinormalisasi terhadap skala 5.0. Tahap selanjutnya adalah perhitungan *cosine similarity* antara vektor preferensi pengguna dengan vektor fitur masing-masing ban kandidat. Perhitungan dilakukan dengan membagi hasil dot product antara vektor U dan vektor T dengan hasil perkalian norma kedua vektor. Hasil dari *Cosine Similarity* dapat dilihat pada tabel 8.

Tabel 8. Hasil akhir rekomendasi

Nama Ban	Brand	Tipe	Harga	Rating	Similarity
Swallow SB118X	Swallow	Scooter	Rp155.000	4.0	92.4%
IRC Duro SD	IRC	Scooter	Rp150.000	4.2	92.2%
Federal Pro	Federal	Touring	Rp170.000	4.0	91.0%

Tabel 8 menyajikan perbandingan akhir ban yang direkomendasikan berdasarkan skor *Cosine Similarity*. Pada pengguna berbudget terbatas, Ban Swallow SB118X menempati peringkat pertama dengan skor similarity 92.4%, diikuti oleh IRC Duro SD pada peringkat kedua dengan skor 92.2%.

4.6. Pengguna Preferensi seimbang

Pengguna dengan Preferensi Seimbang. Pada skenario ini merepresentasikan pengguna yang menginginkan keseimbangan antara performa dan harga yang dapat dilihat pada tabel .

Tabel 9. Input Skenario 2

Parameter	Nilai
Motor	Honda Beat Pop 2024 (110cc)
Ukuran Ban Depan	80/90-14
Ukuran Ban Belakang	90/90-14
Kondisi Jalan	Aspal Halus
Budget Minimum	Rp150.000
Budget Maksimum	Rp400.000
Grip / Cengkeraman	1.0
Daya Tahan	1.0
Kenyamanan	0.8
Kesesuaian Jalan	0.8
Harga Terjangkau	1.0
Rating Pengguna	0.25

Pada tabel 9, pengguna memilih motor Honda Beat Pop 2024 dengan kondisi jalan aspal halus dan budget Rp150.000 hingga Rp400.000. *Grip* (1.0), daya tahan (1.0), dan harga (1.0) menjadi prioritas utama, diikuti kenyamanan (0.8) dan kesesuaian jalan (0.8). Rating pengguna diberikan bobot rendah (0.25) karena pengguna lebih mengutamakan aspek teknis ban sehingga didapatkan vektor pengguna adalah $U = [1.0, 1.0, 0.8, 0.8, 1.0, 0.25]$. Dengan preferensi tersebut menghasilkan hard filter yang dapat dilihat pada tabel 9.

Tabel 10. Hasil hard filter skenario 2

Nama Ban	Tipe	Harga	Status Filter
Federal Pro	Touring / Medium	Rp170.000	Lolos
Aspira Premio	Touring / Medium	Rp195.000	Lolos
Swallow SB118X	Scooter / Medium	Rp155.000	Lolos
IRC RX-02	Touring / Medium	Rp185.000	Lolos
IRC Duro SD	Scooter / Medium	Rp150.000	Lolos

Pada tabel 10 didapatkan 5 ban yang lolos hard filter. Ban yang lolos pada tahap ini memiliki vektor fitur yang dapat dilihat pada tabel 11.

Tabel 11. Vektor fitur

Nama Ban	Grip	Daya Tahan	Kenyamanan	Kesesuaian Jalan	Harga Inv.	Rating
Federal Pro	0.55	0.60	0.90	0.88	0.78	0.80
Aspira Premio	0.55	0.60	0.90	0.88	0.74	0.84
Swallow SB118X	0.45	0.60	0.80	0.80	0.81	0.80
IRC RX-02	0.55	0.60	0.90	0.88	0.75	0.86
IRC Duro SD	0.45	0.60	0.80	0.80	0.82	0.84

Tabel 11 menunjukkan vektor fitur enam dimensi untuk setiap ban kandidat yang lolos hard filter. Nilai grip dihitung dari rata-rata *compound grip* dan *pattern grip*, daya tahan berdasarkan *compound durability*, kenyamanan dari rata-rata *pattern comfort* dan *compound comfort*, kesesuaian jalan berdasarkan matriks skor kondisi jalan, harga menggunakan *inverse normalization*, dan rating dinormalisasi terhadap skala 5.0.

Tabel 12. Perhitungan Cosine Similarity

Nama Ban	Dot Product	$\ T\ $	$\cos(U,T)$	Similarity
Federal Pro	3.554	1.870	0.9122	91.2%
Aspira Premio	3.524	1.871	0.9039	90.4%
Swallow SB118X	3.340	1.772	0.9047	90.5%
IRC RX-02	3.539	1.884	0.9015	90.1%
IRC Duro SD	3.360	1.795	0.8985	89.8%

Tabel 12 menunjukkan hasil perhitungan *Cosine Similarity* antara vektor preferensi pengguna dengan vektor fitur masing-masing ban kandidat. Perhitungan dilakukan dengan membagi hasil *dot product* antara vektor U dan vektor T dengan hasil perkalian norma kedua vektor. Hasil akhir rekomendasi dapat dilihat pada tabel 13.

Tabel 13. Hasil Rekomendasi Skenario 2

Nama Ban	Brand	Tipe	Harga	Rating	Similarity
Federal Pro	Federal	Touring	Rp170.000	4.0	91.2%
Swallow SB118X	Swallow	Scooter	Rp155.000	4.0	90.5%
Aspira Premio	Aspira	Touring	Rp195.000	4.2	90.4%
IRC RX-02	IRC	Touring	Rp185.000	4.3	90.1%
IRC Duro SD	IRC	Scooter	Rp150.000	4.2	89.8%

Tabel 13 menyajikan perbandingan akhir ban yang direkomendasikan berdasarkan skor *Cosine Similarity*. Pada pengguna dengan preferensi seimbang, ban Federal Pro menempati peringkat pertama dengan skor *similarity* 91,2%, diikuti oleh Swallow SB118X pada peringkat kedua dengan skor 90,5%.

4.7. Hasil Evaluasi

Berdasarkan hasil pengujian kedua skenario, beberapa temuan penting dapat diidentifikasi. Pertama, sistem rekomendasi menunjukkan kemampuan yang baik dalam menghasilkan rekomendasi yang bervariasi sesuai dengan preferensi pengguna. Pada Skenario 1 (Pengguna Berbudget Terbatas), sistem berhasil mengeliminasi dua ban yang harganya melebihi budget melalui proses *hard filter*, sehingga hanya tiga ban kandidat yang diproses lebih lanjut. Hal ini menunjukkan bahwa mekanisme filtering bekerja dengan efektif untuk mempersempit ruang pencarian dan memastikan bahwa rekomendasi yang diberikan sesuai dengan batasan budget pengguna.

Kedua, perbedaan preferensi pengguna secara signifikan mempengaruhi perbandingan ban yang direkomendasikan. Pada Skenario 1, Swallow SB118X menempati peringkat pertama (92,4%) karena memiliki harga yang terjangkau (Rp155.000) yang sesuai dengan prioritas pengguna. Pada Skenario 2, Federal Pro menempati peringkat pertama (91,2%) karena memiliki keseimbangan yang baik antara performa, kenyamanan, dan harga.

Ketiga, rentang skor *similarity* yang dihasilkan bervariasi antar skenario. Skenario 1 dan 2 yang memiliki preferensi lebih bervariasi menghasilkan rentang skor yang lebih lebar (91,0%-92,4% dan 89,8%-91,2%).

Keempat, konsistensi antara hasil perhitungan manual dan output sistem pada Skenario 2 (yang merupakan data real dari sistem) menunjukkan bahwa implementasi algoritma *Cosine Similarity* pada sistem sudah benar dan menghasilkan perhitungan yang akurat. Kesesuaian antara Federal Pro sebagai peringkat pertama baik pada hasil perhitungan manual (91,2%) maupun pada tampilan sistem.

5. KESIMPULAN DAN SARAN

Penelitian ini telah berhasil membangun dan menganalisis sistem rekomendasi ban motor menggunakan metode *Content-Based Filtering* (CBF) dengan teknik *Cosine Similarity*. Sistem merepresentasikan setiap ban motor sebagai vektor fitur numerik enam dimensi (*grip*, *durability*, *comfort*, *road_match*, *price_inverse*, dan *rating*) dan membandingkannya dengan vektor preferensi pengguna menggunakan *Cosine Similarity*.

Hasil pengujian dengan dua skenario yang memiliki preferensi berbeda menunjukkan bahwa sistem mampu memberikan rekomendasi yang bervariasi, dengan skor *similarity* berkisar antara

89,8% hingga 92,4%. Skenario 1 menghasilkan rekomendasi Swallow SB118X (92,4%) sebagai ban terbaik untuk pengguna berbudget terbatas. Skenario 2 menghasilkan Federal Pro (91,2%) sebagai ban terbaik untuk pengguna dengan preferensi seimbang.

Untuk pengembangan selanjutnya, sistem dapat diperkaya dengan menambahkan jumlah data ban yang lebih bervariasi, memperluas dimensi fitur vektor (misalnya kebisingan dan performa basah), menambahkan fitur riwayat pencarian, serta melakukan evaluasi dengan melibatkan responden nyata untuk mengukur tingkat kepuasan pengguna.

DAFTAR PUSTAKA

- [1] W. Yuniaristanto, W. Sutopo, M. Hisjam, dan H. Wicaksono, "Estimating the market share of electric motorcycles: A system dynamics approach with the policy mix and sustainable life cycle costs," *Energy Policy*, vol. 195, art. 114345, 2024, doi: 10.1016/j.enpol.2024.114345.
- [2] B. Alhijawi, A. Awajan, dan S. Fraihat, "Survey on the objectives of recommender systems: Measures, solutions, evaluation methodology, and new perspectives," *ACM Computing Surveys*, vol. 55, no. 5, pp. 1–38, Art. 93, 2022, doi: 10.1145/3527449.
- [3] C. Li, I. Ishak, H. Ibrahim, M. Zolkepli, F. Sidi, dan C. Li, "Deep learning-based recommendation system: Systematic review and classification," *IEEE Access*, vol. 11, pp. 113790–113835, 2023, doi: 10.1109/ACCESS.2023.3323353.
- [4] K. Zhang, X. Liu, W. Wang, dan J. Li, "Multi-criteria recommender system based on social relationships and criteria preferences," *Expert Systems with Applications*, vol. 176, art. 114868, 2021, doi: 10.1016/j.eswa.2021.114868.
- [5] J. E. Daugavietis, R. Soloha, E. Dace, dan J. Ziemele, "A comparison of multi-criteria decision analysis methods for sustainability assessment of district heating systems," *Energies*, vol. 15, no. 7, Art. no. 2411, 2022, doi: 10.3390/en15072411.
- [6] Ö. Arslan dan S. Çebi, "A novel approach for multi-criteria decision making: Extending the WASPAS method using decomposed fuzzy sets," *Computers & Industrial Engineering*, vol. 196, art. 110461, 2024, doi: 10.1016/j.cie.2024.110461.
- [7] N. Abhinav dan S. Kamepalli, "Content-based movie recommendation system using cosine similarity measure," in *AIP Conference Proceedings*, vol. 2901, no. 1, art. 060035, 2023, doi: 10.1063/5.0178819.
- [8] M. Roy, P. Kar, dan S. Datta, Eds., *Recommender Systems: A Multi-Disciplinary Approach*. Boca Raton, FL, USA: CRC Press, 2023, doi: 10.1201/9781003319122.

- [9] A. Chaudhari, A. H. Seddig, A. Sarlan, dan R. Raut, "A hybrid recommendation system: A review," *IEEE Access*, vol. 12, pp. 157107–157126, 2024, doi: 10.1109/ACCESS.2024.3480693.
- [10] R. Alabduljabbar, "Matrix factorization collaborative-based recommender system for Riyadh restaurants: Leveraging machine learning to enhance consumer choice," *Applied Sciences*, vol. 13, no. 17, Art. no. 9574, 2023, doi: 10.3390/app13179574.
- [11] Y. Pérez-Almaguer, R. Labrada-García, Y. Gómez-Aguilar, dan J. L. Lau, "Content-based group recommender systems: A general taxonomy and further improvements," *Expert Systems with Applications*, vol. 184, Art. no. 115444, 2021, doi: 10.1016/j.eswa.2021.115444.
- [12] H. Papadakis, A. Papagrigoriou, E. Kosmas, C. Panagiotakis, S. Markaki, dan P. Fragopoulou, "Content-based recommender systems taxonomy," *Foundations of Computing and Decision Sciences*, vol. 48, no. 2, pp. 211–241, 2023, doi: 10.2478/fcds-2023-0009.
- [13] O. A. S. Ibrahim, E. M. G. Younis, E. A. Mohamed, dan W. N. Ismail, "Revisiting recommender systems: An investigative survey," *Neural Computing and Applications*, vol. 37, no. 4, pp. 2145–2173, 2025, doi: 10.1007/s00521-024-10828-5.
- [14] F. Fkih, "Similarity measures for collaborative filtering-based recommender systems: Review and experimental comparison," *J. King Saud Univ. – Comput. Inf. Sci.*, vol. 34, no. 9, pp. 7645–7669, 2022, doi: 10.1016/j.jksuci.2021.09.014.
- [15] A. Levy, B. R. Shalom, dan M. Chalamish, "A guide to similarity measures and their data science applications," *J. Big Data*, vol. 12, no. 1, Art. no. 188, 2025, doi: 10.1186/s40537-025-01227-1.
- [16] H. Zhou, F. Xiong, dan H. Chen, "A comprehensive survey of recommender systems based on deep learning," *Applied Sciences*, vol. 13, no. 20, Art. no. 11378, 2023, doi: 10.3390/app132011378.
- [17] M. Uta, A. Felfernig, V.-M. Le, T. N. T. Tran, D. Garber, S. Lubos, dan T. Burgstaller, "Knowledge-based recommender systems: Overview and research directions," *Frontiers in Big Data*, vol. 7, Art. no. 1304439, 2024, doi: 10.3389/fdata.2024.1304439.
- [18] A. A. Amer, H. I. Abdalla, dan L. Nguyen, "Enhancing recommendation systems performance using highly-effective similarity measures," *Knowledge-Based Systems*, vol. 217, Art. no. 106842, 2021, doi: 10.1016/j.knosys.2021.106842.
- [19] Y. Ge, S. Liu, Z. Fu, J. Tan, Z. Li, S. Xu, Y. Li, Y. Xian, dan Y. Zhang, "A survey on trustworthy recommender systems," *ACM Trans. Recomm. Syst.*, vol. 3, no. 2, Art. no. 13, pp. 1–68, 2024, doi: 10.1145/3652891.
- [20] W. Cai, M. Yang, dan L. Lin, "An inspiration recommendation system for automotive styling design based on user behavior data and group preferences," *Systems*, vol. 12, no. 11, Art. no. 491, 2024, doi: 10.3390/systems12110491.
- [21] J. J. Thakkar, *Multi-Criteria Decision Making*, ser. *Studies in Systems, Decision and Control*, vol. 336. Singapore: Springer, 2021, doi: 10.1007/978-981-33-4745-8.
- [22] R. O'Shea, P. Deeney, E. Triantaphyllou, L. Diaz-Balteiro, dan S. A. Tarim, "Weight stability intervals for multi-criteria decision analysis using the weighted sum model," *Expert Syst. Appl.*, vol. 296, Art. no. 128460, 2026, doi: 10.1016/j.eswa.2025.128460.