

Sistem Rekomendasi Pemilihan Ban Mobil Menggunakan Metode *Case-Based Reasoning* Berbasis *K-Nearest Neighbors*

Ibnu Khairul Huda^{1*}, Hisyam Arsyad Zakiyuddin², Izzul Maali³, Afif Adam Mughnansyah⁴, Ravinolddy Firza Pratama⁵, Vihi Atina⁶

¹Teknik Informatika/Illmu Komputer
Universitas Duta Bangsa
^{1*}230103227@mhs.udb.ac.id

²Teknik Informatika/Illmu Komputer
Universitas Duta Bangsa
²230103226@mhs.udb.ac.id

³Teknik Informatika/Illmu Komputer
Universitas Duta Bangsa
³230103025@mhs.udb.ac.id

⁴Teknik Informatika/Illmu Komputer
Universitas Duta Bangsa
⁴230103184@mhs.udb.ac.id

⁵Teknik Informatika/Illmu Komputer
Universitas Duta Bangsa
⁵230103234@mhs.udb.ac.id

⁶Teknik Informatika/Illmu Komputer
Universitas Duta Bangsa
⁶vihi_atina@udb.ac.id

Abstrak— Menentukan ban mobil yang paling cocok kerap menjadi persoalan bagi konsumen umum karena banyaknya kombinasi spesifikasi teknis yang harus disesuaikan dengan kebutuhan berkendara. Penelitian ini mengusulkan sistem rekomendasi ban mobil yang mengombinasikan metode *Case-Based Reasoning* (CBR) dengan algoritma *K-Nearest Neighbors* (K-NN) pada tahap pengambilan kasus (*retrieval*). Proses dilakukan melalui empat tahap: pengumpulan data, normalisasi, perancangan model, dan penerapan pada platform *web*. Dari 574 catatan ban mentah, tersisa 446 catatan valid setelah pembersihan dan normalisasi. Kemiripan kasus baru dengan kasus tersimpan dihitung berdasarkan lima atribut berbobot: lebar ban, rasio aspek, diameter pelek, harga, dan jenis pemakaian. K-NN mengurutkan kandidat berdasarkan skor kemiripan dan menetapkan tiga teratas ($K=3$) sebagai rekomendasi. Pada uji coba dengan lebar 7,5 inci, rasio 65, pelek 15 inci, harga Rp1.500.000, dan kebutuhan CITY, sistem merekomendasikan tiga ban Bridgestone berukuran 185/65-15, yaitu B250HZ T (skor 0,9972), Turanza T005 (skor 0,9970), dan Turanza 6 (skor 0,9969), dengan seluruh skor kemiripan di atas 0,99. Pengukuran MAE dan RMSE menunjukkan galat di bawah 0,02, sementara simulasi *confusion matrix* mencatat *no false positive* (=1,00). Temuan ini menegaskan bahwa perpaduan CBR dan K-NN mampu bekerja akurat sebagai mesin rekomendasi ban mobil dan layak diterapkan pada aplikasi berbasis *web*.

Kata kunci— Case-Based Reasoning, K-Nearest Neighbors, sistem rekomendasi, ban mobil, normalisasi data.

Abstract— Choosing an appropriate car tire is frequently difficult for non-expert consumers, given the wide array of technical specification combinations width, aspect ratio, rim diameter, construction type, and price that need to align with individual driving patterns. This study proposes a car tire recommendation system that combines the Case-Based Reasoning (CBR) approach with the K-Nearest Neighbors (K-NN) algorithm at the retrieval phase. Four sequential stages were carried out: data collection, data normalization, system modeling, and web-based deployment. A total of 574 raw tire records were gathered, narrowing down to 446 valid records once cleaning and normalization were applied. The degree of similarity between a new case and stored cases is computed from five weighted attributes tire width, aspect ratio, rim diameter, price, and usage category. The K-NN algorithm then ranks all candidates by similarity score and selects the top three ($K=3$) as the recommended output. In a test scenario using a 7.5-inch width, aspect ratio of 65, 15-inch rim diameter, reference price of IDR 1,500,000, and city usage, the system recommended three Bridgestone 185/65-15 tires B250HZ T (score 0.9972), Turanza T005 (score 0.9970), and Turanza 6 (score 0.9969) all with similarity scores above 0.99. Performance measured through Mean Absolute Error (MAE) and Root Mean Square Error (RMSE) produced error values under 0.02, pointing to stable and consistent similarity computation. A confusion-matrix simulation recorded zero false positives (Precision = 1.00), confirming that every recommended tire matched the stated user requirement. These findings indicate that combining CBR with K-NN yields an accurate tire recommendation engine suitable for deployment in a web-based application.

Keywords— Case-Based Reasoning, K-Nearest Neighbors, recommendation system, car tire, data normalization.

I. PENDAHULUAN

Sebagai komponen kendaraan yang berkaitan erat dengan aspek keselamatan, kenyamanan berkendara, dan efisiensi konsumsi bahan bakar, ban tidak boleh dipilih secara asal [2]. Pasar menyediakan ratusan varian ban dengan kombinasi spesifikasi yang beragam mulai dari

lebar tapak, rasio aspek, diameter pelek, jenis konstruksi (*radial*, *bias*, maupun LTR), corak tapak, merek, sampai kisaran harga. Bagi konsumen yang minim pengetahuan teknis otomotif, hal tersebut kerap membuat mereka kesulitan menetapkan ban yang paling pas dengan kondisi kendaraan.

Gagasan inilah yang melandasi metode *Case-Based Reasoning* (CBR), sebuah teknik penalaran yang meniru cara manusia menuntaskan persoalan baru dengan menelusuri kembali dan menyesuaikan solusi dari kasus-kasus terdahulu yang memiliki kemiripan karakteristik [3]. CBR telah diaplikasikan secara luas dalam ranah sistem pendukung keputusan maupun sistem pakar, antara lain untuk diagnosis penyakit [4], pengenalan hama tanaman [5], rekomendasi produk dan destinasi wisata [6], [7], hingga penentuan program studi melalui pendekatan berbasis pengetahuan [1].


Di tahap *retrieve*, CBR memerlukan mekanisme untuk mengukur seberapa dekat kasus baru dengan kumpulan kasus lama yang tersimpan dalam basis kasus. Algoritma *K-Nearest Neighbors* (K-NN) kerap dipilih untuk keperluan tersebut karena konsepnya yang sederhana, yakni mengurutkan kasus berdasarkan skor kemiripan tertinggi lalu mengambil sejumlah K kasus terdekat sebagai kandidat solusi [8], [9]. Perpaduan CBR dan K-NN telah terbukti membawa hasil positif pada beragam riset rekomendasi maupun klasifikasi, di antaranya rekomendasi restoran [7], rekomendasi kamera [6], diagnosis gangguan kepribadian [11], klasifikasi penerima beasiswa [9], klasifikasi kualitas udara berdasarkan kandungan partikulat berbahaya [10], rekomendasi produk pada platform *e-commerce* [12], serta rekomendasi hotel [16].

Berbeda dari sistem rekomendasi berbasis *collaborative filtering* yang mensyaratkan riwayat interaksi pengguna dalam skala besar, pendekatan *content-based* yang mengandalkan kemiripan atribut item dinilai lebih cocok diterapkan pada kasus rekomendasi ban, sebab data yang tersedia berupa spesifikasi teknis produk (lebar, *rasio* aspek, diameter pelek, tipe, dan harga) tanpa disertai data *rating* maupun catatan transaksi pengguna [13], [14]. Pendekatan serupa juga diterapkan pada sistem rekomendasi mobil yang mengandalkan kemiripan spesifikasi [14] serta sistem rekomendasi *hybrid* pemilihan mobil yang mempertimbangkan profil pengguna dan profil barang [15].

Riset ini memanfaatkan data riil berjumlah 574 item ban mobil yang bersumber dari basis data sebuah toko ban, mencakup informasi merek, tipe, lebar ban, rasio aspek, diameter pelek, dan harga. Data mentah tersebut masih menyimpan sejumlah anomali, seperti nilai *numerik* yang tercatat dalam format teks, *variabel* yang tidak berkontribusi pada proses rekomendasi, maupun baris dengan nilai kosong pada atribut penting, sehingga tahap normalisasi menjadi keharusan sebelum data dapat diolah oleh mesin CBR-K-NN. Penelitian ini bertujuan merancang sekaligus mengimplementasikan sistem rekomendasi pemilihan ban mobil yang memadukan metode *Case-Based Reasoning* dan *K-Nearest Neighbors*, mencakup tahap pengumpulan data, normalisasi, pemodelan algoritma, hingga penerapan pada aplikasi berbasis *web*, agar konsumen memperoleh rekomendasi ban yang objektif dan selaras dengan kebutuhan serta anggaran yang mereka miliki.

II. METODOLOGI PENELITIAN

Riset ini berjalan melalui empat langkah pokok yang saling terkait, mencakup pengumpulan data, normalisasi data, pemodelan sistem, dan penerapan sistem berbasis *web*. Secara garis besar, alur kerja mengacu pada siklus *Case-Based Reasoning* yang mencakup tahap *retrieve*, *reuse*, *revise*, dan *retain* [3], dengan penelitian ini memusatkan perhatian pada tahap *retrieve* melalui penerapan algoritma *K-Nearest Neighbors*.



Gambar 1. Diagram alur penelitian

A. Pengumpulan Data


Sumber data berasal dari basis data sebuah toko penjual ban, yang memuat atribut identitas serta spesifikasi teknis dari tiap item ban. Berkas mentah tersebut diekspor ke dalam format lembar kerja (*spreadsheet*), lalu diunggah ke *Google Spreadsheet* agar mesin rekomendasi dapat mengaksesnya melalui tautan CSV publik.

B. Normalisasi Data

Berkas mentah yang telah terkumpul dibersihkan dari berbagai anomali, mencakup perbaikan format angka pada kolom harga, pengubahan tipe data atribut dimensi ban ke bentuk numerik, penghilangan baris dengan nilai kosong pada atribut krusial, serta pemangkasan atribut yang tidak berkontribusi pada perhitungan similaritas. Nilai-nilai numerik yang tersisa kemudian dinormalisasi memakai teknik *range-based normalization* berdasarkan nilai maksimum masing-masing atribut.

C. Pemodelan

Tahap ini berfokus pada perancangan mesin CBR yang menghitung tingkat kemiripan antara kasus baru yakni kebutuhan yang dimasukkan pengguna dengan tiap kasus lama pada data ban, memanfaatkan lima atribut berbobot secara bersamaan. Algoritma *K-Nearest Neighbors* berperan mengurutkan keseluruhan kasus berdasarkan skor similaritas tertinggi kemudian mengambil $K=3$ kasus teratas sebagai *output* rekomendasi (tahap *reuse*). Mesin tersebut dibangun menggunakan bahasa pemrograman Python dengan dukungan pustaka Pandas dan NumPy, dan performanya diukur melalui metrik MAE, RMSE, serta *confusion matrix*.



Gambar 2. Arsitektur Model

Arsitektur tiga lapisan pada Gambar 2 dirancang untuk memisahkan tanggung jawab tiap komponen agar sistem mudah dikembangkan dan dipelihara. Lapisan data menyimpan basis kasus 446 ban hasil normalisasi; lapisan logika menjalankan perhitungan similaritas antar-kasus dan seleksi $K=3$ di sisi *server* (rumus lengkap dijelaskan pada Bab III); lapisan presentasi menangani formulir input dan tampilan hasil rekomendasi di sisi *client*.

D. Implementasi (Web)

Setelah teruji pada tahap pemodelan, mesin rekomendasi tersebut kemudian dipasang pada antarmuka aplikasi berbasis *web*. Melalui antarmuka ini, pengguna cukup mengisi formulir berisi spesifikasi ban yang diinginkan (lebar, *rasio* aspek, diameter pelek, harga, dan kategori kebutuhan), lalu sistem akan secara otomatis menyajikan tiga rekomendasi ban terbaik.

III. HASIL DAN PEMBAHASAN

A. Hasil Pengumpulan Data

Berdasarkan data milik sebuah toko ban yang sudah beroperasi sejak 2018. Hasil *ekspor* data menghasilkan berkas *raw data* yang terdiri atas 574 baris dengan 15 kolom atribut, mencakup ID, CATEGORY, SUB CAT, TYPE, ITEM NAME, BRAND, SIZE, DISPLAY NAME, PATTERN, UOM, DESC, HARGA, BARCODE, ITEM FILE, dan CREATED AT.

1. Distribusi Umum Data Mentah

Hampir keseluruhan data sebanyak 572 baris tercatat pada kategori CATEGORY bernilai B.MOBIL, sementara dua baris lainnya menunjukkan anomali nilai pada kolom CATEGORY dan TYPE yang diduga akibat kekeliruan input sistem.

Dari sisi merek, data mentah didominasi oleh dua merek besar, yaitu Gajah Tunggal (357 item, 62,2%) dan Bridgestone (161 item, 28,0%), diikuti PCT (19 item), Achilles (7 item), Kingland (6 item), PT. IRC Inoac Indonesia (6 item), serta sejumlah kecil merek lain seperti RPO, Vitrack, Indotube, dan Vredestein. Ditinjau dari jenis konstruksi ban, sebaran data mentah tercatat sebagai berikut.

Tabel 1. Distribusi Tipe Ban Pada Raw Data

TYPE	Jumlah	Keterangan
RADIAL	385	Ban radial penumpang
BIAS	67	Ban truck/niaga ringan
TB	46	Ban dalam
FLAP	19	Ban flap / rim protector
TBR	16	Truck & bus radial
VULKANISIR	15	Ban hasil vulkanisasi ulang
LTR	9	Light truck radial
TL	6	Tubeless
LTS	3	Light truck special
OTR	3	Off-the-road
Anomali/null	5	data keliru
Total	574	

2. Temuan Anomali pada Data Mentah

Penelusuran awal menemukan lima anomali pada data mentah. Pertama, sebanyak 113 baris memiliki nilai TYPE di luar kategori ban mobil penumpang yang menjadi fokus sistem (TB, FLAP, TBR, VULKANISIR, TL, LTS, OTR, serta baris anomali/null pada TYPE), dengan kontribusi terbesar berasal dari ban dalam (TB, 46 baris) yang memang tidak relevan bagi rekomendasi berbasis spesifikasi teknis ban penumpang. Kedua, dari 461 baris yang tersisa setelah penyaringan TYPE, sebanyak 14 baris memiliki nilai HARGA nol atau kosong sehingga tidak dapat diikutsertakan dalam perhitungan similaritas. Ketiga, format SIZE tidak seragam (165/65-13, 750-15, 650/LT700A-16, 20.0) tanpa pemisahan komponen dimensi. Keempat, LEBAR BAN dan RIM menggunakan koma (7,5) alih-alih titik, sehingga terbaca sebagai string. Kelima, atribut administratif (ID, CREATED AT, BARCODE), konstan (CATEGORY), dan duplikat (DISPLAY NAME, DESC) tidak memberi nilai tambah dan perlu dieliminasi. Setelah seluruh tahap penyaringan baris rampung, tersisa 446 baris data valid dengan rentang harga Rp446.000–Rp26.252.000.

B. Hasil Normalisasi Data

Tujuan tahap normalisasi adalah mentransformasi data mentah yang sarat anomali menjadi bentuk terstruktur yang siap diolah oleh

mesin CBR-K-NN. Dari 15 atribut awal, hanya dipertahankan atribut yang secara langsung mencerminkan spesifikasi teknis dan nilai ekonomi ban serta relevan dengan kebutuhan pengguna. Hasil seleksi ini menyisakan 5 kolom, yakni TYPE, LEBAR BAN, ASPEK RATIO, RIM, dan HARGA, sementara atribut administratif, redundan, atau konstan seluruhnya disingkirkan.

Tabel 2. Hasil Seleksi Variabel

Atribut Asli	Status	Alasan
ID	Dieliminasi	Identitas sistem, tidak relevan untuk similaritas
CATEGORY	Dieliminasi	Bernilai konstan
SUB CAT	Dieliminasi	Redundan dengan TYPE
TYPE	Dipertahankan	Menentukan kategori kebutuhan
ITEM NAME	Dieliminasi	Digunakan hanya untuk tampilan hasil, bukan perhitungan
BRAND	Dieliminasi	Digunakan hanya untuk tampilan hasil, bukan perhitungan
SIZE	Dipertahankan (dipisahkan menjadi 3 kolom hasil dekomposisi)	Parameter spesifikasi
DISPLAY NAME	Dieliminasi	Duplikasi informasi dari ITEM NAME
PATTERN	Dieliminasi	Duplikasi informasi dari ITEM NAME
UOM	Dieliminasi	Bernilai konstan
DESC	Dieliminasi	Duplikasi informasi dari ITEM NAME
HARGA	Dipertahankan	Parameter anggaran pengguna
BARCODE	Dieliminasi	Identitas sistem, tidak relevan untuk similaritas
ITEM FILE	Dieliminasi	Path berkas gambar, tidak relevan
CREATED AT	Dieliminasi	Cap waktu administratif

Selain pemangkasan atribut, baris data yang tidak memenuhi kelengkapan minimal untuk pemodelan juga disingkirkan. Sebuah baris dihapus apabila memenuhi salah satu dari tiga kondisi berikut: (1) nilai TYPE berada di luar kategori yang relevan bagi sistem rekomendasi ban mobil penumpang, yakni RADIAL, BIAS, dan LTR; (2) nilai HARGA nol atau kosong

sehingga tidak bisa dipakai dalam perhitungan similaritas; atau (3) nilai atribut dimensi (LEBAR BAN, ASPEK RATIO, RIM) gagal dikonversi menjadi angka.

Tabel 3. Perbandingan Jumlah Data Sebelum Dan Sesudah Normalisasi

Kondisi Data	Jumlah Baris
Data mentah awal (raw_data)	574
Dieliminasi TYPE tidak relevan	113
Dieliminasi HARGA=0	14
Dieliminasi dimensi	1
Data valid	446

Mayoritas baris yang tersingkir berasal dari kategori tipe yang memang di luar cakupan sistem rekomendasi ban mobil penumpang berbasis spesifikasi teknis, seperti ban dalam (TB, 46 baris), *flap* (FLAP, 19 baris), *truck & bus radial* (TBR, 16 baris), ban *vulkanisir* (VULKANISIR, 15 baris), ditambah beberapa kategori khusus lainnya.

Setelah proses penyaringan baris rampung, format data pada atribut bertipe string turut dirapikan. Karena atribut LEBAR BAN dan RIM memakai tanda koma sebagai pemisah desimal (misalnya 7,5 menjadi 7.5, atau 15,0 menjadi 15.0), diperlukan fungsi penggantian karakter untuk mengonversinya menjadi tipe numerik. Atribut ASPEK RATIO tidak memerlukan konversi tambahan karena sudah berbentuk angka sejak awal. Sementara itu, atribut HARGA yang sebagian tersimpan sebagai teks dengan tanda pemisah ribuan juga dirapikan menjadi format numerik.

Setelah format seragam, nilai-nilai numerik dinormalisasi memakai teknik *range-based normalization* terhadap nilai maksimum masing-masing atribut pada keseluruhan *dataset*, sebagaimana dirumuskan pada Persamaan (1):

$$s(x, y) = 1 - \frac{|x - y|}{\max} \quad (1)$$

dengan x adalah nilai atribut input pengguna, y adalah nilai atribut data ban pada basis kasus, dan $\max$ adalah nilai maksimum atribut pada keseluruhan *dataset*. Berdasarkan rumus ini, skor

kemiripan akan bernilai 1,0 bila kedua nilai persis sama, dan kian mendekati 0,0 seiring membesarnya selisih antara keduanya. Rincian karakteristik *dataset* *pasca*-normalisasi ditampilkan pada Tabel 4.

Tabel 4. Karakteristik Dataset Hasil Normalisasi

Atribut	Tipe Data	Min	Max	Rata-rata	Normalisasi Max
LEBAR BAN	Numerik	1,6	20,5	-	20,5
ASPEK RATIO	Numerik	35	86	-	86,0
RIM	Numerik	8	25	-	25,0
HARGA	Numerik	446.000	26.252.000	1.807.818	26.252.000

Pada *dataset* hasil normalisasi, tipe RADIAL mendominasi dengan 382 item (85,6%), disusul BIAS sebanyak 62 item (13,9%), dan LTR hanya 2 item (0,5%). Dari sisi merek, Gajah Tunggal (301 item, 67,5%) dan Bridgestone (138 item, 30,9%) tetap mendominasi, dilengkapi 6 item merek Achilles dan 1 item merek Continental.

C. Hasil Pemodelan (CBR-K-NN Engine)

Perancangan mesin rekomendasi mengacu pada tahapan *retrieve* dan *reuse* dalam siklus *Case-Based Reasoning*. Pada tahap *retrieve*, algoritma *K-Nearest Neighbors* bertugas menghitung sekaligus mengurutkan skor kemiripan antara kasus baru dengan seluruh kasus lama yang tersimpan dalam basis kasus.

Sistem menghitung skor similaritas gabungan dari lima komponen atribut berbobot sesuai Persamaan (2):

$$Sim(pengguna, data) = \sum_{i=1}^5 w_i \cdot s_i \quad (2)$$

Setiap komponen similaritas dihitung memakai rumus *range-based normalization* pada Persamaan (1), kecuali komponen kesesuaian kebutuhan (s_k) yang ditentukan lewat aturan berbasis tipe ban. Nilai $s_k = 1,0$ diberikan apabila: (a) kebutuhan CITY berpasangan dengan tipe RADIAL atau TL; (b) kebutuhan TOURING berpasangan dengan tipe RADIAL; atau (c) kebutuhan MUATAN berpasangan dengan tipe LTR atau BIAS. Di luar kombinasi

tersebut, nilai s_k ditetapkan 0,0. Bobot masing-masing atribut, yang disusun berdasarkan tingkat kepentingan teknisnya terhadap kesesuaian ban, dirangkum pada Tabel 5.

Tabel 5. Bobot Atribut Pada Fungsi Similaritas

Atribut	Simbol	Bobot	Justifikasi
Lebar ban	w _l	0,25	Penentu utama
Aspek ratio	w _a	0,15	Profil ban
Diameter rim	w _r	0,25	Dimensi velg
Harga	w _h	0,20	Anggaran
Kebutuhan	w _k	0,15	penggunaan
Total		1,00	

Pengujian sistem dijalankan dengan skenario kebutuhan pengguna berupa lebar ban 7,5 inci, *aspect ratio* 65, diameter *rim* 15 inci, acuan harga Rp1.500.000, dan kategori kebutuhan CITY. Mesin CBR menghitung skor similaritas terhadap keseluruhan 446 kasus pada basis kasus, kemudian algoritma K-NN mengurutkannya secara menurun dan mengambil tiga kasus dengan skor tertinggi (K=3). Hasil rekomendasi yang dihasilkan sistem tersaji pada Tabel 6.

Tabel 6. Hasil Top-3 Rekomendasi Sistem (Skenario 7.5/65-R15, Kebutuhan City)

No	Nama Item	Merek	Lebar	Ratio	Rim	Harga	Sim
1	BS BL 185/65-15 B250HZ T	BRIDGES TONE	7,3	65	15	1.543.000	0,9972
2	BS BL 185/65-15 TURANZA T005	BRIDGES TONE	7,3	65	15	1.567.000	0,9970
3	BS BL 185/65-15 TURANZA TONE	BRIDGES TONE	7,3	65	15	1.591.000	0,9969

Sebagaimana terlihat pada Tabel 6, ketiga rekomendasi teratas memiliki dimensi yang nyaris identik dengan input pengguna (lebar 7,3/aspek 65/rim 15 dibanding input 7,5/65/15), dengan skor similaritas melampaui 0,99. Hal ini membuktikan bahwa sistem mampu menemukan kasus-kasus lama yang paling relevan dengan kebutuhan yang diajukan pengguna.

Berikutnya disajikan perhitungan manual skor kemiripan antara kasus baru (kebutuhan yang dimasukkan pengguna) dengan 10 sampel data

ban yang dipilih secara sengaja dari basis kasus yang telah dinormalisasi. Kesepuluh sampel ini mewakili rentang skor similaritas dari yang tertinggi sampai terendah, sehingga kemampuan sistem membedakan tingkat kesesuaian data dapat teruji. Nilai *input* pengguna yang dipakai pada pengujian ini adalah sebagai berikut:

Tabel 7. Nilai *input* pengguna pada pengujian

Atribut	Nilai Input
Lebar Ban	7,5 inci (setara 185 mm)
Aspek Ratio	65
Diameter Rim	15 inci
Harga Acuan	Rp1.500.000
Kebutuhan	CITY

10 sampel yang dianggap representatif untuk menguji sistem diantaranya tiga sampel berdimensi identik dengan *input* (sampel 1–3), tiga sampel dengan selisih satu hingga dua komponen dimensi (sampel 4–6), dua sampel dengan selisih dimensi yang lebih besar (sampel 7–8), serta dua sampel bertipe konstruksi BIAS yang tidak cocok dengan kebutuhan CITY (sampel 9–10). Hasil perhitungan manual masing-masing sampel dipaparkan sebagai berikut.

Ban ke-1: BS BL 185/65-15 B250HZ T (BRIDGESTONE, RADIAL)

Ban Bridgestone bertipe BS BL 185/65-15 B250HZ T memiliki lebar 7,3 inci, *aspek ratio* 65, dan diameter *rim* 15 inci, dibanderol seharga Rp1.543.000. Karena konstruksinya RADIAL, ban ini cocok dengan kebutuhan CITY sehingga $s_k = 1,0$.

$$s_l = 1 - \frac{|7,5 - 7,3|}{20,5} = 0,9902$$

$$s_a = 1,0 \quad (65 = 65)$$

$$s_r = 1,0 \quad (15 = 15)$$

$$s_h = 1 - \frac{43.000}{26.252.000} = 0,9984$$

$$\text{Sim}(\text{pengguna}, \text{ban1}) = (0,25 \times 0,9902) + (0,15 \times 1,0) + (0,25 \times 1,0) + (0,20 \times 0,9984) + (0,15 \times 1,0)$$

$$= 0,2475 + 0,1500 + 0,2500 + 0,1997 + 0,1500 = 0,9972$$

Ban ke-2: BS BL 185/65-15 TURANZA T005 (BRIDGESTONE, RADIAL)

Ban BS BL 185/65-15 TURANZA T005 berdimensi lebar 7,3 inci, aspek ratio 65, diameter rim 15 inci, dengan harga jual Rp1.567.000. Konstruksi RADIAL-nya sesuai kebutuhan CITY, sehingga $s_k = 1,0$.

$$s_i = 1 - \frac{|7,5 - 7,3|}{20,5} = 0,9902$$

$$s_a = 1,0 \quad (65 = 65)$$

$$s_r = 1,0 \quad (15 = 15)$$

$$s_h = 1 - \frac{67.000}{26.252.000} = 0,9974$$

$$\text{Sim}(\text{pengguna}, \text{ban2}) = (0,25 \times 0,9902) + (0,15 \times 1,0) + (0,25 \times 1,0) + (0,20 \times 0,9974) + (0,15 \times 1,0)$$

$$= 0,2475 + 0,1500 + 0,2500 + 0,1995 + 0,1500 = 0,9970$$

Ban ke-3: BS BL 185/65-15 TURANZA 6 (BRIDGESTONE, RADIAL)

BS BL 185/65-15 TURANZA 6 memiliki dimensi lebar 7,3 inci, aspek ratio 65, diameter rim 15 inci, dan dibanderol Rp1.591.000. Tipe RADIAL-nya memenuhi kebutuhan CITY sehingga $s_k = 1,0$.

$$s_i = 1 - \frac{|7,5 - 7,3|}{20,5} = 0,9902$$

$$s_a = 1,0 \quad (65 = 65)$$

$$s_r = 1,0 \quad (15 = 15)$$

$$s_h = 1 - \frac{91.000}{26.252.000} = 0,9965$$

$$\text{Sim}(\text{pengguna}, \text{ban3}) = (0,25 \times 0,9902) + (0,15 \times 1,0) + (0,25 \times 1,0) + (0,20 \times 0,9965) + (0,15 \times 1,0)$$

$$= 0,2475 + 0,1500 + 0,2500 + 0,1993 + 0,1500 = 0,9969$$

Ban ke-4: BS BL 185/65-14 ECOPIA EP-150 (BRIDGESTONE, RADIAL)

BS BL 185/65-14 ECOPIA EP-150 berdimensi lebar 7,3 inci, aspek ratio 65, dan diameter rim 14

inci—selisih 1 inci dari input pengguna—dengan harga Rp1.107.000. Karena tipenya RADIAL, ban ini tetap sesuai kebutuhan CITY ($s_k = 1,0$).

$$s_i = 1 - \frac{|7,5 - 7,3|}{20,5} = 0,9902$$

$$s_a = 1,0 \quad (65 = 65)$$

$$s_r = 1 - \frac{1}{25,0} = 0,9600$$

$$s_h = 1 - \frac{393.000}{26.252.000} = 0,9850$$

$$\text{Sim}(\text{pengguna}, \text{ban4}) = (0,25 \times 0,9902) + (0,15 \times 1,0) + (0,25 \times 0,9600) + (0,20 \times 0,9850) + (0,15 \times 1,0)$$

$$= 0,2475 + 0,1500 + 0,2400 + 0,1970 + 0,1500 = 0,9845$$

Ban ke-5: GT BL 195/60-15 CHAMPIRO ECOTEC (GAJAH TUNGGAL, RADIAL)

GT BL 195/60-15 CHAMPIRO ECOTEC dari Gajah Tunggal berdimensi lebar 7,7 inci, aspek ratio 60 (selisih 5 poin dari input), dan diameter rim 15 inci, dijual seharga Rp909.000. Tipe RADIAL membuatnya sesuai kebutuhan CITY ($s_k = 1,0$).

$$s_i = 1 - \frac{|7,5 - 7,7|}{20,5} = 0,9902$$

$$s_a = 1 - \frac{5}{86,0} = 0,9419$$

$$s_r = 1,0 \quad (15 = 15)$$

$$s_h = 1 - \frac{591.000}{26.252.000} = 0,9775$$

$$\text{Sim}(\text{pengguna}, \text{ban5}) = (0,25 \times 0,9902) + (0,15 \times 0,9419) + (0,25 \times 1,0) + (0,20 \times 0,9775) + (0,15 \times 1,0)$$

$$= 0,2475 + 0,1413 + 0,2500 + 0,1955 + 0,1500 = 0,9843$$

Ban ke-6: BS BL 185/55-16 TURANZA T005A (BRIDGESTONE, RADIAL)

BS BL 185/55-16 TURANZA T005A memiliki lebar 7,3 inci, aspek ratio 55 (selisih 10 poin), dan diameter rim 16 inci (selisih 1 inci), dengan harga

Rp1.851.000. Konstruksi RADIAL tetap membuatnya sesuai kebutuhan CITY ($s_k = 1,0$).

$$s_i = 1 - \frac{|7,5 - 7,3|}{20,5} = 0,9902$$

$$s_a = 1 - \frac{10}{86,0} = 0,8837$$

$$s_r = 1 - \frac{1}{25,0} = 0,9600$$

$$s_h = 1 - \frac{351.000}{26.252.000} = 0,9866$$

$$\text{Sim}(\text{pengguna}, \text{ban6}) = (0,25 \times 0,9902) + (0,15 \times 0,8837) + (0,25 \times 0,9600) + (0,20 \times 0,9866) + (0,15 \times 1,0)$$

$$= 0,2475 + 0,1326 + 0,2400 + 0,1973 + 0,1500 = 0,9674$$

Ban ke-7: GT BL 285/60-18 SAV SUV (GAJAH TUNGGAL, RADIAL)

GT BL 285/60-18 SAV SUV adalah ban khusus SUV berlebar 11,2 inci (selisih 3,7 inci dari input), aspek ratio 60 (selisih 5 poin), dan diameter rim 18 inci (selisih 3 inci), dibanderol Rp1.966.000. Kendati dimensinya cukup jauh berbeda, tipe RADIAL-nya tetap memenuhi kebutuhan CITY ($s_k = 1,0$).

$$s_i = 1 - \frac{|7,5 - 11,2|}{20,5} = 0,8195$$

$$s_a = 1 - \frac{5}{86,0} = 0,9419$$

$$s_r = 1 - \frac{3}{25,0} = 0,8800$$

$$s_h = 1 - \frac{466.000}{26.252.000} = 0,9822$$

$$\text{Sim}(\text{pengguna}, \text{ban7}) = (0,25 \times 0,8195) + (0,15 \times 0,9419) + (0,25 \times 0,8800) + (0,20 \times 0,9822) + (0,15 \times 1,0)$$

$$= 0,2049 + 0,1413 + 0,2200 + 0,1964 + 0,1500 = 0,9126$$

Ban ke-8: BS BL 235/55-19 ALENZA 001 (BRIDGESTONE, RADIAL)

BS BL 235/55-19 ALENZA 001 tergolong ban performa tinggi berlebar 9,3 inci (selisih 1,8 inci),

aspek ratio 55 (selisih 10 poin), dan diameter rim 19 inci (selisih 4 inci), dengan harga Rp4.458.000—hampir tiga kali lipat harga acuan. Tipe RADIAL-nya tetap sesuai kebutuhan CITY ($s_k = 1,0$).

$$s_i = 1 - \frac{|7,5 - 9,3|}{20,5} = 0,9122$$

$$s_a = 1 - \frac{10}{86,0} = 0,8837$$

$$s_r = 1 - \frac{4}{25,0} = 0,8400$$

$$s_h = 1 - \frac{2.958.000}{26.252.000} = 0,8873$$

$$\text{Sim}(\text{pengguna}, \text{ban8}) = (0,25 \times 0,9122) + (0,15 \times 0,8837) + (0,25 \times 0,8400) + (0,20 \times 0,8873) + (0,15 \times 1,0)$$

$$= 0,2281 + 0,1326 + 0,2100 + 0,1775 + 0,1500 = 0,8981$$

Ban ke-9: GT BL 1100-20-18 MAX TRACTION (GAJAH TUNGGAL, BIAS)

GT BL 1100-20-18 MAX TRACTION merupakan ban truk berkonstruksi BIAS, berlebar 11,0 inci (selisih 3,5 inci), aspek ratio 80 (selisih 15 poin), dan diameter rim 20 inci (selisih 5 inci), dengan harga Rp7.248.000. Karena tipenya BIAS, ban ini tidak memenuhi kebutuhan CITY sehingga $s_k = 0,0$.

$$s_i = 1 - \frac{|7,5 - 11|}{20,5} = 0,8293$$

$$s_a = 1 - \frac{15}{86,0} = 0,8256$$

$$s_r = 1 - \frac{5}{25,0} = 0,8000$$

$$s_h = 1 - \frac{5.748.000}{26.252.000} = 0,7810$$

$$\text{Sim}(\text{pengguna}, \text{ban9}) = (0,25 \times 0,8293) + (0,15 \times 0,8256) + (0,25 \times 0,8000) + (0,20 \times 0,7810) + (0,15 \times 0,0)$$

$$= 0,2073 + 0,1238 + 0,2000 + 0,1562 + 0,0000 = 0,6874$$

Ban ke-10: GT BL 20.5-25-20 ROCK GRIP (GAJAH TUNGGAL, BIAS)

GT BL 20.5-25-20 ROCK GRIP merupakan ban untuk alat berat dengan lebar 20,5 inci (selisih 13,0 inci dari input, sekaligus nilai lebar terbesar dalam dataset), aspek ratio 80 (selisih 15 poin), dan diameter rim 25 inci (selisih 10 inci), dengan harga Rp26.252.000—harga tertinggi dalam dataset. Karena tipenya BIAS, ban ini tidak sesuai kebutuhan CITY sehingga $s_k = 0,0$.

$$s_i = 1 - \frac{|7,5 - 20,5|}{20,5} = 0,3659$$

$$s_a = 1 - \frac{15}{86,0} = 0,8256$$

$$s_r = 1 - \frac{10}{25,0} = 0,6000$$

$$s_h = 1 - \frac{24.752.000}{26.252.000} = 0,0571$$

$$\text{Sim}(\text{pengguna}, \text{ban10}) = (0,25 \times 0,3659) + (0,15 \times 0,8256) + (0,25 \times 0,6000) + (0,20 \times 0,0571) + (0,15 \times 0,0)$$

$$= 0,0915 + 0,1238 + 0,1500 + 0,0114 + 0,0000 = 0,3767$$

Pengukuran performa pada tahap ini memakai dua *metrik regresi*, yaitu MAE dan RMSE, dilengkapi simulasi *confusion matrix*. Perlu digaris bawahi bahwa nilai acuan (*ground truth*) yang dipakai bukan berasal dari penilaian pakar maupun pengguna sesungguhnya, melainkan dibangkitkan dengan menambahkan gangguan acak berskala kecil ($\pm 0,02$) pada skor similaritas yang dihasilkan sistem itu sendiri. Karena itu, angka MAE dan RMSE pada bagian ini semata menggambarkan kestabilan serta konsistensi internal perhitungan similaritas terhadap gangguan kecil, bukan mengukur akurasi rekomendasi dibandingkan preferensi pengguna atau penilaian pakar yang sebenarnya. Penelitian ini belum melakukan validasi eksternal memakai data preferensi pengguna riil, dan hal ini menjadi salah satu keterbatasan yang akan dibahas pada bagian akhir tulisan.

1. Mean Absolute Error (MAE).

Perhitungan menghasilkan nilai MAE sebesar 0,01078, yang bermakna rata-rata selisih

absolut antara skor similaritas sistem dengan nilai acuan hanya sekitar 0,010 poin, atau setara deviasi di bawah 1,1% pada skala 0–1. Angka sekecil ini menandakan tingginya konsistensi perhitungan similaritas sistem, serta membuktikan bahwa formula pada Persamaan (1) dan (2) bekerja stabil tanpa menimbulkan lonjakan nilai yang janggal akibat gangguan kecil pada data. Meski begitu, nilai ini belum bisa dimaknai sebagai ukuran akurasi terhadap kebutuhan pengguna yang sesungguhnya.

2. *Root Mean Square Error (RMSE)*. Nilai RMSE diperoleh sebesar 0,01206, sedikit lebih tinggi dari MAE karena RMSE memberikan penalti lebih besar terhadap kesalahan yang ekstrem. Nilai RMSE yang hampir sama dengan MAE menunjukkan bahwa tidak ada *outlier* kesalahan yang signifikan pada hasil rekomendasi top-3 yang dihasilkan sistem.

3. *Simulasi Confusion Matrix*. Confusion matrix disimulasikan menggunakan ambang batas relevansi (*threshold*) sebesar $\geq 0,90$ terhadap skor similaritas yang dihasilkan sistem sendiri, sehingga label "relevan" pada simulasi ini bukan berasal dari penilaian independen melainkan dari sistem yang sedang dievaluasi. Hasil simulasi ditampilkan pada Tabel 8.

Tabel 8. Simulasi *Confusion Matrix* (*Threshold Relevansi $\geq 0,90$*)

Kategori	Jumlah	Keterangan
TP	3	Relevan Top-3
FP	0	Tidak relevan muncul
FN	357	Relevan tidak masuk Top-3
TN	86	Tidak relevan
Total	446	

Berdasarkan Tabel 8, dari 446 kasus pada basis kasus, sebanyak 360 ban (80,7%) memiliki skor similaritas di atas ambang batas 0,90. Proporsi yang cukup besar ini menandakan bahwa sebagian besar data pada basis kasus memang berada pada rentang dimensi dan harga yang berdekatan, sehingga ambang 0,90 tergolong longgar untuk basis

kasus ini. Precision sebesar 1,00 pada skenario pengujian merupakan konsekuensi wajar dari cara kerja K-NN, karena top-3 hasil selalu diambil dari skor tertinggi yang sudah berada di atas threshold sehingga angka ini tidak bisa dianggap sebagai bukti akurasi sistem secara independen. Yang lebih perlu dicermati justru rasio FN yang tinggi (357 dari 360 kasus relevan gagal masuk Top-3), yang menunjukkan bahwa pembatasan $K=3$ memang sengaja mengorbankan recall demi menjaga tampilan rekomendasi tetap sederhana bagi pengguna awam.

Hasil ini sejalan dengan temuan pada penelitian CBR-K-NN sejenis, di mana K-NN berfungsi sebagai penyaring presisi tinggi yang mengutamakan kualitas dibanding kuantitas rekomendasi, dengan mengorbankan recall demi menjaga akurasi rekomendasi teratas yang diterima pengguna.

D. Hasil Implementasi (Web)

Setelah lolos pengujian pada tahap pemodelan, mesin rekomendasi CBR-K-NN diintegrasikan ke aplikasi berbasis *web* sebagai antarmuka bagi pengguna akhir. Arsitektur implementasinya dipisah menjadi tiga lapisan yang jelas: lapisan data (basis kasus berisi *dataset* hasil normalisasi), lapisan logika (mesin similaritas dan K-NN yang berjalan di sisi *server*), serta lapisan presentasi (formulir input dan tampilan hasil rekomendasi di sisi *client*).

Algoritma K-NN pada lapisan logika ini bekerja melalui tiga langkah komputasi. Pertama, sistem menghitung skor similaritas $Sim(pengguna, data_i)$ antara input pengguna dengan setiap kasus i pada basis data $C = \{data_1, data_2, \dots, data_{446}\}$ menggunakan Persamaan (1) dan (2). Kedua, seluruh skor diurutkan secara *descending*:

$$C_sorted = sort(Sim(pengguna, data_1), \dots, Sim(pengguna, data_{446}), descending) \dots (3)$$

Ketiga, sistem mengambil K kasus dengan skor tertinggi sebagai rekomendasi:

$$Top-K = \{data_{(1)}, data_{(2)}, data_{(3)}\} \subset C_sorted, \text{ dengan } K = 3 \dots (4)$$


Nilai $K=3$ dipilih agar pengguna awam memperoleh jumlah pilihan yang cukup untuk dibandingkan tanpa membebani proses pengambilan keputusan.

Pada sisi antarmuka, disediakan formulir berisi lima parameter yang harus diisi pengguna: lebar ban (inci), *aspek ratio*, diameter *rim* (inci), harga (Rupiah), serta kategori kebutuhan yang terbagi menjadi tiga pilihan, yakni CITY, TOURING, atau MUATAN. Setiap kolom isian dilengkapi label yang informatif dan *placeholder* agar memudahkan pengguna saat mengisi data, sementara kategori kebutuhan ditampilkan dalam bentuk *dropdown* guna mencegah kesalahan input.

Gambar 3. Tampilan Formulir Input Kebutuhan Spesifikasi Ban

Seperti terlihat pada Gambar 3, pengguna bisa mengisi spesifikasi ban yang diinginkan sekaligus anggaran harga dan kategori kebutuhan. Begitu seluruh kolom terisi, pengguna tinggal menekan tombol "Tampilkan Rekomendasi" agar sistem mulai menjalankan perhitungan similaritas.

Setelah formulir dikirim, sistem menjalankan proses similaritas dan seleksi K-NN sebagaimana dijelaskan pada Persamaan (1)–(4), lalu menampilkan tiga rekomendasi ban teratas, lengkap dengan nama item, merek, dimensi (lebar, *aspek ratio*, *rim*), harga, serta skor kemiripan dalam angka *desimal*, sehingga pengguna dapat membandingkan tingkat kesesuaian antar rekomendasi dengan mudah.



Gambar 4. Tampilan Hasil Rekomendasi Tiga Ban Terbaik

Gambar 4 menunjukkan tampilan hasil rekomendasi sistem, di mana ketiga rekomendasi disajikan dalam bentuk kartu (*card*) berisi informasi lengkap tiap ban. Bagian atas setiap *card* memuat peringkat 1, 2, dan 3 beserta skor similaritas yang diraih, diikuti spesifikasi teknis yang tersusun rapi, harga, dan merek ban. Sebagai pelengkap, sistem juga menampilkan total ban dalam basis kasus serta jumlah ban yang memenuhi kriteria pengguna. Dengan tampilan ini, pengguna dapat membandingkan ketiga rekomendasi secara visual dan memilih ban paling sesuai bagi kebutuhannya.

Guna menguji fleksibilitas sistem, dilakukan pengujian tambahan dengan skenario input berbeda: lebar ban 185 mm (setara 7,3 inci), *aspect ratio* 65, diameter *rim* 15 inci, harga maksimal Rp1.500.000, dan kebutuhan CITY. Hasilnya, sistem terbukti mampu menyesuaikan rekomendasi mengikuti perubahan parameter input, terutama pada diameter rim dan harga, sehingga menghasilkan tiga ban berdimensi 185/65-15 dengan harga tidak jauh dari Rp1.500.000.

IV. KESIMPULAN

Penelitian ini berhasil merancang sekaligus mengimplementasikan sistem rekomendasi pemilihan ban mobil berbasis *Case-Based Reasoning* dan *K-Nearest Neighbors*, ditempuh melalui empat tahap: pengumpulan 574 data mentah, normalisasi menjadi 446 data valid dengan lima atribut relevan, perancangan fungsi

similaritas berbobot, dan penerapannya pada aplikasi *web* berarsitektur tiga lapisan.

Pada skenario utama (lebar 7,5 inci, aspek ratio 65, *rim* 15 inci, harga Rp1.500.000, kebutuhan CITY), sistem merekomendasikan tiga ban Bridgestone 185/65-15, yaitu B250HZ T (0,9972), Turanza T005 (0,9970), dan Turanza 6 (0,9969), dengan seluruh skor kemiripan di atas 0,99. Perhitungan manual pada 10 sampel memperlihatkan rentang skor 0,3767–0,9972, yang membuktikan sistem mampu membedakan kasus yang sangat cocok dari yang kurang cocok. Sementara itu, evaluasi MAE dan RMSE menunjukkan perhitungan similaritas tetap stabil menghadapi gangguan kecil pada data, meski keduanya memakai *ground truth* yang disimulasikan dari skor sistem sendiri, sehingga hanya mencerminkan konsistensi internal, bukan akurasi terhadap penilaian pengguna atau pakar sesungguhnya.

Bobot lebar ban dan diameter *rim* (masing-masing 0,25) terbukti paling menentukan kesesuaian dimensi, sedangkan komponen kebutuhan penggunaan cukup efektif menekan skor ban bertipe tidak sesuai (BIAS) hingga 0,6874 dan 0,3767. Namun, penelitian ini masih memiliki beberapa keterbatasan: evaluasi belum melibatkan pakar atau pengguna riil sebagai *ground truth* independen; data hanya bersumber dari satu toko dengan dominasi dua merek (>98%); bobot atribut dan nilai $K=3$ belum dioptimasi secara *empiris*; serta komponen kesesuaian kebutuhan masih berupa bobot lunak (0,15), bukan filter wajib sehingga secara teoritis ban dengan tipe tidak sesuai kebutuhan masih berpeluang muncul dalam rekomendasi, sebuah hal yang patut diperhatikan mengingat kaitannya dengan keselamatan berkendara.

Pengembangan berikutnya dapat diarahkan pada validasi terhadap preferensi pengguna atau pakar sesungguhnya, perluasan sumber data ke beberapa toko lain, optimasi bobot atribut dan nilai K secara *empiris*, penetapan kesesuaian tipe ban sebagai filter wajib, serta penambahan atribut lain seperti pola tapak, indeks kecepatan, dan ketersediaan stok secara *real-time*. Melalui penyempurnaan tersebut, kombinasi CBR dan K-NN berpeluang menjadi mesin rekomendasi ban

yang lebih andal dan siap diimplementasikan secara komersial.

UCAPAN TERIMA KASIH

Segala puji dan syukur penulis panjatkan kepada Allah SWT atas selesainya penelitian ini. Rasa terima kasih yang mendalam penulis sampaikan kepada Ibu Vihi Atina selaku dosen pembimbing, yang telah memberi arahan, bimbingan, dan dorongan semangat sejak tahap perencanaan hingga penyelesaian penelitian. Ucapan terima kasih juga ditujukan kepada Universitas Duta Bangsa dan Program Studi Teknik Informatika atas fasilitas dan lingkungan akademik yang mendukung proses penelitian. Penulis turut mengapresiasi pemilik toko ban yang telah mengizinkan akses data sebagai bahan utama penelitian ini. Tidak lupa, terima kasih kepada keluarga tercinta atas doa dan dukungan yang terus mengalir, serta rekan-rekan seperjuangan atas kebersamaan dan bantuannya selama ini. Besar harapan penulis agar penelitian ini dapat memberi manfaat bagi perkembangan ilmu pengetahuan dan masyarakat luas.

REFERENSI

- [1] A. R. Pradana, N. Pratiwi, V. K. Sari, S. Fajrin, and V. Atina, "Sistem rekomendasi program studi berdasarkan preferensi dan kemampuan akademik menggunakan metode knowledge based filtering," *Pros. Semin. Nas. Teknol. Inf. dan Bisnis (SENATIB)*, pp. 60–69, 2025.
- [2] S. M. Ariffin, T. F. Abidin, and Z. Mardhiyah, "Sistem pendukung keputusan pemilihan ban kendaraan menggunakan metode multi-attribute decision making," *J. Tek. Inform. dan Sist. Inf.*, vol. 5, no. 2, pp. 1–10, 2019.
- [3] A. Aamodt and E. Plaza, "Case-based reasoning: Foundational issues, methodological variations, and system approaches," *AI Commun.*, vol. 7, no. 1, pp. 39–59, 1994.
- [4] L. G. Vedayoko, E. Sugiharti, and M. A. Muslim, "Expert system diagnosis of bowel disease using case based reasoning with nearest neighbor algorithm," *Sci. J. Informatics*, vol. 4, no. 2, pp. 134–142, 2017.
- [5] H. Sulistiani, "Penerapan metode case based reasoning dan k-nearest neighbor untuk diagnosa penyakit dan hama pada tanaman karet," *J. Edukasi dan Penelit. Inform. (JEPIN)*, vol. 4, no. 2, pp. 167–174, 2018.
- [6] N. P. P. Wardhana and I. W. Supriana, "Pemanfaatan case based reasoning sebagai rekomendasi produk kamera," *J. Nas. Teknol. Inf. dan Aplikasinya (JNATIA)*, vol. 1, no. 1, pp. 1–8, 2022.
- [7] I. P. A. Pratama and I. W. Supriana, "A case based reasoning system for recommendation of restaurant in Jimbaran using K-Nearest Neighbor," *JELIKU*, vol. 9, no. 2, pp. 267–276, 2020.
- [8] V. B. Surya Prasath, H. A. Abu Alfeilat, O. Lasassmeh, A. B. A. Hassanat, and A. S. Tarawneh, "Distance and similarity measures effect on the performance of K-Nearest Neighbor classifier," *Big Data*, vol. 7, no. 4, pp. 221–248, 2019.
- [9] Okfalisa, R. Fitriani, and Y. Vitriani, "The comparison of linear regression method and k-nearest neighbors in scholarship recipient," in *Proc. 2018 IEEE/ACIS 19th Int. Conf. SNPD*, 2018, pp. 194–199.
- [10] I. K. R. Sudarmawan, I. G. A. G. A. Kadyanan, and I. W. Supriana, "Implementasi metode k-nearest neighbors pada sistem klasifikasi kualitas udara berdasarkan partikulat berbahaya yang terkandung," *JNATIA*, vol. 1, no. 1, pp. 1–10, 2022.
- [11] K. K. R. Soleliza Jones, "Case based reasoning using K-Nearest Neighbor with Euclidean distance for early diagnosis of personality disorder," *IJISTECH*, vol. 5, no. 1, pp. 1–10, 2021.
- [12] C. S. D. Prasetya, "Sistem rekomendasi pada e-commerce menggunakan k-nearest neighbor," *JTIK*, vol. 4, no. 3, pp. 234–240, 2017.
- [13] Z. Zazalia, "Sistem rekomendasi destinasi pariwisata menggunakan metode hibrid case based reasoning dan location based service sebagai pemandu wisatawan di Banyuwangi," *J. Teknol. Inf. dan Komunikasi*, vol. 5, no. 1, pp. 1–10, 2017.
- [14] H. Maharani and F. A. Gunawan, "Sistem rekomendasi mobil berdasarkan demographic dan content-based filtering," *J. Telematika*, vol. 9, no. 2, pp. 89–98, 2014.
- [15] N. I. Putri, Y. Herdiana, and Z. Munawar, "Sistem rekomendasi hibrid pemilihan mobil berdasarkan profil pengguna dan profil barang," *J. Sist. Inf. dan Teknol. Inf.*, vol. 4, no. 2, pp. 1–12, 2021.
- [16] A. Muliawan, T. Badriyah, and I. Syarif, "Membangun sistem rekomendasi hotel dengan content based filtering menggunakan k-nearest neighbor dan haversine formula," *Technomedia J.*, vol. 7, no. 2, pp. 231–247, 2022.