

Pemanfaatan Random Forest Classifier Untuk Sistem Rekomendasi Makanan Berbasis Preferensi Pengguna

¹Muhamad Sadam Akbar, ²Iksan Ramadhan

^{1,2}Universitas Esa Unggul, Bekasi, Indonesia

*Korespondensi : sadamakbar93@student.esaunggul.ac.id

Submit : 03 Jan, 2026 | Diterima : 24 Feb, 2026 | Terbit : 02 Mar, 2026

ABSTRACT

The diversity of food choices often makes it difficult for consumers to determine dishes that match their preferences, a problem that is particularly relevant for students at Universitas Esa Unggul Bekasi. This study aims to develop a web-based food recommendation system capable of predicting and providing personalized recommendations based on user preferences. The Random Forest Classifier algorithm was selected as the core model due to its ability to handle complex data and produce accurate predictions for preferences such as food type (soupy/non-soupy), spiciness level, special dietary needs, and allergy considerations. The research methodology adopted a prototyping approach, involving extensive data collection from a dataset on Kaggle (14,948 records) and web scraping results from Cookpad. The data were processed through column standardization, text cleaning, merging, duplicate removal, nutritional estimation, and labeling. The Random Forest Classifier model was then trained and implemented within a web application that allows users to input preferences and receive recommendations in the form of food descriptions, images, and short recipes, including complete nutritional information. Testing results indicate high model accuracy: 89.84% for food type, 95.24% for spiciness level, and 92.43% for dish category, demonstrating the system's effectiveness in delivering relevant recommendations. This research contributes to the development of more personalized and efficient culinary recommendation systems within a university environment.

Keywords: Recommendation System, Random Forest Classifier, Food Preferences, Machine Learning, Web Application.

ABSTRAK

Keragaman pilihan makanan seringkali menyulitkan konsumen dalam menentukan hidangan yang sesuai dengan preferensi, sebuah permasalahan yang relevan bagi mahasiswa Universitas Esa Unggul Bekasi. Penelitian ini bertujuan untuk mengembangkan sistem rekomendasi makanan berbasis web yang dapat memprediksi dan menyajikan rekomendasi personal berdasarkan preferensi pengguna. Algoritma Random Forest Classifier dipilih sebagai inti model karena kemampuannya dalam mengelola data kompleks dan memberikan prediksi akurat untuk preferensi seperti jenis makanan (berkuah/tidak berkuah), tingkat kepedasan, kebutuhan diet khusus, dan pertimbangan alergi. Metodologi penelitian mengadopsi pendekatan *prototyping*, melibatkan pengumpulan data ekstensif dari dataset Kaggle (14.948 data) dan hasil *web scraping* dari Cookpad. Data kemudian diproses melalui standarisasi kolom, pembersihan teks, penggabungan, penghapusan duplikat, estimasi gizi, dan pelabelan. Model Random Forest Classifier dilatih dan diimplementasikan dalam aplikasi web yang memungkinkan pengguna memasukkan preferensi dan menerima rekomendasi berupa deskripsi makanan, gambar, serta resep singkat, termasuk informasi nutrisi lengkap. Hasil pengujian menunjukkan akurasi model yang tinggi: 89.84% untuk jenis makanan, 95.24% untuk tingkat pedas, dan 92.43% untuk tipe hidangan, membuktikan efektivitas sistem dalam memberikan rekomendasi yang relevan. Penelitian ini berkontribusi pada pengembangan sistem rekomendasi kuliner yang lebih personal dan efisien di lingkungan universitas.

Kata Kunci: Sistem Rekomendasi, Random Forest Classifier, Preferensi Makanan, Machine Learning, Aplikasi Web

PENDAHULUAN

Setiap individu memiliki preferensi makanan yang unik dan dinamis, dipengaruhi oleh berbagai faktor personal seperti jenis makanan (misalnya, berkuah atau tidak berkuah), tingkat kepedasan, kebutuhan diet khusus, bahkan pertimbangan alergi. Di tengah semakin beragamnya pilihan kuliner, konsumen sering kali dihadapkan pada kesulitan dalam menentukan hidangan yang paling sesuai dengan selera dan kebutuhan spesifik merek (Syaifudin & Ardyningrum, 2024). Permasalahan ini sangat relevan di lingkungan padat seperti kampus Universitas Esa Unggul Bekasi, di mana mahasiswa membutuhkan akses cepat dan mudah ke opsi makanan yang relevan. Kehadiran berbagai penawaran makanan yang melimpah, meskipun memberikan kebebasan, justru dapat menimbulkan kebingungan dan inefisiensi dalam proses pengambilan keputusan. Oleh karena itu, diperlukan sebuah solusi inovatif berupa sistem yang dapat menyederhanakan proses pencarian makanan dan menghadirkan rekomendasi yang dipersonalisasi (Muliadi & Lestari, 2019) (Erlangga & Sutrisno, 2020).

Untuk mengatasi tantangan tersebut, penelitian ini berfokus pada pengembangan sistem rekomendasi makanan berbasis web yang dapat memprediksi dan menyajikan rekomendasi yang personal berdasarkan *input* preferensi dari pengguna. Algoritma *Random Forest Classifier* dipilih sebagai inti dari model sistem ini. Pemilihan *Random Forest* didasarkan pada kemampuannya yang terbukti dalam menangani data kompleks dan multidimensional, serta kemampuannya untuk menggabungkan kekuatan banyak pohon keputusan (*ensemble learning*) yang secara efektif mengurangi risiko *overfitting* dan meningkatkan akurasi prediksi (Forests et al., 2024) (Fuji Astari et al., 2024) (Pamuji & Ramadhan, 2021). Algoritma ini sangat cocok untuk tugas klasifikasi preferensi makanan yang melibatkan fitur tekstual dari resep. Dengan memanfaatkan berbagai atribut makanan dan preferensi pengguna yang terdefinisi, sistem ini diharapkan dapat secara signifikan mempermudah pengguna dalam menemukan makanan yang benar-benar sesuai dengan keinginan mereka.

Tujuan utama dari penelitian ini mencakup perancangan dan implementasi sistem rekomendasi makanan berbasis web yang menerapkan algoritma *Random Forest Classifier*, mengevaluasi akurasi dan efektivitas model *Random Forest* dalam menghasilkan rekomendasi yang relevan, serta mengintegrasikan berbagai atribut preferensi konsumen seperti jenis makanan, tingkat kepedasan, kebutuhan diet khusus, dan pertimbangan alergi ke dalam sistem untuk menghasilkan rekomendasi yang sangat personal. Ruang lingkup penelitian ini difokuskan pada pengembangan aplikasi web untuk rekomendasi makanan bagi mahasiswa Universitas Esa Unggul. Klasifikasi dan rekomendasi dalam sistem ini didasarkan pada tiga parameter utama: Jenis Makanan (berat/ringan), Tingkat Kepedasan (pedas/tidak pedas), dan Tipe Hidangan (berkuah/tidak berkuah). Kontribusi yang diharapkan dari penelitian ini adalah solusi praktis yang efisien dalam pemilihan makanan sehari-hari, sekaligus sumbangan ilmiah dalam bidang sistem rekomendasi dan penerapan *machine learning* untuk domain kuliner.

METODE PENELITIAN

Penelitian ini mengadopsi Metode Prototyping dalam pengembangan sistem, yang merupakan pendekatan yang sesuai untuk proyek yang berfokus pada pembuktian konsep dan pengembangan iteratif. Tahapan-tahapan yang dilakukan adalah sebagai berikut:

Metode Prototype

Pengembangan sistem rekomendasi makanan ini mengadopsi Metodologi *Prototyping* (Andini et al., 2023), sebuah pendekatan rekayasa perangkat lunak iteratif yang berfokus pada pembangunan model kerja sistem (prototipe) secara cepat dan bertahap, kemudian diperbaiki berdasarkan umpan balik pengguna. Metode *prototyping* sangat cocok untuk proyek-proyek yang memiliki kebutuhan pengguna yang belum sepenuhnya jelas atau yang mungkin berevolusi selama pengembangan, memungkinkan validasi konsep awal dan penyesuaian yang fleksibel.

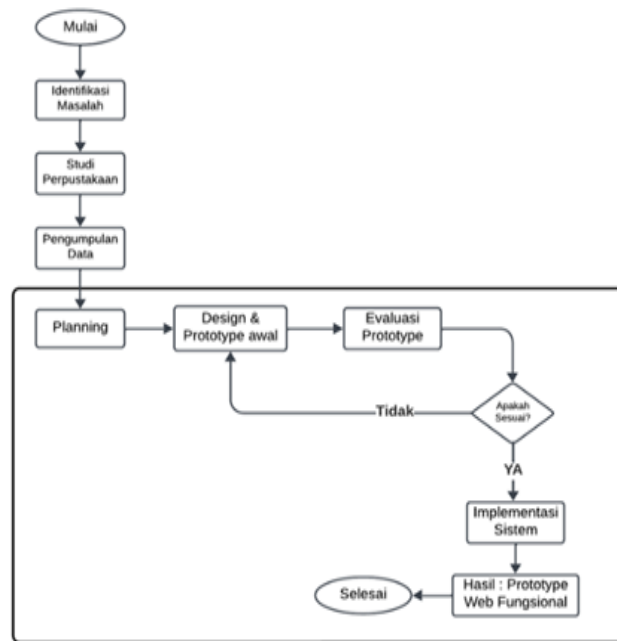


Gambar 1. Metode Prototype

Tahapan utama dalam metodologi *prototyping* yang diterapkan dalam penelitian ini meliputi:

1. **Komunikasi:** Tahap awal untuk mengidentifikasi kebutuhan fungsional dan non-fungsional sistem serta mengumpulkan preferensi pengguna melalui diskusi dan analisis awal.
2. **Perencanaan Cepat (Quick Plan):** Merancang gambaran umum sistem, termasuk fitur-fitur utama dan arsitektur, serta menentukan fungsionalitas inti yang akan dibangun pada prototipe pertama.
3. **Pemodelan/Perancangan Cepat (Quick Design):** Membuat desain awal antarmuka pengguna (UI/UX) dan struktur basis data yang akan mendukung fungsionalitas prototipe.
4. **Konstruksi Prototipe:** Mengembangkan prototipe fungsional pertama yang mencakup fitur-fitur dasar rekomendasi berdasarkan hasil perancangan cepat. Prototipe ini bersifat parsial tetapi interaktif.
5. **Penyebaran dan Umpan Balik (Deployment and Feedback):** Prototipe yang telah dibangun diuji coba oleh pengguna. Umpan balik yang diperoleh digunakan untuk mengidentifikasi kekurangan, kebutuhan tambahan, atau area perbaikan.
6. **Perbaikan Iteratif:** Melakukan modifikasi dan penyempurnaan pada prototipe berdasarkan umpan balik yang diterima. Siklus ini diulang hingga prototipe memenuhi semua kebutuhan yang disepakati dan berfungsi sesuai harapan.
7. **Pengiriman Sistem (Delivery):** Setelah prototipe final disetujui dan dianggap stabil, sistem dikembangkan menjadi produk akhir yang siap digunakan. Pendekatan ini memastikan sistem yang dihasilkan responsif terhadap kebutuhan pengguna dan berfungsi secara optimal melalui siklus perbaikan berkelanjutan, meminimalkan risiko kesalahan di tahap akhir.

Untuk memberikan gambaran alur penelitian secara keseluruhan, dapat dilihat pada kerangka berpikir berikut:



Gambar 2. Kerangka Berpikir

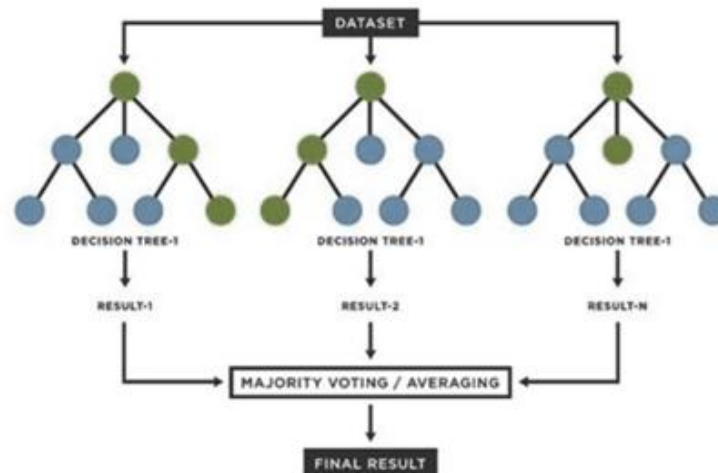
Pra-pemrosesan Data

Data resep dikumpulkan secara ekstensif dari dua sumber utama untuk memastikan cakupan dan variasi yang memadai: dataset Kaggle (berisi 14.948 entri) dan hasil *web scraping* dari platform Cookpad. Setelah akuisisi, data melalui serangkaian tahapan pra-pemrosesan yang komprehensif untuk memastikan kualitas, konsistensi, dan kesiapannya untuk pemodelan. Tahapan ini meliputi:

1. **Standarisasi Kolom:** Menyelaraskan nama dan format kolom antar dataset untuk memungkinkan penggabungan data yang mulus.
2. **Pembersihan Teks:** Melakukan pembersihan data pada kolom tekstual seperti judul, daftar bahan, dan langkah-langkah resep untuk menghilangkan karakter khusus, angka yang tidak relevan, dan *stopwords* yang tidak memberikan makna kontekstual. Ini juga melibatkan normalisasi teks ke huruf kecil.
3. **Penggabungan dan Penghapusan Duplikat:** Menggabungkan seluruh *dataframe* yang telah diproses menjadi satu dataset master. Selanjutnya, duplikasi resep diidentifikasi dan dihapus berdasarkan kombinasi unik dari judul, bahan, dan langkah-langkah untuk menghasilkan dataset yang bersih dan unik.
4. **Estimasi Nutrisi:** Melakukan perhitungan estimasi nilai nutrisi (misalnya, kalori, protein, lemak, karbohidrat) untuk setiap resep berdasarkan data bahan baku yang tersedia. Proses ini penting untuk fitur rekomendasi berbasis diet.
5. **Pelabelan Data:** Ini adalah tahap krusial di mana dataset diperkaya dengan penambahan tiga kolom label kategori sebagai target prediksi untuk model. Kolom-kolom ini adalah *jenis_makanan* (misalnya, 'makanan berat', 'makanan ringan'), *tingkat_pedas* (misalnya, 'pedas', 'tidak pedas'), dan *tipe_hidangan* (misalnya, 'berkuah', 'tidak berkuah'). Proses pelabelan ini dilakukan menggunakan fungsi klasifikasi internal yang menerapkan aturan prioritas dan sistem penilaian berbasis kata kunci yang ditemukan dalam judul dan deskripsi resep. Hasil akhir dari pra-pemrosesan adalah file CSV *resep_final_lengkap.csv* yang berisi 16.381 resep unik, bersih, lengkap dengan informasi nutrisi, dan label yang relevan.

Random Forest Classifier (RFC) Pengembangan Model

Setelah dataset yang telah diproses siap, pengembangan model inti dilakukan dengan memanfaatkan algoritma Random Forest Classifier. Random Forest merupakan metode pembelajaran *ensemble* yang membangun banyak pohon keputusan pada *subset* data dan secara acak memilih *subset* fitur pada setiap pembagian. Hasil akhir klasifikasi didasarkan pada *voting* dari semua pohon, yang mengurangi *overfitting* dan meningkatkan akurasi serta stabilitas model (Forests et al., 2024) (Fuji Astari et al., 2024) (Pamuji & Ramadhan, 2021).



Gambar 3. Random Forest Classifier

Tiga model RFC terpisah dikembangkan dan dilatih, masing-masing spesifik untuk memprediksi satu dari tiga kategori preferensi (jenis_makanan, tingkat_pedas, tipe_hidangan). Proses pengembangan model meliputi:

1. **Rekayasa Fitur:** Data tekstual kualitatif dari kolom `processed_text` (gabungan judul, bahan, dan langkah-langkah) diubah menjadi representasi numerik yang dapat dipahami oleh algoritma *machine learning*. Ini dilakukan menggunakan `TfidfVectorizer`, yang menghitung bobot TF-IDF (Term Frequency-Inverse Document Frequency) untuk setiap kata, merefleksikan signifikansi kata dalam dokumen relatif terhadap seluruh korpus.
2. **Pembagian Dataset:** Dataset yang telah direkayasa fitur kemudian dibagi menjadi set pelatihan (training set) dan set pengujian (testing set), biasanya dengan rasio 80:20 atau 70:30. Set pelatihan digunakan untuk melatih model, sementara set pengujian digunakan untuk mengevaluasi kinerja dan kemampuan generalisasi model terhadap data baru yang belum pernah dilihat.
3. **Pelatihan dan Penyimpanan Model:** Masing-masing model Random Forest Classifier dilatih menggunakan set pelatihan. Setelah proses pelatihan selesai, model yang sudah terlatih disimpan dalam format biner (misalnya, menggunakan pustaka `joblib` di Python). Penyimpanan ini memungkinkan model untuk dimuat kembali dan digunakan secara efisien dalam aplikasi web tanpa perlu melatih ulang setiap kali aplikasi dijalankan.

Implementasi Sistem

Model *Random Forest Classifier* yang telah dilatih dan disimpan diintegrasikan ke dalam aplikasi web interaktif yang dibangun menggunakan *framework* Flask, sebuah *microframework* Python yang ringan (Walingkas & Saian, 2023) (Syaiful Bahri et al., 2022). Arsitektur aplikasi dirancang untuk memastikan responsivitas dan fungsionalitas yang efisien. Tahapan implementasi utama meliputi:

1. **Pemuatan Aset Aplikasi:** Saat aplikasi web dijalankan, dataset resep yang telah diproses (`resep_final_lengkap.csv`), objek `TfidfVectorizer` yang telah dilatih, dan ketiga model Random Forest Classifier (`jenis_makanan_model.joblib`, `tingkat_pedas_model.joblib`, `tipe_hidangan_model.joblib`) dimuat ke dalam memori server. Ini meminimalkan latensi dan memungkinkan pemrosesan permintaan rekomendasi yang cepat.
2. **Logika Pemrosesan Rekomendasi:** Ketika pengguna mengajukan preferensi melalui formulir web (melalui `endpoint /recommend`), permintaan diproses melalui serangkaian langkah:
 - 1) **Penyaringan Awal:** Sistem melakukan penyaringan resep berdasarkan teks pencarian yang dimasukkan pengguna dan daftar alergi yang dipilih (filter keras), memastikan hanya resep yang relevan dan aman yang dipertimbangkan.
 - 2) **Transformasi Input:** Teks resep yang tersisa dari hasil penyaringan awal diubah menjadi vektor TF-IDF menggunakan `TfidfVectorizer` yang sama yang digunakan saat pelatihan model.
 - 3) **Prediksi Preferensi:** Vektor TF-IDF ini kemudian dimasukkan ke dalam ketiga model Random Forest Classifier untuk memprediksi probabilitas kesesuaian resep dengan

- preferensi jenis_makanan, tingkat_pedas, dan tipe_hidangan pengguna.
- 4) **Penerapan Preferensi Diet:** Preferensi diet khusus (misalnya, rendah kalori, vegetarian) diimplementasikan baik melalui *filtering* berdasarkan nilai nutrisi yang terhitung (misalnya, hanya menampilkan resep dengan 30% kalori terendah) atau melalui pencarian kata kunci langsung dalam teks resep.
 - 5) **Perhitungan Skor Rekomendasi:** Skor rekomendasi gabungan dihitung untuk setiap resep, menggabungkan probabilitas prediksi dari ketiga model RFC dengan pertimbangan preferensi diet.
 - 6) **Penyajian Hasil:** Resep kemudian diberi peringkat berdasarkan skor rekomendasi tertinggi dan disajikan kepada pengguna secara berurutan, biasanya dalam format paginasi (misalnya, 10 resep per halaman) dengan menyertakan deskripsi, gambar, dan resep singkat. Hasil dikirim dalam format JSON ke sisi klien (browser) yang kemudian ditampilkan secara dinamis menggunakan HTML, CSS, dan JavaScript untuk pengalaman pengguna yang intuitif.

HASIL DAN PEMBAHASAN

Hasil perancangan dan implementasi sistem rekomendasi makanan berbasis web, serta evaluasi komprehensif terhadap kinerja algoritma Random Forest Classifier yang diterapkan.

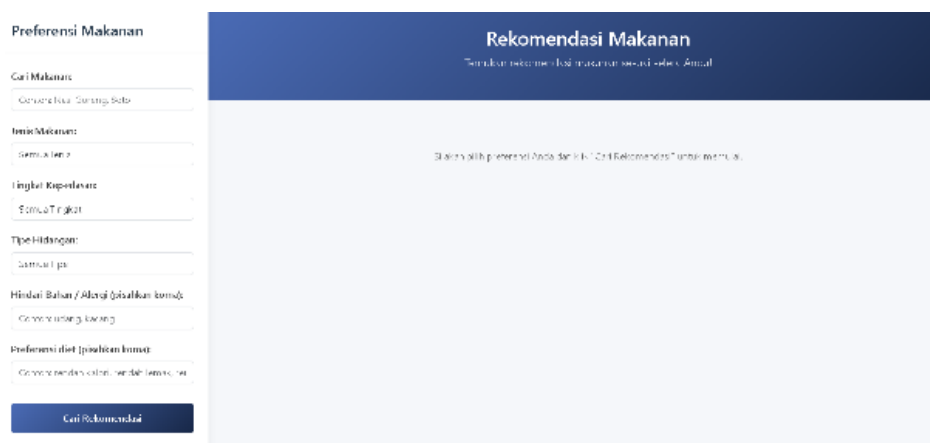
Arsitektur dan Desain Sistem

Sistem rekomendasi makanan dikembangkan sebagai aplikasi web menggunakan *framework* Python Flask, mengadopsi arsitektur *client-server* yang memungkinkan interaksi dinamis dengan pengguna (Walingkas & Saian, 2023) (Syaiful Bahri et al., 2022). Arsitektur sistem dirancang untuk mendukung alur kerja yang efisien dari input pengguna hingga penyajian rekomendasi. Secara umum, sistem terdiri dari beberapa komponen utama: Antarmuka Pengguna (UI) untuk interaksi, *server* Flask yang mengelola logika bisnis dan integrasi model, basis data resep yang telah diproses, dan model Random Forest Classifier yang telah dilatih. Ketika pengguna memasukkan preferensi, *server* akan memproses input, menjalankan model prediksi, menerapkan filter, dan mengembalikan daftar resep yang relevan.

Implementasi dan Antarmuka Pengguna

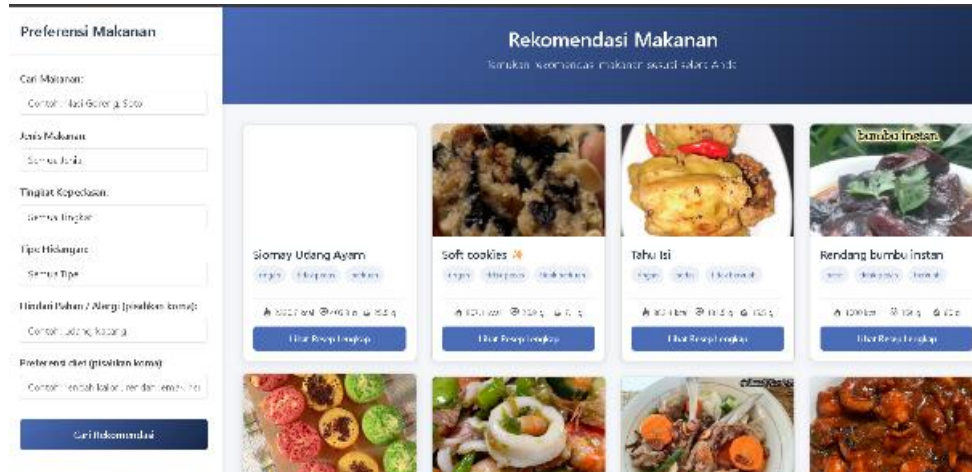
Implementasi sistem dilakukan menggunakan Python sebagai bahasa pemrograman utama, dengan Flask sebagai *web framework* (Walingkas & Saian, 2023) (Syaiful Bahri et al., 2022). Data resep yang telah bersih dan berlabel (berisi 16.381 entri) dimuat ke dalam aplikasi bersama dengan model RFC yang telah terlatih dan objek *TfidfVectorizer*. Antarmuka pengguna dirancang agar intuitif dan responsif, memungkinkan pengguna untuk berinteraksi dengan sistem secara efisien.

1. **Tampilan Antarmuka Utama (Home Page):** Pengguna disambut dengan halaman utama yang menyediakan *form* untuk memasukkan kriteria pencarian dan preferensi. Ini mencakup kolom untuk teks pencarian, pilihan untuk jenis hidangan (berat/ringan), tingkat kepedasan, tipe hidangan (berkuah/tidak berkuah), serta opsi untuk memasukkan alergi spesifik dan preferensi diet. Tampilan awal aplikasi dapat dilihat pada Gambar 4.



Gambar 4. Tampilan Awal Web

2. **Tampilan Hasil Rekomendasi:** Setelah pengguna memasukkan preferensi dan mengklik tombol "Rekomendasi", sistem akan memproses input tersebut dan menampilkan daftar resep yang paling sesuai. Hasil rekomendasi disajikan dalam format kartu atau *grid* yang ringkas, masing-masing menampilkan judul resep, gambar, dan ringkasan singkat. Halaman ini juga dilengkapi dengan fitur paginasi untuk memudahkan navigasi di antara banyak hasil. Gambar 5.



Gambar 5. Tampilan Hasil Rekomendasi

3. **Tampilan Detail Resep:** Pengguna dapat mengklik salah satu resep dari daftar rekomendasi untuk melihat detail lengkap. Halaman detail resep menyajikan informasi yang lebih komprehensif, meliputi deskripsi resep, daftar bahan-bahan secara rinci, langkah-langkah pembuatan, dan estimasi informasi nutrisi. Tampilan ini memberikan semua informasi yang dibutuhkan pengguna untuk memutuskan apakah akan mencoba resep tersebut. Gambar 6.



Gambar 6. Tampilan Detail Resep

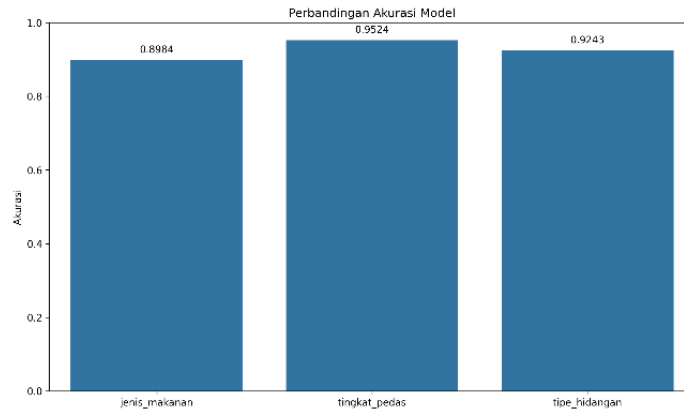
Evaluasi Kinerja Random Forest Classifier

Evaluasi kinerja algoritma Random Forest Classifier merupakan aspek krusial untuk memastikan akurasi sistem rekomendasi. Dataset resep yang telah diproses dibagi menjadi set pelatihan dan pengujian. Model dilatih pada set pelatihan dan dievaluasi pada set pengujian untuk mengukur kemampuan generalisasinya. Akurasi model diukur untuk setiap kategori preferensi yang diprediksi oleh Random Forest Classifier.

Hasil pengujian menunjukkan kinerja model yang kuat untuk ketiga kategori klasifikasi.

1. Akurasi model untuk prediksi **Jenis Makanan** adalah **89.84%**.
2. Akurasi model untuk prediksi **Tingkat Pedas** adalah **95.24%**.
3. Akurasi model untuk prediksi **Tipe Hidangan** adalah **92.43%**.

Angka akurasi ini menunjukkan bahwa model Random Forest Classifier memiliki kemampuan yang sangat baik dalam memprediksi kategori resep berdasarkan fitur yang diekstraksi dari teks. Visualisasi akurasi keseluruhan dapat dilihat pada Gambar 7.

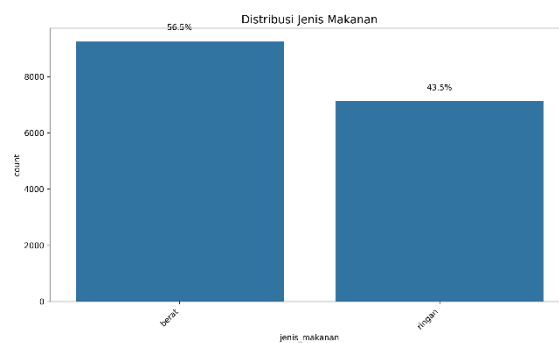


Gambar 7. Akurasi Model

Untuk analisis lebih mendalam, kami memeriksa *confusion matrix* dan distribusi kelas untuk setiap model:

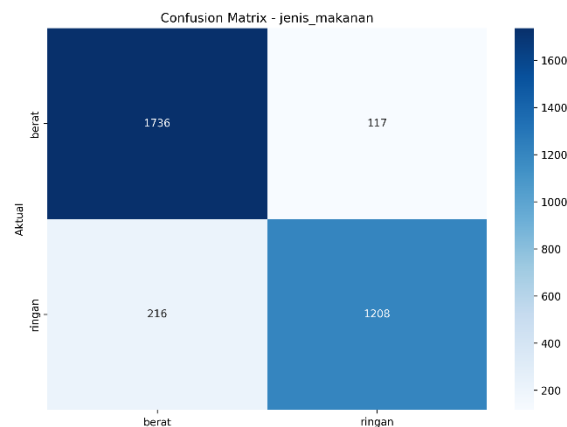
1. **Jenis Makanan:**

- 1) Distribusi data untuk kategori jenis makanan dapat dilihat pada **Gambar 8 Distribusi Kelas Jenis Makanan**.



Gambar 8. Distribusi Kelas Jenis Makanan

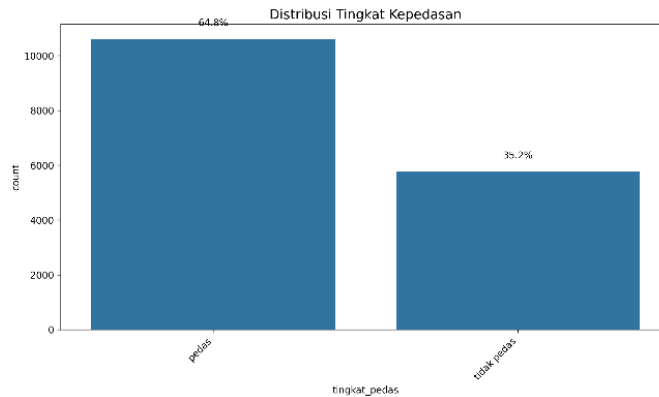
- 2) *Confusion Matrix* untuk klasifikasi jenis makanan (Lihat **Gambar 9 Confusion Matrix Jenis Makanan**) menunjukkan jumlah *true positives* (resep berat yang diprediksi berat, dan resep ringan yang diprediksi ringan) yang tinggi, serta *false positives* dan *false negatives* yang relatif rendah. Model menunjukkan kemampuan yang kuat dalam membedakan kedua jenis ini, meskipun terdapat beberapa misklasifikasi pada kasus-kasus ambigu yang mungkin memiliki karakteristik lintas kategori.



Gambar 9. Confusion Matrix Jenis Makanan

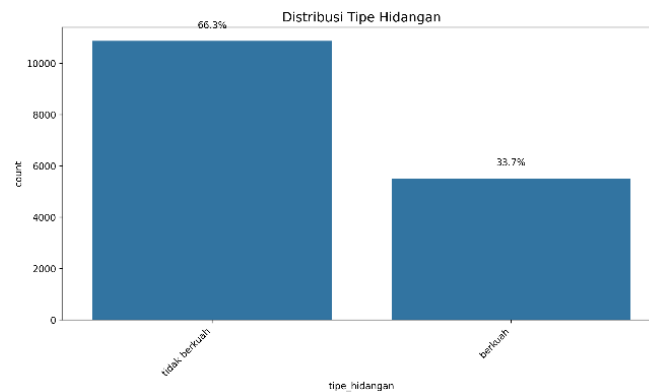
2. **Tingkat Pedas:**

- 1) Distribusi kelas untuk tingkat pedas disajikan pada **Gambar 10 Distribusi Kelas Tingkat Pedas**.



Gambar 10. Distribusi Kelas Tingkat Pedas

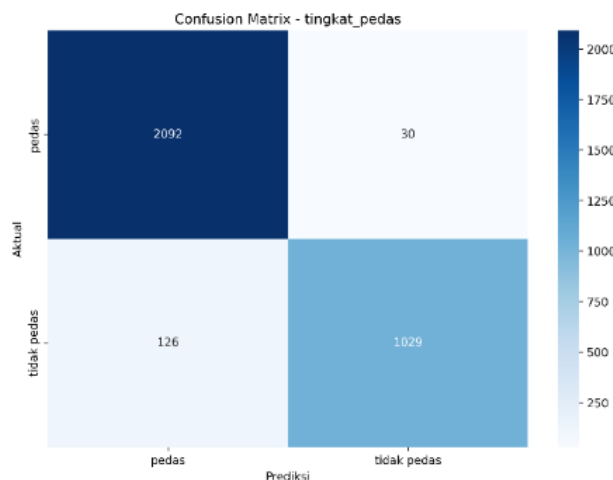
- 2) Dengan akurasi tertinggi sebesar 95.24%, *confusion matrix* untuk tingkat pedas (Lihat **Gambar 11 Confusion Matrix Tingkat Pedas**) mengonfirmasi bahwa model sangat efektif dalam mengidentifikasi karakteristik yang menunjukkan kepedasan sebuah resep. Jumlah prediksi yang benar sangat dominan dibandingkan kesalahan klasifikasi, menunjukkan bahwa fitur-fitur tekstual yang berkaitan dengan kata kunci pedas sangat kuat dan mudah dikenali oleh model.



Gambar 11. Confusion Matrix Tingkat Pedas

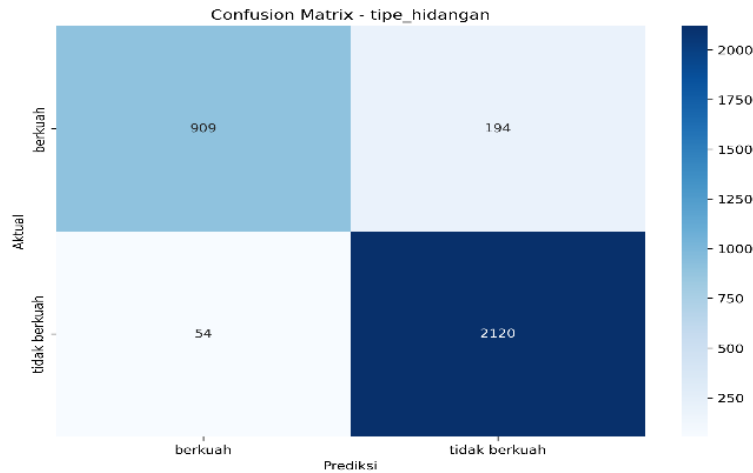
3. **Tipe Hidangan:**

- 1) Analisis distribusi data untuk tipe hidangan dapat dilihat pada **Gambar 12 Distribusi Kelas Tipe Hidangan**.



Gambar 12. Distribusi Kelas Tipe Hidangan

- 2) Model untuk tipe hidangan (berkuah/tidak berkuah) mencapai akurasi 92.43%. *Confusion matrix* terkait (Lihat **Gambar 13 Confusion Matrix Tipe Hidangan**) menunjukkan kinerja model yang sangat baik dalam mengidentifikasi karakteristik "kuah" atau "tidak berkuah" dalam resep, dengan jumlah *false positives* dan *false negatives* yang sangat rendah, mengindikasikan kemampuan model untuk membedakan secara akurat antara kedua kelas tersebut.



Gambar 13. Confusion Matrix Tipe Hidangan

Secara keseluruhan, matrix akurasi yang tinggi untuk ketiga model menunjukkan bahwa fitur rekayasa dari *TfidfVectorizer* efektif dalam menangkap informasi penting dari teks resep, dan *Random Forest Classifier* berhasil memanfaatkan fitur-fitur tersebut untuk klasifikasi yang akurat.

KESIMPULAN

Penelitian ini bertujuan untuk mengembangkan sistem rekomendasi makanan berbasis web menggunakan algoritma *Random Forest Classifier* berdasarkan preferensi konsumen di Universitas Esa Unggul Bekasi. Berdasarkan hasil dan analisis yang telah dilakukan, dapat disimpulkan bahwa tujuan penelitian telah tercapai dengan sukses.

Sistem rekomendasi makanan berbasis web telah berhasil diimplementasikan, menyediakan antarmuka yang intuitif bagi pengguna untuk memasukkan preferensi makanan (jenis makanan, tingkat kepedasan, tipe hidangan), batasan alergi, dan kebutuhan diet. Pemilihan metodologi *prototyping* terbukti efektif dalam memandu pengembangan sistem melalui siklus iteratif, memastikan sistem yang dihasilkan responsif terhadap kebutuhan pengguna.

Penggunaan algoritma *Random Forest Classifier* sebagai inti model klasifikasi menunjukkan kinerja yang sangat memuaskan. Hasil evaluasi model menunjukkan akurasi tinggi untuk ketiga kategori prediksi, yaitu 89.84% untuk Jenis Makanan, 95.24% untuk Tingkat Pedas, dan 92.43% untuk Tipe Hidangan. Akurasi yang konsisten dan tinggi ini menegaskan kemampuan algoritma dalam mempelajari pola kompleks dari data resep dan memberikan prediksi yang tepat, yang secara langsung berkontribusi pada relevansi dan personalisasi rekomendasi yang dihasilkan sistem. Integrasi fitur penyaringan alergi dan preferensi diet juga berhasil meningkatkan fungsionalitas dan keamanan sistem.

UCAPAN TERIMA KASIH

Penulis ingin menyampaikan rasa terima kasih yang sebesar-besarnya atas kontribusi dan dukungan yang tak ternilai selama pelaksanaan penelitian ini. Apresiasi yang tulus ditujukan kepada kedua orang tua dan seluruh keluarga atas cinta, doa, serta dukungan moral dan materiil yang tak pernah putus, yang menjadi pilar kekuatan utama.

Terima kasih juga disampaikan kepada **Iksan Ramadhan, S.Kom, M.K**, atas bimbingan, arahan, dan masukan yang berharga selama seluruh proses penelitian dan penulisan tugas akhir ini. Secara khusus, penulis juga mengucapkan terima kasih kepada **Farhanah Andika Putri** atas pengertian, dukungan, kesabaran, dan motivasi yang tak henti-hentinya.

Selain itu, penulis menyampaikan rasa terima kasih kepada saudara dan sahabat terbaik atas kebersamaan, semangat, dan dukungan yang selalu ada di setiap suka dan duka. Dukungan mereka telah menjadi bagian penting dari perjalanan ini. Akhir kata, ucapan terima kasih juga

diberikan kepada **Universitas Esa Unggul Bekasi** atas fasilitas dan lingkungan akademik yang sangat mendukung terlaksananya penelitian ini.

REFERENSI

- Andini, N., Taufiq, R., Priyanggodo, D. Y., & Sugiyani, Y. (2023). Penggunaan Metode Prototype Pada Pengembangan Sistem Informasi Imunisasi Posyandu. *JIKA (Jurnal Informatika)*, 7(4), 431. <https://doi.org/10.31000/jika.v7i4.9329>
- Erlangga, E., & Sutrisno, H. (2020). Sistem Rekomendasi Beauty Shop Berbasis Collaborative Filtering. *EXPERT: Jurnal Manajemen Sistem Informasi Dan Teknologi*, 10(2), 47. <https://doi.org/10.36448/jmsit.v10i2.1611>
- Forests, P. M. R., Decision-making, A., Batutin, A., Data, U., Platform, M., Education, A. I., Forests, R., Learning, M., & Decision-making, A. (2024). *Random Forests in Machine Learning for Advanced Decision-Making What is a Random Forest? Key Components of Random Forests How Random Forests Work*. 1–7.
- Fuji Astari, D., Ridwan, R., & Melina, M. (2024). Klasifikasi Tingkat Stres Saat Tidur Menggunakan Algoritma Random Forest. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(5), 3676–3684. <https://doi.org/10.36040/jati.v7i5.7750>
- Muliadi, K. H., & Lestari, C. C. (2019). Rancang Bangun Sistem Rekomendasi Tempat Makan Menggunakan Algoritma Typicality Based Collaborative Filtering. *Techno.Com*, 18(4), 275–287. <https://doi.org/10.33633/tc.v18i4.2515>
- Pamuji, F. Y., & Ramadhan, V. P. (2021). Komparasi Algoritma Random Forest dan Decision Tree untuk Memprediksi Keberhasilan Immunotherapy. *Jurnal Teknologi Dan Manajemen Informatika*, 7(1), 46–50. <https://doi.org/10.26905/jtmi.v7i1.5982>
- Syaifudin, Y. W., & Ardyningrum, N. A. (2024). Penggunaan Metode Analisis Data Untuk Rekomendasi Menu Makanan Berdasarkan Persediaan Bahan dan Preferensi Pengguna. *INFORMAL: Informatics Journal*, 9(1), 57. <https://doi.org/10.19184/isj.v9i1.43263>
- Syaiful Bahri, M. N., Danan Jaya, I. P. Y., Dirgantoro, B., Mal, I., Ahmad, U. A., & Septiawan, R. R. (2022). Implementasi Sistem Rekomendasi Makanan pada Aplikasi EatAja Menggunakan Algoritma Collaborative Filtering. *Multinetics*, 7(2), 177–185. <https://doi.org/10.32722/multinetics.v7i2.4062>
- Walingkas, H. L., & Saian, P. O. N. (2023). Penerapan Framework Flask pada Pembangunan Sistem Informasi Pemasok Barang. *Jurnal JTik (Jurnal Teknologi Informasi Dan Komunikasi)*, 7(2). <https://doi.org/10.35870/jtik.v7i2.729>