



ANALISIS KOMPARATIF MODEL KLASIFIKASI KEBUGARAN DAN EVALUASI REGRESI PREDIKSI KALORI DAN CHATBOT PADA EKOSISTEM FITTRACK AI

Putra Hikmah Febryan ^{a*}, Eka Asa Setyaning Pratiwi ^b, Asif Faruqi ^c, Dhian Satria Yudha Kartika ^d

^a Fakultas Ilmu Komputer / Sistem Informasi; 23082010173@student.upnjatim.ac.id, UPN “Veteran” Jawa Timur; Jl. Rungkut Madya, Gn. Anyar, Kec. Gn. Anyar, Surabaya, Jawa Timur

^b Fakultas Ilmu Komputer / Sistem Informasi; 23082010113@student.upnjatim.ac.id, UPN “Veteran” Jawa Timur; Jl. Rungkut Madya, Gn. Anyar, Kec. Gn. Anyar, Surabaya, Jawa Timur

^c Fakultas Ilmu Komputer / Sistem Informasi; asiffarوقي.si@upnjatim.ac.id, UPN “Veteran” Jawa Timur; Jl. Rungkut Madya, Gn. Anyar, Kec. Gn. Anyar, Surabaya, Jawa Timur

^d Fakultas Ilmu Komputer / Bisnis Digital; dhian.satria@upnjatim.ac.id, UPN “Veteran” Jawa Timur; Jl. Rungkut Madya, Gn. Anyar, Kec. Gn. Anyar, Surabaya, Jawa Timur

* Penulis Korespondensi: Putra Hikmah Febryan

ABSTRACT

Interpreting physiological health data and self-reported nutrition records often poses a computational challenge for non-expert users. Therefore, this study aims to conduct a comparative analysis of fitness level classification modeling and predictive calorie regression evaluation. Both are integrated into a unified health tracking ecosystem called FitTrack AI. The performance of the Random Forest, XGBoost, and Support Vector Machine (SVM) algorithms was comprehensively compared for multi-class classification. Meanwhile, calorie burn estimates were evaluated using the Random Forest Regressor. As a holistic system, this ecosystem is also supported by body weight projection analysis (Linear Regression), dietary pattern mining (Apriori), and an automated logging interface based on a Large Language Model (Groq API). Test results show that XGBoost is the best classification model, with an accuracy rate of 76.37%, outperforming other algorithms. In the calorie prediction regression test, the model achieved highly accurate performance with a coefficient of determination (R^2) of 0.996. In terms of ecosystem functionality, the interactive virtual assistant (FitBot) recorded a 90.0% success rate in executing tool calls for data entry and achieved a System Usability Scale (SUS) score of 90.1 (Very Good category). Overall, this multi-model analytical approach has proven to be robust and effective in translating the complexity of biological data into comprehensive and personalized digital health insights.

Keywords: *fitness classification; calorie prediction; machine learning; association rule mining; health chatbot; large language model; wearable technology*

Abstrak

Pengguna awam sering menghadapi tantangan komputasional dalam menginterpretasi data kesehatan fisiologis dan mencatat nutrisi secara mandiri. Oleh karena itu, penelitian ini bertujuan untuk melakukan analisis komparatif pemodelan klasifikasi tingkat kebugaran dan evaluasi regresi prediksi kalori. Kedua model tersebut kemudian diintegrasikan ke dalam sebuah ekosistem pelacak kesehatan terpadu, yaitu FitTrack AI. Kinerja algoritma Random Forest, XGBoost, dan Support Vector Machine (SVM) dibandingkan secara komprehensif untuk klasifikasi multi-kelas. Sementara itu, estimasi pembakaran kalori dievaluasi menggunakan Random Forest Regressor. Sebagai sistem yang holistik, ekosistem ini juga didukung oleh analisis proyeksi berat badan (Regresi Linier), penambangan pola makan (Apriori), serta antarmuka pencatatan otomatis berbasis *Large Language Model* (Groq API). Hasil pengujian membuktikan bahwa XGBoost merupakan model klasifikasi terbaik dengan tingkat akurasi mencapai 76,37%, mengungguli algoritma lainnya. Pada pengujian regresi prediksi kalori, pemodelan mencapai performa yang sangat presisi dengan nilai koefisien determinasi (R^2) sebesar 0,996. Dari sisi fungsionalitas ekosistem, asisten virtual interaktif (FitBot) mencatatkan tingkat keberhasilan eksekusi *tool calling* sebesar 90,0% untuk entri data,

serta meraih skor *System Usability Scale* (SUS) sebesar 90,1 (kategori Sangat Baik). Secara keseluruhan, pendekatan analitik multi model ini terbukti tangguh dan efektif dalam menjembatani kompleksitas data biologis menjadi wawasan kesehatan digital yang komprehensif dan terpersonalisasi.

Kata Kunci: klasifikasi kebugaran; prediksi kalori; machine learning; association rule mining; large language model; chatbot kesehatan; asisten virtual

1. PENDAHULUAN

Gaya hidup yang tidak aktif dan pola makan yang tidak terkendali merupakan dua faktor risiko utama yang berkontribusi terhadap meningkatnya prevalensi penyakit tidak menular, seperti obesitas, diabetes tipe 2, dan penyakit kardiovaskular. Organisasi Kesehatan Dunia, seperti *World Health Organization* (WHO), secara tegas menganjurkan pemantauan aktivitas fisik rutin dan pengaturan asupan kalori sebagai langkah-langkah pencegahan yang krusial [16]. Meskipun standar kesehatan ini telah ditetapkan secara global, penerapan yang efektif pada tingkat individu seringkali masih kurang memadai. Tantangan utama yang menghalangi penerapan kebiasaan ini adalah kurangnya konsistensi pengguna dalam mencatat data harian mereka secara mandiri. Kurangnya pemahaman masyarakat umum dalam menafsirkan data biologis mereka merupakan kendala fungsional yang signifikan.

Berbagai aplikasi pelacakan kebugaran komersial saat ini telah banyak tersedia di pasaran, namun sebagian besar platform tersebut masih berfokus secara eksklusif pada satu aspek. Misalnya, aplikasi seperti MyFitnessPal terutama berfokus pada pemantauan asupan kalori [17], sedangkan platform seperti Strava berfokus untuk melacak aktivitas fisik pengguna [18]. Pemisahan fungsionalitas ini mengakibatkan kurangnya integrasi yang terpadu antara analitik prediktif dan rekomendasi kesehatan yang dipersonalisasi dalam satu ekosistem yang terpadu. Antarmuka pencatatan manual yang kaku dalam aplikasi-aplikasi ini dapat menghambat keterlibatan jangka panjang, terutama bagi pengguna yang belum berpengalaman dan menginginkan kemudahan.

Meskipun model prediktif dan agen percakapan telah dikembangkan untuk mengatasi berbagai masalah teknologi, sebagian besar penelitian sebelumnya telah menganalisis kedua bidang teknologi ini secara terpisah [10], [19]. Terdapat kekosongan yang signifikan dalam penelitian mengenai penggabungan analisis prediktif fisiologis dan antarmuka pencatatan berbasis *Large Language Model* (LLM) ke dalam sebuah ekosistem yang terpadu. Penelitian saat ini sebagian besar berfokus pada evaluasi algoritma *machine learning* untuk mengidentifikasi metrik kebugaran tanpa menyertakan fitur interaksi pengguna yang adaptif [19]. Di sisi lain, penelitian mengenai agen percakapan kesehatan sering kali mengabaikan evaluasi kinerja yang sebanding dari algoritma prediksi yang secara langsung menganalisis data fisiologis [10]. Oleh karena itu, kajian komprehensif yang membandingkan keefektifan berbagai model analitik dalam konteks platform pelacakan mandiri yang didukung oleh asisten virtual masih sangat terbatas.

Untuk menjembatani kesenjangan penelitian ini, penelitian ini mengembangkan FitTrack AI, sebuah aplikasi berbasis web untuk pelacakan kebugaran dan nutrisi. Keunikan eksplisit dari penelitian ini terletak pada pendekatan metodologis yang mengintegrasikan berbagai analitik kesehatan secara komprehensif. Secara spesifik, sistem ini mengintegrasikan empat komponen analitis yang berbeda, seperti klasifikasi tingkat kebugaran, prediksi kalori, prediksi tren berat badan, dan penjelajahan pola diet yang dikendalikan oleh asisten virtual berbasis LLM interaktif yang dilengkapi dengan fitur memanggil alat (*tool calling*). Berdasarkan perancangan ekosistem terpadu tersebut, kontribusi utama dari penelitian ini meliputi:

1. Perbandingan kinerja tiga algoritma klasifikasi (Random Forest, XGBoost, SVM) untuk klasifikasi tingkat kebugaran multi-kelas. Kontribusi ini penting dalam ekosistem kesehatan digital karena evaluasi algoritma yang presisi memastikan sistem mampu memberikan rekomendasi adaptif yang sangat terpersonalisasi sesuai kondisi fisik pengguna [19].
2. Implementasi model regresi untuk memprediksi kalori yang terbakar berdasarkan variabel fisiologis *real-time*. Kemampuan prediksi ini esensial bagi pengembangan teknologi kesehatan karena mampu menyajikan umpan balik secara instan, yang terbukti krusial untuk mempertahankan motivasi dan intervensi gaya hidup secara dinamis [20].
3. Integrasi asisten AI dengan kemampuan memanggil alat (*tool calling*) untuk pencatatan data melalui percakapan dalam satu sistem yang terpadu. Integrasi percakapan otomatis ini secara signifikan menurunkan hambatan teknis dan kelelahan pencatatan (*user fatigue*), sehingga menjamin keterlibatan dan konsistensi entri data kesehatan jangka panjang bagi pengguna awam [10].

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Kemajuan dalam teknologi *Machine Learning* (ML) dan *Large Language Model* (LLM) membuka peluang untuk mengatasi tantangan-tantangan dalam pemantauan kesehatan dan kebugaran. Berbagai algoritma komputasi dan agen kecerdasan buatan telah dieksplorasi secara ekstensif dalam penelitian terdahulu untuk memaksimalkan analisis data fisiologis dan pola kebiasaan pengguna. Integrasi kedua teknologi ini diharapkan dapat mendorong strategi pencegahan yang lebih disesuaikan dan adaptif, yang dirancang khusus sesuai gaya hidup masing-masing individu. Oleh karena itu, tinjauan terhadap penelitian-penelitian sebelumnya sangat penting untuk mengevaluasi kemampuan teknologi yang ada dan mengidentifikasi kekurangan fungsional yang memerlukan pengembangan lebih lanjut.

Dalam konteks pemodelan prediktif untuk kesehatan, algoritma klasifikasi *ensemble* seperti Random Forest, XGBoost, dan Support Vector Machine (SVM) telah banyak digunakan. Penelitian oleh Hamid dan Subhiyakti (2025) menunjukkan bahwa kombinasi algoritma Random Forest, SVM, dan XGBoost yang dioptimalkan dengan SMOTE mampu menghasilkan performa klasifikasi yang sangat baik dalam memprediksi status kesehatan fisiologis [1]. Keandalan model *ensemble* ini juga dibuktikan oleh Devi et al. (2025) yang berhasil mengimplementasikan model hibrida XGBoost dan Random Forest untuk memprediksi kalori secara akurat berdasarkan berbagai variabel fisik [2]. Penerapan teknik komputasi ini telah menunjukkan keefektifan yang signifikan dalam mengelola dataset medis dan fisiologis yang memiliki dimensi tinggi dan variansi yang besar. Evaluasi yang konsisten dari berbagai penelitian menegaskan bahwa algoritma-algoritma ini sangat relevan untuk diintegrasikan sebagai mesin analitis dasar dalam platform kesehatan digital.

Demikian pula untuk analisis nutrisi, algoritma penambangan data (*data mining*) telah terbukti efektif dalam mengungkap pola asosiasi. Merliani et al. (2022) menerapkan algoritma Apriori untuk merekomendasikan menu makanan dan minuman berdasarkan pola transaksi sebelumnya [3]. Pendekatan serupa juga divalidasi oleh Jantan et al. (2024), yang menggunakan metode FP-Growth untuk menganalisis preferensi makanan secara mendalam [4].

Di sisi lain, kemunculan *Large Language Model* (LLM) dengan kemampuan memanggil alat atau fungsi (*tool calling*) telah membawa paradigma baru. Sebuah tinjauan sistematis oleh Oh et al. (2021) menyoroti bahwa *chatbot* AI memiliki efektivitas yang tinggi dalam mempromosikan aktivitas fisik dan pola makan sehat [5]. Kemampuan ini semakin valid dengan temuan Thirunavukarasu et al. (2023), yang menegaskan bahwa LLM memiliki potensi transformatif dalam memproses data medis dan kesehatan yang kompleks, asalkan diintegrasikan dengan sistem yang terawasi [10].

Kemampuan analitis AI ini semakin canggih ketika agen AI tidak hanya memberikan jawaban teks secara pasif, tetapi mampu melakukan personalisasi interaksi [6] dan memanggil fungsi eksternal. Yao et al. (2023) melalui kerangka kerja React membuktikan bahwa LLM yang menggabungkan kemampuan penalaran (*reasoning*) dan tindakan (*acting/tool calling*) dapat mengeksekusi tugas tugas *backend* secara dinamis dan akurat [11]. Integrasi antarmuka berbasis *chatbot* ini juga terbukti secara signifikan meningkatkan keterlibatan pengguna melalui pendekatan *neural network* [7].

Meskipun model prediktif dan agen percakapan telah terbukti efektif pada masing-masing domainnya, belum banyak penelitian yang mengintegrasikan analitik prediktif fisiologis dengan pencatatan percakapan berbasis LLM secara komprehensif dalam satu ekosistem web yang terpadu. Arsitektur aplikasi berbasis web telah terbukti secara empiris sebagai alat yang efisien dan mudah diakses untuk memfasilitasi intervensi kesehatan berbasis pemantauan mandiri di kalangan masyarakat umum tanpa memerlukan instalasi tambahan [21]. Penelitian ini secara langsung mengatasi kesenjangan yang ada dalam literatur dengan mengembangkan FitTrack AI, sebuah sistem yang menggabungkan kemudahan input data melalui percakapan dengan keandalan *machine learning* untuk memberikan umpan balik seketika. Integrasi fungsional multi-model ini menjamin bahwa data aktivitas sehari-hari yang dikumpulkan secara alami dapat langsung diproses menjadi wawasan prediktif secara instan. Pendekatan holistik berbasis web ini pada akhirnya memelopori inovasi sistem digital terpadu yang sangat efektif untuk menekan angka kelelahan pengguna (*user fatigue*) secara jangka panjang.

2.2. Landasan Teori

2.2.1. Algoritma Klasifikasi dan Regresi

Pengolahan data fisiologis dalam sistem ini bertumpu pada algoritma pembelajaran mesin. Random Forest dan XGBoost merupakan metode *ensemble* berbasis pohon keputusan, namun keduanya memiliki perbedaan mendasar. Random Forest membangun pohon secara independen melalui teknik *bagging*, sedangkan XGBoost membangunnya secara sekuensial untuk memperbaiki kesalahan dari model sebelumnya melalui teknik *boosting* [22]. Meskipun prosesnya berbeda, kedua algoritma tersebut menunjukkan ketahanan yang signifikan terhadap *overfitting*, karena ketahanan ini berasal dari agregasi prediksi secara bersamaan dari banyak pohon, bukan ketergantungan pada satu pohon saja. Sementara itu, algoritma *Support Vector Machine* (SVM) bekerja dengan mencari *hyperplane* optimal untuk memisahkan kelas data. Ketiga algoritma ini akan dievaluasi kinerjanya untuk menentukan klasifikasi tingkat kebugaran terbaik. Selain itu, pendekatan regresi digunakan untuk memprediksi keluaran numerik kontinu, seperti estimasi kalori yang terbakar secara *real-time*.

Implementasi algoritma *ensemble* terbukti sangat efektif dalam domain informatika kesehatan karena kemampuannya mengekstraksi pola dari dataset fisiologis yang kompleks dan sering kali memiliki distribusi kelas yang tidak seimbang. Penelitian sebelumnya membuktikan bahwa metode seperti XGBoost dan Random Forest secara konsisten mengungguli model klasifikasi tradisional dalam memprediksi status kesehatan seperti identifikasi kondisi tubuh dengan metrik akurasi yang tinggi [1]. Di samping itu, penerapan metode regresi ensemble untuk memprediksi estimasi kalori terbakar juga memberikan tingkat presisi yang superior, karena algoritma ini mampu memetakan interaksi non-linear yang kompleks antara durasi latihan, detak jantung rata-rata, dan karakteristik metrik tubuh pengguna secara holistik [2].

2.2.2. Association Rule Mining

Untuk memproses data pencatatan nutrisi, algoritma Apriori digunakan untuk menemukan aturan asosiasi (*association rules*) antara berbagai jenis makanan yang dikonsumsi pengguna. Algoritma ini beroperasi dengan mengidentifikasi kelompok item yang secara rutin muncul bersamaan dalam riwayat pola makan harian pengguna (*frequent itemsets*) di dalam basis data. Metode komputasi ini secara sistematis menyaring kombinasi makanan yang tidak melampaui ambang batas minimum, sehingga hanya menyisakan pola-pola yang signifikan secara statistik [23]. Kumpulan data yang telah tervalidasi ini kemudian dianalisis lebih lanjut untuk menghasilkan representasi pola diet (*dietary patterns*) yang nyata dan terukur.

Hasil penemuan aturan asosiasi ini memiliki nilai praktis yang sangat tinggi untuk mendukung pengambilan keputusan terkait asupan gizi pengguna. Sebagai contoh aplikasi praktisnya, jika sistem mengidentifikasi aturan asosiasi yang kuat bahwa konsumsi karbohidrat tinggi, seperti nasi goreng atau rawon, seringkali tidak disertai dengan asupan serat pelengkap, sistem dapat segera merancang notifikasi intervensi gizi. Melalui evaluasi metrik support, confidence, dan lift, sistem dapat merekomendasikan kombinasi menu makanan tambahan yang lebih sehat secara otomatis atau mendeteksi pola konsumsi nutrisi yang kurang seimbang [3]. Penerapan metode *association rule mining* semacam ini telah terbukti sukses diimplementasikan dalam berbagai penelitian analitik preferensi makanan, yang mana sistem bergeser dari sekadar pencatat riwayat pasif menjadi mesin pemberi wawasan (*insight engine*) yang adaptif terhadap profil kebiasaan diet masing-masing individu [4].

2.2.3. Large Language Models (LLM) dan tool calling

Large Language Model (LLM) memungkinkan pengembangan agen percakapan yang memahami konteks bahasa alami. Kemampuan *tool calling* mengubah LLM dari sekadar generator teks menjadi agen eksekutor. LLM dapat menerjemahkan pesan tidak terstruktur dari pengguna menjadi parameter JSON yang terstruktur, lalu secara otomatis memanggil fungsi *backend* (API) untuk menyimpannya ke dalam basis data. Infrastruktur API modern yang menawarkan pemrosesan inferensi berkecepatan tinggi, seperti Groq API, menjadi pilihan utama karena arsitekturnya telah terbukti memiliki kecepatan dan stabilitas yang unggul dalam memproses inferensi token dibandingkan dengan infrastruktur komputasi awan konvensional [24]. Latensi yang sangat rendah ini sangat penting untuk eksekusi algoritma secara instan, sehingga menjamin bahwa respons asisten virtual berjalan lancar dan tidak memutus momentum interaksi pengguna.

Integrasi fungsionalitas asisten percakapan berbasis kecerdasan buatan ini dirancang untuk mengatasi kendala retensi pengguna yang kerap terjadi pada aplikasi kesehatan yang masih menggunakan antarmuka formulir manual yang kaku. Pendekatan interaksi konversasional yang natural dan dipersonalisasi telah diakui dalam berbagai studi sistematis mampu meningkatkan keterlibatan (*engagement*) pengguna dalam

mempertahankan rutinitas kebugaran dan program penurunan berat badan [5], [7]. Dengan arsitektur yang andal dan kapabilitas pemanggilan fungsi (*tool calling*) yang presisi, *chatbot* asisten kesehatan ini dapat memberikan layanan pendampingan yang proaktif, aman, dan memfasilitasi komunikasi dua arah yang praktis antara pengguna dan sistem basis data [6].

2.2.4. Metrik Evaluasi Model *Machine Learning*

Kinerja model klasifikasi dievaluasi menggunakan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Sementara itu, untuk model regresi, evaluasi dilakukan menggunakan *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan Koefisien Determinasi (R^2). Dua metrik utama untuk regresi didefinisikan melalui persamaan berikut:

1. *Root Mean Squared Error* (RMSE): Metrik yang mengukur akar kuadrat dari rata rata selisih kuadrat antara nilai prediksi (y_i) dan nilai aktual (y_i).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (1)$$

2. Koefisien Determinasi (R^2): R^2 merepresentasikan proporsi varians dari variabel dependen yang dapat diprediksi dari variabel independen, di mana $\bar{y}$ adalah rata rata dari data yang diamati.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2)$$

2.2.5. Penambahan Pola Konsumsi Makanan (Algoritma Apriori)

Dalam analisis pola asosiasi menggunakan algoritma Apriori, selain menetapkan ambang batas *support* dan *confidence*, kekuatan aturan asosiasi dievaluasi menggunakan metrik *Lift*. Nilai *Lift* yang lebih besar dari 1 menunjukkan hubungan positif yang kuat antar item. Perhitungan *Lift* dirumuskan sebagai berikut:

$$Lift(A \rightarrow B) = \frac{Confidence(A \rightarrow B)}{Support(B)} \quad (3)$$

2.2.6. Pengembangan Sistem Berbasis Web dan Arsitektur Basis Data

FitTrack AI dibangun sebagai aplikasi berbasis web interaktif menggunakan kerangka kerja (*framework*) Streamlit yang sepenuhnya berbasis bahasa pemrograman Python. Streamlit dirancang secara khusus untuk memfasilitasi siklus pengembangan aplikasi *machine learning* dan *data science* secara terpadu dan efisien. Penggunaan kerangka kerja ini memungkinkan integrasi yang mulus antara logika komputasi *backend* (seperti algoritma prediktif dan *reasoning* dari LLM) dengan antarmuka pengguna *frontend*, tanpa memerlukan arsitektur pengembangan web tradisional yang terpisah [12].

Ekosistem *pure Python* ini sangat ideal untuk memproses data fisiologis dan menjalankan model prediktif secara *real time*. Selain itu, arsitektur sistem ini terhubung secara langsung dengan basis data relasional memanfaatkan SQLite untuk lingkungan pengembangan dan MySQL untuk lingkungan produksi guna memastikan bahwa riwayat aktivitas, log makanan, dan metrik kebugaran pengguna tersimpan dengan aman dan terstruktur.


3. METODOLOGI PENELITIAN

3.1. Desain dan Arsitektur Sistem

FitTrack AI dikembangkan sebagai aplikasi berbasis web menggunakan kerangka kerja Streamlit dan bahasa pemrograman Python. Sistem ini dirancang secara modular dengan lima komponen utama, yaitu *app.py* untuk kontrol antarmuka dan routing, *chatbot.py* untuk mengintegrasikan asisten virtual berbasis Groq API, *database.py* untuk manajemen basis data, *models.py* untuk pelatihan dan inferensi model *machine learning*, dan *mining.py* untuk implementasi algoritma Apriori. Basis data dirancang untuk mendukung dua skema penyimpanan, yaitu SQLite untuk lingkungan pengembangan lokal dan MySQL untuk lingkungan produksi, dengan lima tabel utama, seperti *users*, *food_log*, *activity_log*, *weight_progress*, dan *chat_history*.

Analisis Komparatif Model Klasifikasi Kebugaran dan Evaluasi Regresi Prediksi Kalori pada Ekosistem FitTrack AI (Putra Hikmah Febryan)

Pendekatan arsitektur modular ini diterapkan untuk mengisolasi fungsionalitas sistem berdasarkan prinsip pemisahan perhatian (*separation of concerns*), yang secara signifikan mempermudah proses pemeliharaan dan skalabilitas aplikasi di masa mendatang. Penggunaan Streamlit memfasilitasi interaksi pengguna yang responsif melalui antarmuka web, sementara beban komputasi yang intensif seperti inferensi algoritma klasifikasi kebugaran dan iterasi pencarian pola association rule didelegasikan secara efisien pada modul `models.py` dan `mining.py`. Selain itu, fleksibilitas skema penyimpanan ganda menjamin kelancaran siklus pengembangan perangkat lunak dari tahap purwarupa hingga implementasi (*deployment*) di komputasi awan. Skema basis data relasional tersebut dirancang terpusat untuk menjaga integritas relasi antar entitas, sehingga memungkinkan modul chatbot maupun analitik untuk mengakses dan menyinkronkan metrik aktivitas harian pengguna secara *real time*.



Gambar 1. Diagram Arsitektur Sistem

3.2. Dataset

Penelitian ini menggunakan tiga jenis dataset utama yang bersumber dari repositori publik Kaggle dan saling terhubung di dalam sistem, yaitu: (1) dataset kinerja fisik [13] yang berisi variabel klinis dan fisik (tekanan darah, kekuatan genggaman, fleksibilitas tubuh, jumlah *sit up*, jarak lompatan, dan persentase lemak tubuh) sebagai data latih untuk model klasifikasi kebugaran; (2) dataset sesi latihan [14] yang berisi variabel durasi latihan, rata rata detak jantung, suhu tubuh, usia, dan berat badan, sebagai data latih untuk model prediksi pembakaran kalori; dan (3) dataset nutrisi makanan [15] yang berisi kandungan kalori, protein, karbohidrat, dan lemak dari berbagai jenis makanan, yang digunakan untuk pencatatan makanan dan analisis pola konsumsi.

Ketiga dataset ini saling terhubung dan membentuk alur pemrosesan data holistik di dalam ekosistem FitTrack AI. Dataset Kinerja Tubuh (1) berfungsi sebagai fondasi awal untuk memetakan kapasitas fisiologis dan mengklasifikasikan level kebugaran pengguna (A hingga D). Klasifikasi ini kemudian menjadi acuan dalam mengevaluasi riwayat aktivitas harian yang diproses oleh modul prediksi kalori menggunakan Dataset Sesi Latihan (2). Terakhir, total pengeluaran energi dari pembakaran kalori latihan tersebut disandingkan dengan asupan energi harian yang dilacak melalui Dataset Nutrisi Makanan (3). Dengan demikian, sistem

mampu menghitung keseimbangan kalori bersih (net calorie balance) serta memberikan rekomendasi pola makan adaptif berdasarkan relasi empiris antara tingkat kebugaran, intensitas olahraga, dan nutrisi makanan pengguna.

Tabel 1. Ringkasan *Dataset* yang Digunakan

<i>Dataset</i>	<i>Jumlah Data</i>	<i>Jumlah Fitur</i>	<i>Sumber</i>
Kinerja Tubuh	13.393 baris	12 (11 input + 1 kelas target)	Kaggle - <i>Body Performance Data</i> [13]
Sesi Latihan	750.000 baris	9 (7 input + 1 target + 1 ID)	Kaggle - <i>Predict Calorie Expenditure</i> [14]
Nutrisi Makanan	1.541 baris	5 (Nama Makanan & 4 nilai nutrisi)	Kaggle - <i>Food Nutritional Facts</i> [15]

3.3. Prapemrosesan Data

Tahap prapemrosesan data meliputi penanganan nilai yang hilang, normalisasi/standarisasi fitur numerik menggunakan Standard Scaler, pengkodean variabel kategorikal, serta pemisahan data menjadi set pelatihan dan set pengujian. Secara spesifik, dataset tersebut dibagi dengan rasio 80:20, di mana 80% data dialokasikan untuk pelatihan model dan 20% untuk pengujian.

Sebelum penerapan teknik oversampling, evaluasi pada data latih menunjukkan adanya ketidakseimbangan proporsi kelas target kebugaran fisik, di mana kelas intermediat (Kelas B dan C) mendominasi distribusi masing-masing sekitar ~33% hingga ~35%, sedangkan kelas ekstrem yaitu Kelas A (Sangat Baik) dan Kelas D (Buruk) memiliki representasi observasi yang lebih sedikit, yakni berada di kisaran ~15% hingga ~18%. Untuk mengatasi ketidakseimbangan kelas tersebut dan mencegah model mengembangkan bias mayoritas, diterapkan teknik Synthetic Minority Oversampling Technique (SMOTE). Teknik ini secara sintesis membangkitkan sampel baru pada ruang fitur kelas minoritas hingga seluruh kelas (A, B, C, dan D) mencapai distribusi proporsi yang setara tepat 25% pada data latih.

Penerapan serangkaian teknik prapemrosesan ini merupakan fondasi krusial untuk mengoptimalkan metrik evaluasi algoritma pembelajaran mesin, khususnya Support Vector Machine (SVM) yang sangat sensitif terhadap variansi skala fitur berdimensi tinggi. Penggunaan Standard Scaler menjamin bahwa seluruh variabel fisiologis yang secara natural memiliki satuan ukur dan rentang yang jauh berbeda (seperti detak jantung rata-rata dibandingkan dengan persentase lemak tubuh) distandarisasi dengan rata-rata nol dan variansi satu, sehingga mencegah fitur dengan nilai absolut besar mendominasi proses pembobotan model. Intervensi SMOTE tidak hanya mencegah terjadinya anomali overfitting yang sering menipu pada akurasi metrik, tetapi juga secara signifikan menaikkan tingkat sensitivitas (recall) model dalam mengklasifikasikan kategori tingkat kebugaran ekstrem yang umumnya minim representasi klinis.

3.4. Klasifikasi Tingkat Kebugaran

1. Tingkat kebugaran fisik pengguna diklasifikasikan ke dalam empat kategori: A (Sangat Baik), B (Baik), C (Cukup), dan D (Buruk), berdasarkan variabel fisiologis yang dijelaskan pada Sub-bab 3.2. Dalam penelitian ini, kinerja tiga algoritma klasifikasi dibandingkan dengan konfigurasi parameter yang telah dijustifikasi:
2. Random Forest: Metode pembelajaran ensemble yang membangun banyak pohon keputusan secara acak dan menggabungkan prediksinya melalui pemungutan suara mayoritas. Model dikonfigurasi dengan `n_estimators=100` dan `max_depth=None`. Pemilihan 100 pohon penduga (estimators) dinilai memberikan titik keseimbangan optimal antara kestabilan reduksi variansi dan efisiensi waktu komputasi, sementara kedalaman pohon yang tidak dibatasi (`max_depth=None`) memungkinkan setiap node berpartisipasi data secara tuntas hingga mencapai ruang kelas yang murni.
3. XGBoost (Extreme Gradient Boosting): Metode ensemble boosting yang membangun model secara berurutan untuk memperbaiki kesalahan model sebelumnya. Hiperparameter diatur dengan `learning_rate=0.1` dan `n_estimators=100`. Tingkat pembelajaran (learning rate) sebesar 0,1 dipilih sebagai faktor penyusutan (shrinkage factor) standar untuk mencegah kontribusi berlebih dari pohon individual dan mengeliminasi risiko overfitting selama iterasi boosting berlangsung.

4. Support Vector Machine (SVM): Metode klasifikasi yang mencari hiperbidang optimal untuk memisahkan kelas-kelas data. SVM diimplementasikan menggunakan kernel Radial Basis Function (RBF) dengan parameter regularisasi $C=1.0$. Parameter $C=1.0$ bertindak sebagai justifikasi standar yang memberikan penalti seimbang terhadap kesalahan klasifikasi pada data latih sambil mempertahankan margin pemisah antar-kelas yang cukup lebar pada ruang non-linear.

3.5. Prediksi Kalori Terbakar

Perkiraan kalori yang terbakar selama aktivitas fisik dihitung menggunakan algoritma Random Forest Regressor dengan variabel masukan yang meliputi durasi latihan, detak jantung rata-rata (BPM), suhu tubuh ($^{\circ}\text{C}$), usia, dan berat badan pengguna. Model regresi ini dikonfigurasi menggunakan hiperparameter $n_estimators=100$ dan parameter kontrol $random_state=42$. Justifikasi penetapan parameter ini bertujuan untuk menjamin konvergensi nilai Mean Squared Error (MSE) pada tingkat minimum serta memastikan stabilitas dan reproduksibilitas hasil eksperimen inferensi.

Keunggulan arsitektur Random Forest Regressor dalam konteks pemodelan fisiologis terletak pada kemampuannya mengelola interaksi kompleks multidimensi secara stabil (robust). Berbeda dengan model regresi linier tradisional, algoritma berbasis ensemble ini tidak rentan terhadap multikolinearitas antar fitur input sebagai contoh, korelasi alamiah yang tinggi antara lonjakan detak jantung dan kenaikan suhu tubuh saat intensitas latihan meningkat. Dengan meratakan hasil akhir prediksi dari sekumpulan pohon keputusan yang independen, model ini efektif menekan variansi dan meminimalisasi dampak anomali dari fluktuasi pengukuran sensor.

3.6. Prediksi Tren Berat Badan

Tren berat badan pengguna dari waktu ke waktu diproyeksikan menggunakan regresi linier sederhana, dengan menghitung kemiringan garis tren dari setidaknya dua titik data historis untuk memproyeksikan nilai berat badan selama 7, 14, atau 30 hari ke depan.

Meskipun metode Simple Linear Regression memiliki pendekatan matematis yang mendasar, implementasinya dalam pelacakan komposisi tubuh memberikan nilai interpretasi komputasional yang sangat aplikatif bagi pengguna akhir. Proyeksi parametrik yang dihasilkan melalui ekstrapolasi kemiringan garis (slope) secara transparan memvisualisasikan lintasan arah (trajectory) dari fluktuasi berat badan, yang dalam pencatatan mentah sering kali bias akibat variasi harian seperti tingkat retensi cairan. Dari perspektif informatika perilaku kesehatan, penyajian kuantifikasi prediktif ini berfungsi sebagai mekanisme umpan balik visual (visual feedback loop) yang membantu pengguna memvalidasi efektivitas manajemen kalori mereka secara objektif.

3.7. Penambangan Pola Konsumsi Makanan (Apriori)

Pola kombinasi makanan yang sering dikonsumsi bersama dianalisis menggunakan algoritma Apriori, sebuah metode penambangan aturan asosiasi yang mengidentifikasi himpunan item yang sering muncul bersama berdasarkan ambang batas dukungan dan kepercayaan minimum.

Hasil analisis ditampilkan dalam bentuk aturan asosiasi yang terdiri dari pasangan item beserta nilai dukungan dan keyakinannya. Untuk eksperimen ini, ambang batas minimum dikonfigurasi pada $min_support=0.05$ (5%) dan $min_confidence=0.5$ (50%). Justifikasi penetapan support sebesar 5% didasarkan pada karakteristik data riwayat diet individu yang cenderung memiliki sebaran kombinasi menu yang sangat luas (sparse); menetapkan ambang batas terlalu tinggi akan membuang pola makan signifikan yang jarang dipesan namun rutin berpasangan. Sementara itu, confidence sebesar 50% memastikan bahwa hanya aturan dengan tingkat kepastian asosiasi minimal satu berbanding dua yang disajikan sebagai acuan rekomendasi sistem. Selain ambang batas tersebut, kekuatan aturan asosiasi dievaluasi secara valid menggunakan metrik Lift.

3.8. Asisten Virtual Berbasis LLM (FitBot)

FitBot, asisten virtual interaktif dalam sistem ini, diimplementasikan menggunakan model bahasa llama-3.3-70b-versatile yang diakses melalui API Groq. Pemilihan parameter model dengan 70 miliar parameter dijustifikasi oleh kebutuhan pemahaman konteks semantik bahasa alami yang tinggi, khususnya dalam menangani variasi instruksi gizi dan olahraga dalam bahasa Indonesia. Selain itu, parameter temperatur (generation temperature) dikonfigurasi pada angka rendah ($temperature=0.2$) untuk meminimalisasi

halusinasi LLM dan memastikan konsistensi output ekstraksi JSON saat mengeksekusi parameter pemanggilan fungsi (tool calling).

Integrasi kapabilitas tool calling pada arsitektur LLM menandai pergeseran paradigma dari antarmuka chatbot konvensional yang pasif menjadi agen cerdas otonom. Dengan menerjemahkan intensi pengguna dari bahasa alami yang tidak terstruktur menjadi muatan JSON terstruktur yang dapat dieksekusi oleh parameter fungsi sistem, mekanisme ini menjembatani fleksibilitas interaksi manusia dengan rigiditas skema basis data relasional, sekaligus secara drastis mengurangi beban kognitif pengguna dalam melakukan entri data harian.

3.9. Metrik Evaluasi

Evaluasi kinerja pemodelan dilakukan menggunakan data uji yang terpisah dari data latih. Kinerja model klasifikasi dievaluasi berdasarkan Akurasi, Presisi, Recall, dan F1-Score, sedangkan kinerja model regresi dievaluasi berdasarkan RMSE, MAE, dan R^2 . Untuk memberikan pemahaman komprehensif terhadap hasil evaluasi, interpretasi fungsional dari masing-masing metrik diuraikan sebagai berikut:

1. Akurasi (*Accuracy*): Mengukur persentase ketepatan prediksi model secara keseluruhan dalam mengklasifikasikan keempat kategori kebugaran tubuh secara benar.
2. Presisi (*Precision*): Mengukur proporsi ketepatan prediksi kelas positif terhadap total prediksi positif model; metrik ini krusial untuk memastikan model tidak salah melabeli pengguna berfisik buruk sebagai pengguna berfisik sangat baik (*false positive*).
3. Recall (*Sensitivity*): Mengukur sejauh mana model mampu mengenali seluruh sampel observasi pada satu kelas target kebugaran sebenarnya; meminimalisasi kesalahan negatif palsu (*false negative*).
4. F1-Score: Merupakan rata-rata harmonis antara Presisi dan Recall. Metrik ini memberikan gambaran performa model yang seimbang dan sangat objektif, khususnya dalam evaluasi klasifikasi multi-kelas.
5. RMSE (*Root Mean Squared Error*): Mengakar-kuadratkan rata-rata kesalahan prediksi kalori. Metrik ini secara otomatis memberikan penalti yang jauh lebih berat terhadap kesalahan estimasi prediksi yang jauh meleset dari data empiris.
6. MAE (*Mean Absolute Error*): Mengukur rata-rata selisih absolut antara kalori hasil prediksi model dan kalori aktual (dalam satuan kkal), merepresentasikan toleransi penyimpangan rata-rata harian yang dialami pengguna.
7. Koefisien Determinasi (R^2): Mengukur persentase sejauh mana variansi variabel dependen (pembakaran kalori) dapat dijelaskan oleh model regresi berdasarkan variabel independen fisiologis masukan (mendekati 1,0 berarti akurasi prediksi sempurna).

Pemilihan kombinasi metrik evaluasi komprehensif ini dirancang untuk memberikan transparansi matematis yang objektif terhadap keandalan prediksi algoritma. Pada domain klasifikasi kebugaran, penggunaan metrik F1 Score disandingkan dengan akurasi untuk memastikan bahwa model memberikan keseimbangan harmonis antara presisi dan sensitivitas (*recall*) lintas kategori, yang sangat krusial untuk mencegah model bias terhadap kelas mayoritas meskipun data telah dioversampling. Sementara itu, pada pemodelan regresi, penggunaan *Root Mean Squared Error* (RMSE) secara efektif memberikan penalti komputasional yang lebih berat terhadap kesalahan estimasi prediksi yang jauh meleset (*large errors*), sedangkan Koefisien Determinasi (R^2) mengonfirmasi sejauh mana variansi model mampu menjelaskan pola data aktual. Keseimbangan metrik ini menjamin bahwa landasan analitik sistem memiliki tingkat signifikansi yang valid untuk diimplementasikan.

3.10. Pengaturan Eksperimen

Pengembangan sistem dan pelatihan model dilakukan pada mesin dengan sistem operasi 64-bit menggunakan lingkungan IDE. *Backend* dan *pipeline machine learning* dikembangkan menggunakan Python 3.10. Pustaka Scikit-learn dan XGBoost digunakan untuk pelatihan dan evaluasi model, sementara antarmuka web dibangun dengan Streamlit. SQLite digunakan sebagai basis data lokal selama fase eksperimen. Asisten virtual diintegrasikan melalui infrastruktur *cloud* Groq API untuk memastikan waktu inferensi yang cepat pada antarmuka percakapan.

Konfigurasi arsitektur perangkat keras dan lunak ini dipilih berdasarkan prinsip ketangkasan pengembangan perangkat lunak (*agile software development*) dan efisiensi komputasi analitik. Pemanfaatan pustaka Scikit-learn dan XGBoost di atas ekosistem Python memastikan stabilitas paralelisasi selama proses pelatihan *hyperparameter* komputasi tinggi pada *dataset* fisiologis. Secara khusus, pendelegasian proses pemahaman bahasa alami (NLP) ke infrastruktur *cloud* Groq API merupakan keputusan arsitektural yang fundamental;

Analisis Komparatif Model Klasifikasi Kebugaran dan Evaluasi Regresi Prediksi Kalori pada Ekosistem FitTrack AI (Putra Hikmah Febryan)

teknologi pemrosesan berbasis *Language Processing Unit* (LPU) ini memangkas latensi inferensi secara dramatis. Hal ini memastikan sinkronisasi antara ekstraksi data dari LLM berparameter masif (70 miliar parameter) dan eksekusi instruksi basis data lokal berjalan seketika (*real-time*), menjaga kelancaran interaksi tanpa menimbulkan hambatan proses komputasi (*bottleneck*).

3.11. Pengujian *Usability* (*System Usability Scale*)

Evaluasi antarmuka sistem dari perspektif pengguna dilakukan menggunakan kuesioner *System Usability Scale* (SUS) versi bahasa Indonesia yang terdiri dari 10 pernyataan standar dengan skala Likert 1 hingga 5. Pengujian ini melibatkan 50 responden. Ukuran sampel ini telah memenuhi kriteria kelayakan berdasarkan *Central Limit Theorem* dalam metode penelitian kuantitatif ($n > 30$), yang memastikan bahwa distribusi data mendekati kurva normal [8]. Penggunaan 50 responden dinilai sangat memadai untuk meminimalkan margin of error, meningkatkan keandalan statistik, dan memastikan stabilitas nilai rata-rata SUS yang diperoleh [9]. Sebelum menghitung skor akhir, instrumen kuesioner terlebih dahulu diuji validitas dan reliabilitasnya untuk memastikan konsistensi tanggapan. Skor akhir SUS kemudian dihitung dengan menjumlahkan bobot spesifik dari setiap pernyataan, yang selanjutnya dikalikan dengan faktor 2,5 untuk menghasilkan rentang skor 0 hingga 100. Kuesioner ini memuat serangkaian pernyataan yang dirancang khusus untuk menangkap persepsi dan umpan balik pengguna selama berinteraksi dengan berbagai fitur di dalam aplikasi FitTrack AI. Data tanggapan responden ini akan menjadi basis dalam analisis *usability*. Daftar pernyataan yang diberikan kepada responden disajikan pada Tabel 2.

Tabel 2. Daftar pernyataan kuesioner SUS

No	Pernyataan	Tipe Pernyataan
1	Saya berpikir akan sering menggunakan aplikasi FitTrack AI.	Positif
2	Saya merasa aplikasi FitTrack AI terlalu rumit padahal dapat dibuat lebih sederhana.	Negatif
3	Saya merasa aplikasi FitTrack AI mudah untuk digunakan.	Positif
4	Saya merasa butuh dukungan (bantuan) dari orang teknis/ahli untuk dapat menggunakan aplikasi FitTrack AI.	Negatif
5	Saya merasa berbagai fitur dalam aplikasi FitTrack AI terintegrasi dengan baik.	Positif
6	Saya merasa ada banyak hal yang tidak konsisten pada aplikasi FitTrack AI.	Negatif
7	Saya merasa mayoritas orang akan dapat belajar menggunakan aplikasi FitTrack AI dengan sangat cepat.	Positif
8	Saya merasa aplikasi FitTrack AI sangat merepotkan (tidak praktis) saat digunakan.	Negatif
9	Saya merasa sangat percaya diri saat menggunakan aplikasi FitTrack AI.	Positif
10	Saya harus belajar banyak hal terlebih dahulu sebelum dapat menggunakan aplikasi FitTrack AI.	Negatif

Berdasarkan analisis demografi, ke-50 responden yang berpartisipasi memiliki karakteristik yang sangat representatif terhadap target pengguna akhir aplikasi kesehatan digital modern. Mayoritas responden didominasi oleh kelompok usia Generasi Z pada rentang 18–22 tahun (82%) dengan latar belakang status pekerjaan sebagai pelajar/mahasiswa (90%), serta rasio jenis kelamin yang seimbang (52% perempuan dan 48% laki-laki). Poin karakteristik paling krusial adalah bahwa 100% responden menyatakan telah memiliki pengalaman (*domain knowledge*) menggunakan aplikasi pelacak kebugaran sejenis sebelumnya. Karakteristik ini menjamin bahwa tanggapan dan penilaian *usability* yang diberikan terhadap fungsionalitas sistem FitTrack AI bersumber dari evaluasi yang objektif, informatif, dan valid secara literasi digital.

4. HASIL DAN PEMBAHASAN

4.1 Hasil Klasifikasi Tingkat Kebugaran

Perbandingan kinerja ketiga algoritma klasifikasi (Random Forest, XGBoost, dan SVM) pada data uji ditunjukkan pada Tabel 3.

Tabel 3. Perbandingan Kinerja Model Klasifikasi Tingkat Kebugaran

Model	Akurasi (%)	Presisi	Recall	f1 score
Random Forest	74.47%	0.7481	0.7446	0.7436
XGBoost	76.37%	0.7700	0.7637	0.7623
SVM	70.06%	0.7081	0.7006	0.7015

Berdasarkan Tabel 3, XGBoost merupakan model dengan kinerja terbaik untuk klasifikasi tingkat kebugaran. Keunggulan kinerja XGBoost dibandingkan Random Forest dan SVM dikarenakan penerapan mekanisme Extreme Gradient Boosting yang secara iteratif memperbaiki kesalahan prediksi dari pohon-pohon keputusan sebelumnya (sequential tree building). Berbeda dengan Random Forest yang membangun pohon secara paralel dan independen (bagging), teknik boosting pada XGBoost memberikan bobot penalti yang lebih besar pada sampel kelas observasi yang sulit diklasifikasikan (hard examples). Selain itu, XGBoost mengintegrasikan parameter regularisasi formal (L^1 dan L^2) secara langsung pada fungsi objektifnya, yang secara signifikan meredam variansi prediksi dan meminimalisasi overfitting, sejalan dengan efektivitas performanya pada domain prediksi klinis kesehatan [1]. Sementara itu, performa SVM menjadi yang terendah (70.06%) karena variasi biologis non-linear pada dataset fisiologis membuat pemetaan hyperplane pembatas antar-kelas (A, B, C, D) menjadi kurang tajam meskipun telah disintesis menggunakan teknik SMOTE.

4.2 Perkiraan Kalori yang Terbakar

Model regresi Random Forest untuk memprediksi kalori yang terbakar dievaluasi menggunakan data uji, dengan hasilnya ditampilkan pada Tabel 4.


Tabel 4. Hasil Evaluasi Model Prediksi Kalori yang Terbakar

Metrik	Nilai
RMSE (kkal)	3.6660 (or~3.67)
MAE (kkal)	2.2789 (or ~2.28)
R ²	0.996566 (or ~0.997)

Model regresi Random Forest untuk memprediksi kalori yang terbakar menunjukkan performa yang sangat luar biasa. Pencapaian koefisien determinasi (R^2) yang sangat tinggi sebesar 0.997 membuktikan bahwa model mampu menangkap hampir seluruh variasi relasi matematis di dalam dataset fisiologis. Keberhasilan ini didorong oleh struktur Random Forest Regressor yang memanfaatkan rata-rata ansambel (*ensemble averaging*) dari banyak pohon keputusan berakar dalam. Dalam ilmu fisiologi olahraga, estimasi pengeluaran energi bergantung pada relasi non-linear eksponensial dan interaktif antar-variabel, seperti lonjakan detak jantung (BPM) yang berbanding lurus dengan durasi latihan dan berat badan pengguna. Algoritma berbasis pohon secara natural mempartisi ruang fitur secara hierarkis tanpa terikat oleh batasan asumsi linieritas klasik, yang terbukti memberikan akurasi superior pada pemodelan prediksi kalori [2].

4.3 Hasil Prediksi Tren Berat Badan

Model peramalan ini menggunakan algoritma Regresi Linier dari pustaka Scikit-Learn. Fitur masukan utamanya adalah representasi numerik ordinal dari tanggal pencatatan berat badan, sedangkan variabel targetnya adalah berat badan dalam kilogram (kg). Evaluasi model dilakukan secara langsung menggunakan data historis milik pengguna (minimal 2 titik data). Keandalan model diukur melalui Koefisien Determinasi dan Koefisien Kemiringan (Koefisien Regresi), yang menunjukkan laju perubahan berat badan per hari (kg/hari). Koefisien positif menunjukkan tren kenaikan berat badan, sedangkan koefisien negatif menunjukkan penurunan berat badan. Berikut adalah visualisasi hasil prediksi:



Gambar 2. Grafik Proyeksi Tren Berat Badan

Dari perspektif interaksi pengguna dan psikologi perilaku kesehatan, ekstrapolasi tren berat badan jangka pendek hingga menengah ini memberikan nilai manfaat yang krusial bagi pencapaian target fisik individu. Fluktuasi berat badan harian acapkali menipu pengguna akibat retensi air ataupun massa sisa makanan di dalam tubuh, yang dapat menurunkan motivasi program diet. Dengan memproyeksikan lintasan garis kemiringan (slope) berdasarkan data historis aktual menuju 7, 14, dan 30 hari ke depan, sistem bertindak sebagai instrumen umpan balik objektif. Pengguna dapat langsung memvalidasi apakah program defisit atau surplus kalori yang sedang dipraktikkan telah berada di jalur yang tepat menuju target berat badannya, sekaligus memicu kesadaran intervensi dini apabila tren linier menunjukkan deviasi yang bertolak belakang dari tujuan awal.

4.4 Hasil Penambangan Pola Makan (Apriori)

Penambangan aturan asosiasi menggunakan algoritma Apriori menghasilkan sejumlah aturan asosiasi dengan nilai *support* dan *confidence*, sebagaimana ditunjukkan pada Tabel 5.

Tabel 5. Contoh Aturan Asosiasi yang Dihasilkan oleh Algoritma Apriori

Antecedent	Consequent	Support	Confidence	Lift
Roti	Telur	0.1417 (14.17%)	1.0000 (100%)	7.0588
Burger	Kentang Goreng	0.1583 (15.83%)	1.0000 (100%)	6.3158
Salad	Yogurt	0.1333 (13.33%)	1.0000 (100%)	5.7143
Dada Ayam	Nasi	0.1500 (15.00%)	1.0000 (100%)	4.8000
Pizza	Keju	0.1083 (10.83%)	1.0000 (100%)	5.7143
Yogurt	Salad	0.1333 (13.33%)	1.0000 (100%)	5.7143

Semua aturan asosiasi yang dihasilkan divalidasi menggunakan metrik Lift, dengan pola-pola utama mencatat nilai Lift yang sangat signifikan, berkisar antara 4.800 hingga 7.058. Nilai Lift ini, yang jauh melebihi 1.0, menunjukkan bahwa kombinasi item makanan ini memiliki korelasi positif yang sangat kuat dan bukan sekadar kebetulan statistik. Tabel 5 menunjukkan bahwa keberadaan item antecedent benar-benar mendorong konsumsi item consequent, dengan probabilitas kemunculan bersamaan yang 7 kali lebih tinggi dibandingkan ketika item-item tersebut dikonsumsi secara terpisah. Dalam implementasi sistem FitTrack AI, aturan-aturan asosiasi ini secara langsung diberdayakan sebagai mesin pemberi rekomendasi gizi proaktif. Apabila seorang pengguna mencatatkan konsumsi "Burger" ke dalam riwayat makannya, sistem dapat mengantisipasi kecenderungan konsumsi "Kentang Goreng" (Lift = 6.3158) dan secara adaptif memberikan peringatan batas aman kalori harian terlebih dahulu. Sebaliknya, pola positif tinggi seperti "Salad → Yogurt" atau "Roti → Telur" digunakan oleh asisten virtual untuk menyajikan saran menu sehat pelengkap yang adaptif terhadap profil konsumsi pengguna [3], [4].

4.5 Evaluasi Fungsionalitas AI dan Usability Sistem

Pengujian pada asisten virtual (FitBot) dievaluasi melalui dua pendekatan, yaitu pengujian fungsionalitas teknis (*tool calling*) dan pengujian penerimaan pengguna menggunakan kuesioner *System Usability Scale* (SUS).

Pada pengujian fungsionalitas, asisten virtual dievaluasi berdasarkan kemampuannya dalam memproses prompt bahasa alami menjadi format data terstruktur dan menyimpannya secara otomatis ke dalam basis data. Berdasarkan pengujian menggunakan 30 skenario percakapan yang mencakup perintah pencatatan aktivitas, pencatatan nutrisi tunggal, hingga pencatatan ganda, sistem menunjukkan tingkat keberhasilan eksekusi (*success rate*) sebesar 90.0% (27 dari 30 skenario sukses). Selain itu, integrasi infrastruktur *cloud* menghasilkan rata rata waktu respons (*latency*) sebesar 1,48 detik per interaksi. Kegagalan minor yang terjadi (10.0%) umumnya disebabkan oleh input pengguna yang memiliki tingkat ambiguitas sangat tinggi sehingga gagal diekstraksi secara presisi oleh model bahasa dan rinciannya akan disajikan pada tabel 6.

Tabel 6. Hasil Pengujian Skenario Fungsionalitas tool calling FitBot

No.	Kategori Skenario	Contoh Input User	Inisiasi Tool	Status	Latensi (detik)
1	Pencatatan Olahraga	"Ya, tolong catat lari 30 menit." (Konfirmasi)	log_activity	Sukses	1,32
2	Pencatatan Olahraga	"Oke catatkan gym beban 45 menit."	log_activity	Sukses	1,41
3	Pencatatan Olahraga	"Oke catatkan gym beban 45 menit."	log_activity	Sukses	1,23
4	Pencatatan Olahraga	"Oke catatkan gym beban 45 menit."	log_activity	Sukses	1,45
5	Pencatatan Olahraga	"Tolong dicatat jalan kaki 80 menit tadi pagi."	log_activity	Sukses	1,51
6	Nutrisi Tunggal	"Ya, catatkan makan dada ayam bakar 200g."	log_food	Sukses	1,39
7	Nutrisi Tunggal	"Sarapan tadi semangkuk oatmeal, log ya."	log_food	Sukses	1,42
8	Nutrisi Tunggal	"Iya, catat es kopi susu gula aren."	log_food	Sukses	1,48
9	Nutrisi Tunggal	"Oke masukkan pisang satu buah sebagai snack"	log_food	Sukses	1,36
10	Nutrisi Tunggal	"Boleh, catat telur rebus dua butir tadi pagi."	log_food	Sukses	1,55
11	Nutrisi Ganda	"Iya, tolong dicatatkan nasi putih dan dada ayam."	log_food (2 item)	Sukses	1,60
12	Nutrisi Ganda	"Oke tolong catat burger dan kentang goreng."	log_food (2 item)	Sukses	1,58
13	Nutrisi Ganda	"Ya, silakan log salad buah dan yogurt."	log_food (2 item)	Sukses	1,62
14	Pertanyaan Umum	"Berapa kalori yang ada dalam nasi goreng?"	None	Sukses	1,12
15	Rekomendasi Menu	"Bisa berikan saran sarapan sehat diet?"	None	Sukses	1,18
16	Hipotetis	"Kalau saya push-up tiap hari efeknya apa?"	None	Sukses	1,20
17	Penolakan Log	"Tidak usah dicatat, terima kasih."	None	Sukses	1,29
18	Kalimat Ambigu	"Saya makan sesuatu yang manis, tebak apa?"	None	Sukses	1,34
19	Kalimat Ambigu	"Badan saya pegal, tolong catat." (Kurang log_activity parameter)		Gagal	1,78
20	Kalimat Ambigu	"Tadi saya makan banyak sekali di pesta." log_food		Gagal	1,82

No.	Kategori Skenario	Contoh Input User	Inisiasi Tool	Status	Latensi (detik)
21	Negasi Ganda	"Saya tidak jadi lari tapi tadi makan donat, jangan catat larinya, tapi donatnya saja."	log_activity & log_food	Gagal	1,89
22	Negasi Ganda	"Iya, tolong dicatat sarapan roti gandum dan selai kacang."	log_food	Sukses	1,48
23	Negasi Ganda	"Ya, tolong catat makan burger dan kentang goreng."	log_food	Sukses	1,39
24	Negasi Ganda	"Ya, silakan dicatat salad buah dan yogurt."	log_food	Sukses	1,34
25	Pertanyaan Kalori	"Berapa kalori yang terkandung dalam seporsi nasi goreng ayam?"	None	Sukses	1,02
26	Rekomendasi Menu	"Bisa berikan saran menu sarapan sehat untuk turun berat badan?"	None	Sukses	0,94
27	Skenario Hipotetis	"Kalau saya lari 30 menit sehari, kira-kira turun berapa kilo?"	None	Sukses	1,46
28	Pernyataan Tanpa Log	"Saya baru saja selesai makan semangkuk bakso kuah."	None	Sukses	0,68
29	Penolakan Log	"Tidak usah dicatat, terima kasih."	None	Sukses	1,01
30	Pendapat Kualitatif	"Makanan saya hari ini rasanya agak manis dan gurih, kira-kira sehat?"	None	Sukses	0,94

Analisis terhadap 3 kasus kegagalan eksekusi (10,0% dari total pengujian) menunjukkan adanya keterbatasan model bahasa dalam menangani input yang sangat ambigu atau memiliki struktur logika perintah yang bertolak belakang (*conflicting intents*). Pada skenario 19, model gagal melakukan tool calling karena ketiadaan parameter durasi dan jenis aktivitas yang spesifik pada pernyataan pengguna ("Badan saya pegal, tolong catat"). Kasus serupa terjadi pada skenario 20, di mana model tidak dapat mengestimasi nilai kalori dan kandungan nutrisi akibat ketidakjelasan deskripsi porsi makan ("makan banyak sekali di pesta"). Sementara itu, kegagalan pada skenario 21 disebabkan oleh kompleksitas struktur negasi ganda ("jangan catat larinya, tapi donatnya saja"), di mana model mengalami *false trigger* dengan memanggil fungsi pencatatan aktivitas olahraga meskipun pengguna telah meminta untuk mengabaikannya. Kasus kasus kegagalan ini mengindikasikan perlunya penerapan filter validasi parameter input (*guardrails*) yang lebih ketat sebelum memicu pemanggilan fungsi (*tool calling*) di masa mendatang.

Dari sisi penerimaan pengguna, instrumen kuesioner SUS didistribusikan kepada 50 responden untuk mengukur tingkat kemudahan penggunaan aplikasi secara keseluruhan. Sebelum menghitung skor akhir, kualitas kuesioner dievaluasi terlebih dahulu menggunakan perangkat lunak Jamovi. Hasil uji reliabilitas menunjukkan nilai Cronbach's Alpha sebesar 0,889, yang mengindikasikan bahwa kuesioner memiliki tingkat konsistensi internal yang sangat tinggi (sangat reliabel).

Selain itu, uji validitas (*item rest correlation*) membuktikan bahwa seluruh 10 pernyataan kuesioner adalah valid. Hal ini didasarkan pada perbandingan nilai *r*-hitung yang seluruhnya lebih besar dibandingkan nilai *r*-tabel untuk $N=50$ pada taraf signifikansi 5% (yakni 0,279). Rincian nilai validitas masing masing item disajikan pada Tabel 7.

Tabel 7. Hasil Uji Validitas Kuesioner SUS

Nomor Item	Nilai Korelasi <i>r</i> -hitung	Batas <i>r</i> -tabel	Keterangan
1	0,662	0,279	Valid
2	0,872	0,279	Valid
3	0,662	0,279	Valid
4	0,385	0,279	Valid
5	0,338	0,279	Valid
6	0,872	0,279	Valid
7	0,414	0,279	Valid
8	0,872	0,279	Valid

Nomor Item	Nilai Korelasi r-hitung	Batas r-tabel	Keterangan
9	0,414	0,279	Valid
10	0,872	0,279	Valid

Setelah kuesioner dipastikan valid dan reliabel, tahapan selanjutnya adalah melakukan perhitungan skor akhir SUS. Penilaian dilakukan berdasarkan aturan standar, di mana skor dari item pernyataan bernada positif dikurangi 1, sedangkan skor item pernyataan bernada negatif dikurangkan dari angka 5. Total penjumlahan skor dari setiap responden kemudian dikalikan dengan faktor 2,5.

Berdasarkan pengolahan data dari 50 responden, diperoleh rentang nilai dengan skor terendah sebesar 72,5 dan skor tertinggi sebesar 100. Secara kumulatif, perhitungan skor akhir SUS menghasilkan nilai rata rata (mean) sebesar 90,1. Merujuk pada pedoman interpretasi penilaian *System Usability Scale*, skor 90,1 ini berada jauh di atas batas kelayakan standar. Skor ini secara meyakinkan masuk ke dalam rentang penerimaan (*Acceptability Range*) kategori "Acceptable", menduduki peringkat kualitas (*Grade Scale*) A, dan meraih kategori tingkat penilaian (*Adjective Rating*) "Excellent" (Sangat Baik). Hasil kuantitatif ini secara empiris membuktikan bahwa antarmuka interaktif berbasis asisten virtual yang ditawarkan oleh FitTrack AI terbukti sangat efisien dan mudah digunakan oleh para pengguna akhir.

4.6 Pembahasan Umum

Secara keseluruhan, hasil pengujian menunjukkan bahwa integrasi berbagai metode machine learning ke dalam satu sistem terpadu mampu memberikan wawasan yang lebih komprehensif dibandingkan aplikasi pelacak kebugaran konvensional yang hanya berfokus pada pencatatan data pasif. Temuan kinerja klasifikasi dan regresi dalam sistem ini sejalan dengan penelitian terdahulu [1], [2], yang membuktikan keandalan algoritma ensemble berbasis pohon (seperti Random Forest dan XGBoost) dalam memproses variabel fisiologis secara presisi. Namun, FitTrack AI memberikan nilai tambah yang signifikan dengan tidak hanya menyajikan analitik secara visual, melainkan juga mengintegrasikannya dengan kemampuan asisten percakapan tool calling berbasis LLM. Hal ini secara langsung mengisi kesenjangan penelitian yang disoroti dalam literatur [6], di mana agen AI diharapkan tidak sekadar pasif, melainkan mampu berinteraksi secara aman dan dinamis dengan basis data backend.

Meskipun sistem telah beroperasi secara fungsional dan mendapatkan tingkat penerimaan (*usability*) yang sangat baik dari pengguna, penelitian ini masih memiliki beberapa keterbatasan yang perlu diakui:

1. Keterbatasan Dataset dan Generalisasi: Model *machine learning* dilatih menggunakan dataset publik yang mungkin memiliki distribusi demografis yang berbeda dengan populasi lokal pengguna.
2. Ketergantungan pada Infrastruktur Pihak Ketiga: Kinerja asisten virtual sangat bergantung pada stabilitas koneksi internet dan latensi dari infrastruktur *cloud* (Groq API).
3. Penanganan Bahasa Alami yang Ambigu: Sistem masih memiliki kerentanan dalam mengekstraksi parameter format JSON secara presisi apabila pengguna memberikan instruksi yang sangat ambigu, menggunakan bahasa prokem lokal, atau memasukkan perintah ganda yang saling bertentangan.

Untuk mengatasi keterbatasan-keterbatasan struktural dan operasional tersebut, serangkaian solusi teknis strategis dapat diterapkan pada iterasi pengembangan selanjutnya:

1. Mitigasi Keterbatasan Dataset: Melakukan pelatihan ulang (*re-training*) dan kalibrasi model secara berkala dengan mengumpulkan dataset fisiologis primer dari pengguna lokal di Indonesia, serta menerapkan teknik validasi silang berstratifikasi (*Stratified K-Fold Cross Validation*) untuk menjamin keandalan prediksi pada demografi khusus.
2. Mitigasi Infrastruktur Pihak Ketiga: Menerapkan arsitektur hibrida (*hybrid cloud-edge inference*) atau mekanisme *fallback retry-circuit breaker*. Apabila terjadi lonjakan latensi atau *time-out* pada API pihak ketiga, sistem dapat secara otomatis mengalihkan proses ekstraksi instruksi ke model bahasa berskala kecil (*Small Language Model*) yang dikelola secara lokal pada peladen internal.
3. Mitigasi Bahasa Alami/Slang Lokal: Melakukan *fine-tuning* lanjutan pada model bahasa menggunakan korpus percakapan sehari-hari dalam bahasa Indonesia, termasuk pemetaan kosakata informal, serta melengkapi asisten dengan alur *dialog manager* agar mampu menangani konteks percakapan multi-putaran (*multi-turn*) yang rumit secara presisi.

5. KESIMPULAN DAN SARAN

Penelitian ini telah berhasil melakukan analisis komparatif terhadap model klasifikasi kebugaran dan evaluasi regresi prediksi kalori yang diintegrasikan ke dalam ekosistem cerdas FitTrack AI. Berdasarkan hasil pengujian komparatif, algoritma XGBoost terbukti sebagai model dengan kinerja terbaik untuk klasifikasi tingkat kebugaran dengan akurasi mencapai 76,37%, mengungguli Random Forest (74,47%) dan SVM (70,06%). Sementara itu, pada evaluasi pemodelan regresi untuk prediksi pembakaran kalori, Random Forest Regressor menunjukkan presisi yang sangat tinggi dengan koefisien determinasi (R^2) sebesar 0,996 dan *Mean Absolute Error* (MAE) sebesar 2,28 kkal.

Secara keseluruhan, integrasi pendekatan multi-model ke dalam ekosistem FitTrack AI yang mencakup analitik prediktif, penambahan pola makan dengan algoritma Apriori, dan proyeksi tren berat badan telah tervalidasi secara sistematis. Sistem ini tidak hanya berhasil mengotomatiskan interpretasi data biologis yang kompleks, tetapi juga memecahkan kendala keengganan entri data manual melalui asisten virtual (FitBot) yang mencatat tingkat keberhasilan eksekusi tool calling hingga 90,0%. Arsitektur terpadu ini menghasilkan tingkat penerimaan pengguna akhir yang sangat tinggi, dibuktikan oleh perolehan skor System Usability Scale (SUS) sebesar 90,1 yang berada pada kategori penilaian Excellent (Sangat Baik).

Untuk penelitian selanjutnya, direkomendasikan perluasan ukuran dataset latih agar mencakup demografi yang lebih representatif terhadap populasi lokal, serta pelaksanaan validasi klinis terhadap estimasi kalori di bawah beban kerja fisik dunia nyata. Dari sisi infrastruktur, sistem dapat ditingkatkan dengan mengintegrasikan sinkronisasi API waktu nyata dari perangkat *wearable* (seperti *smartwatch*) dan penerapan arsitektur *cloud-native* untuk menangani skalabilitas basis data. Selain itu, implementasi *Retrieval Augmented Generation* (RAG) sangat disarankan guna melengkapi asisten virtual dengan pedoman medis dan nutrisi yang tervalidasi secara klinis. Secara spesifik, arsitektur RAG tersebut dapat diaugmentasi menggunakan basis pengetahuan (*knowledge base*) yang bersumber dari basis data medis dan gizi yang tervalidasi secara klinis, seperti Tabel Komposisi Pangan Indonesia (TKPI) Kementerian Kesehatan RI, direktori literatur medis standar (misalnya PubMed atau Cochrane Library), serta pedoman klinis resmi manajemen diet dari asosiasi ahli gizi terkemuka.

Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada Bapak Asif Faroqi, S.Kom., M.Kom. dan Bapak Dhian Satria Yudha Kartika, S.Kom., M.Kom. selaku dosen pembimbing atas arahan, diskusi, dan evaluasi komprehensif yang diberikan selama proses penelitian. Terima kasih juga disampaikan kepada Marcus Cordelius dan Haikal Pratama Samudera atas dukungan teknis dan kolaborasinya dalam pengembangan sistem pada penelitian ini.

DAFTAR PUSTAKA

- [1] M. As'an Hamid and E. R. Subhiyakto, "Performance comparison of Random Forest, SVM, and XGBoost algorithms with SMOTE for stunting prediction," *Journal of Applied Informatics and Computing*, vol. 9, no. 4, pp. 1163–1169, 2025.
- [2] K. A. Sumithra Devi, et al., "Hybrid model analysis for calorie prediction using ensemble learning techniques," *International Journal of Environmental Sciences*, vol. 11, no. 6, pp. 3024–3031, 2025.
- [3] N. N. Merliani, et al., "Penerapan algoritma Apriori pada transaksi penjualan untuk rekomendasi menu makanan dan minuman," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 8, no. 1, pp. 9–16, 2022.
- [4] H. Jantan, et al., "Association rule mining-based food preferences analysis using FP-Growth method," in *Proc. ICIS 2023*, Springer, 2024, pp. 217–230.
- [5] Y. J. Oh, et al., "A systematic review of artificial intelligence chatbots for promoting physical activity, healthy diet, and weight loss," *International Journal of Behavioral Nutrition and Physical Activity*, vol. 18, p. 160, 2021.
- [6] I. A. Pap and S. Oniga, "eHealth Assistant AI chatbot Using a Large Language Model to Provide Personalized Answers through Secure Decentralized Communication," *Sensors*, vol. 24, no. 18, p. 6140, 2024.
- [7] R. Fadhilah, et al., "Integrasi fitur chatbot dalam aplikasi edukasi kesehatan dan kebugaran menggunakan algoritma neural network," *Jurnal Kecerdasan Buatan dan Teknologi Informasi*, vol. 3, no. 3, pp. 125–135, 2024.
- [8] Sugiyono, *Metode Penelitian Kuantitatif, Kualitatif, dan R&D*, Edisi ke-3. Bandung: Alfabeta, 2022.

- [9] J. Sauro and J. R. Lewis, *Quantifying the User Experience: Practical Statistics for User Research*, 3rd ed. Cambridge, MA: Morgan Kaufmann, 2025.
- [10] A. J. Thirunavukarasu, et al., "Large language models in medicine," *Nature Medicine*, vol. 29, no. 8, pp. 1930–1940, 2023, doi: 10.1038/s41591-023-02448-8.
- [11] S. Yao, et al., "ReAct: Synergizing Reasoning and Acting in Language Models," in *Proceedings of the International Conference on Learning Representations (ICLR)*, Kigali, Rwanda, 2023.
- [12] M. Khorasani, M. Abdou, and J. H. Fernández, *Web Application Development with Streamlit: Develop and Deploy Secure and Scalable Web Applications to the Cloud Using a Pure Python Framework*. Apress, Springer, 2022.
- [13] kukuroo3, "Body Performance Data," Kaggle, 2022. [Online]. Tersedia: <https://www.kaggle.com/datasets/kukuroo3/body-performance-data>
- [14] A. Shamim, "Predict Calorie Expenditure," Kaggle, 2022. [Online]. Tersedia: <https://www.kaggle.com/datasets/adilshamim8/predict-calorie-expenditure>
- [15] beridzeg45, "Food Nutritional Facts," Kaggle, 2022. [Online]. Tersedia: <https://www.kaggle.com/datasets/beridzeg45/food-nutritional-facts>
- [16] World Health Organization, *WHO Guidelines on Physical Activity and Sedentary Behaviour*. Geneva, Switzerland: WHO, 2020. [Online]. Tersedia: <https://www.who.int/publications/i/item/9789240015128>
- [17] MyFitnessPal, "MyFitnessPal: Calorie Counter," Mobile Application, 2025. [Online]. Tersedia: <https://www.myfitnesspal.com/>
- [18] Strava, "Strava: Run, Ride, Hike," Mobile Application, 2025. [Online]. Tersedia: <https://www.strava.com/>
- [19] L. Wang, et al., "Deep learning techniques applied to human activity recognition: A review," *Pattern Recognition Letters*, vol. 119, pp. 47–59, 2019, doi: 10.1016/j.patrec.2018.02.010.
- [20] F. Jiang, et al., "Artificial intelligence in healthcare: past, present and future," *Stroke and Vascular Neurology*, vol. 2, no. 4, pp. 230–243, 2017, doi: 10.1136/svn-2017-000101.
- [21] C. Vandelanotte, et al., "Past, Present, and Future of eHealth and mHealth Research to Improve Physical Activity and Dietary Behaviors," *Journal of Nutrition Education and Behavior*, vol. 48, no. 3, pp. 219–228, 2016, doi: 10.1016/j.jneb.2015.12.006.
- [22] T. Chen and C. Guestrin, "XGBoost: A Scalable Tree Boosting System," in *Proc. 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD)*, San Francisco, CA, USA, 2016, pp. 785–794, doi: 10.1145/2939672.2939785.
- [23] P. Fournier-Viger, et al., "A survey of itemset mining," *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, vol. 7, no. 4, e1207, 2017, doi: 10.1002/widm.1207.
- [24] W. Kwon, et al., "Efficient Memory Management for Large Language Model Serving with PagedAttention," in *Proc. 29th ACM Symposium on Operating Systems Principles (SOSP)*, 2023, pp. 611–626, doi: 10.1145/3600006.3613165.

NOMENKLATUR

Daftar Singkatan dan Istilah Teknis:

1. AI: *Artificial Intelligence* (Kecerdasan Buatan)
2. API: *Application Programming Interface*
3. BMI: *Body Mass Index* (Indeks Massa Tubuh)
4. BPM: *Beats Per Minute* (Detak Jantung per Menit)
5. JSON: *JavaScript Object Notation* (Format Data Pertukaran Terstruktur)
6. LLM: *Large Language Model* (Model Bahasa Besar)
7. MAE: *Mean Absolute Error* (rata rata Kesalahan Absolut)
8. ML: *Machine Learning* (Pembelajaran Mesin)
9. RMSE: *Root Mean Squared Error* (Akar rata rata Kesalahan Kuadrat)
10. SMOTE: *Synthetic Minority Oversampling Technique*
11. SUS: *System Usability Scale* (Skala Pengukuran Kegunaan Sistem)
12. SVM: *Support Vector Machine*
13. XGBoost: *Extreme Gradient Boosting*

Daftar Simbol dan Variabel Metrik:

1. n : Jumlah titik data (sampel) atau jumlah total responden
2. y_i : Nilai aktual atau nilai target nyata pada observasi ke- i
3. $\hat{y}_i$: Nilai prediksi yang dihasilkan oleh model regresi pada observasi ke- i
4. $\bar{y}$: rata rata (*mean*) dari keseluruhan data aktual yang diobservasi

5. R^2 : Koefisien Determinasi (Metrik evaluasi untuk keakuratan prediksi model regresi)
6. $A \rightarrow B$: Notasi Aturan Asosiasi (*Association Rule*), yang bermakna munculnya item/makanan A (*Antecedent*) diikuti dengan item/makanan B (*Consequent*)
7. *Support* (B): Probabilitas atau persentase frekuensi kemunculan item B dalam keseluruhan transaksi pengguna
8. *Confidence* ($A \rightarrow B$): Probabilitas bersyarat, mengukur seberapa sering item B muncul secara bersamaan ketika item A sudah muncul
9. *Lift* ($A \rightarrow B$): Rasio kekuatan korelasi dalam aturan asosiasi. Nilai *Lift* > 1 menunjukkan adanya korelasi positif yang signifikan antara item A dan item B