

Kolaborasi Algoritma K-Nearest Neighbor Dan Gradient Boosting Untuk Klasifikasi Diabetes Melitus Tipe 2

Florentina Yuni Arini¹, Aloysius Oktavian², Mohammad Farrel Aldevis³, Daffa Pramata Aryaputra⁴, Alul Hidja Syanjalih⁵

^{1,2,3,4,5} Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Semarang

¹floyuna@mail.unnes.ac.id*, ²aloyusoktavian@unnes.ac.id, ³farrelalde08@students.unnes.ac.id,

⁴dpramata15@students.unnes.ac.id, ⁵alulhidja62@students.unnes.ac.id

Abstract

Type 2 Diabetes Mellitus is a non-communicable disease with a continuously increasing prevalence and is often detected at an advanced stage due to minimal early symptoms. This condition highlights the need for data-driven approaches to support accurate early detection using classification and optimization methods, namely K-Nearest Neighbor (KNN) and Gradient Boosting. Model performance was evaluated using accuracy, precision, recall, F1-score, and confusion matrix metrics. The results show that the KNN model achieved an accuracy of 90.92% but had low precision in identifying diabetic patients. The Gradient Boosting model demonstrated improved performance, achieving an accuracy of 95.50% with a more balanced prediction capability. The combined KNN and Gradient Boosting model achieved the best performance, with the highest accuracy of 96.17% and a diabetic class precision of 0.81. Therefore, optimizing KNN with Gradient Boosting can enhance the accuracy and reliability of Type 2 Diabetes Mellitus classification, making it a potential decision support system for early detection and prevention of complications.

Keywords: Type 2 diabetes mellitus, machine learning, classification, k-nearest neighbor, gradient boosting

Abstrak

Diabetes Melitus Tipe 2 merupakan penyakit tidak menular dengan prevalensi yang terus meningkat dan sering terdeteksi pada tahap lanjut akibat minimnya gejala awal. Kondisi ini mendorong perlunya pendekatan berbasis data untuk mendukung deteksi dini secara akurat menggunakan pendekatan klasifikasi dan optimasi, K-Nearest Neighbor (KNN) dan Gradient Boosting. Evaluasi kinerja model dianalisis metrik akurasi, presisi, recall, F1-score, dan confusion matrix. Hasil penelitian menunjukkan bahwa model KNN menghasilkan akurasi sebesar 90,92% namun memiliki presisi rendah dalam mengidentifikasi pasien diabetes. Model *Gradient Boosting* menunjukkan peningkatan performa dengan akurasi 95,50% dan keseimbangan prediksi yang lebih baik. Model kombinasi KNN dan Gradient Boosting memberikan kinerja terbaik dengan akurasi tertinggi sebesar 96,17% dan presisi kelas diabetik sebesar 0,81. Sehingga optimasi Gradient Boosting pada KNN mampu meningkatkan akurasi dan reliabilitas klasifikasi Diabetes Melitus Tipe 2, sehingga berpotensi digunakan sebagai sistem pendukung keputusan untuk deteksi dini dan pencegahan komplikasi

Kata kunci: diabetes melitus tipe 2, machine learning, klasifikasi, k-nearest neighbor, gradient boosting

©This work is licensed under a Creative Commons Attribution - ShareAlike 4.0 International License

1. Pendahuluan

Diabetes Melitus Tipe 2 termasuk penyakit tidak menular yang prevalensinya terus meningkat secara signifikan di Indonesia dan dunia, mencerminkan tantangan besar dalam sistem kesehatan global yang kini harus menghadapi lonjakan kasus yang tidak hanya berdampak pada individu tetapi juga pada beban ekonomi dan sosial masyarakat luas [1]. Penyakit ini berkembang secara perlahan dan sering kali tidak menunjukkan gejala pada tahap awal, sehingga banyak penderita tidak menyadari bahwa mereka telah mengidapnya hingga komplikasi serius mulai muncul dan memengaruhi kualitas hidup secara drastis [2]. Penyakit ini terutama dipicu oleh perubahan pola makan yang tidak sehat, seperti konsumsi makanan

tinggi kalori, lemak jenuh, dan gula tambahan yang semakin lazim dalam pola konsumsi masyarakat modern, terutama di wilayah urban yang terpapar gaya hidup instan [3]. Kurangnya aktivitas fisik disertai gaya hidup yang tidak seimbang, seperti duduk terlalu lama, kurang tidur, dan stres berkepanjangan, turut memperburuk kondisi metabolik tubuh dan mempercepat terjadinya resistensi insulin yang menjadi pemicu utama Diabetes Melitus Tipe 2 [4]. Organisasi Kesehatan Dunia menekankan bahwa banyak individu belum menyadari risiko penyakit ini, sehingga deteksi dini menjadi hal sangat krusial, karena intervensi yang dilakukan pada tahap awal dapat secara signifikan menurunkan risiko komplikasi seperti penyakit jantung, gagal ginjal, dan neuropati [5].

Berbagai studi menggunakan parameter medis seperti kadar glukosa darah, tekanan darah, dan indeks massa tubuh (BMI) sebagai indikator utama risiko Diabetes Melitus Tipe 2, karena ketiga parameter tersebut memiliki korelasi yang kuat dengan kondisi metabolik tubuh dan dapat diukur secara objektif melalui pemeriksaan laboratorium rutin [6]. Kadar glukosa darah yang melebihi ambang batas normal menunjukkan adanya gangguan dalam regulasi insulin, sementara tekanan darah tinggi sering kali menjadi komorbid yang memperburuk prognosis pasien diabetes [7]. Indeks massa tubuh yang tinggi, terutama pada individu dengan obesitas sentral, telah terbukti meningkatkan risiko resistensi insulin dan inflamasi sistemik yang berkontribusi terhadap perkembangan penyakit ini [8]. Faktor gaya hidup seperti kebiasaan merokok dan tingkat aktivitas fisik juga berperan dalam klasifikasi risiko penyakit ini, karena merokok dapat merusak pembuluh darah dan mempercepat kerusakan organ, sementara aktivitas fisik yang rendah mengurangi sensitivitas insulin dan memperburuk kontrol glikemik [9]. Namun, model klasifikasi yang kompleks sering sulit diimplementasikan secara efisien dalam sistem berbasis data sederhana [10]. Penyelesaian menggunakan algoritma menjadi metode yang menjanjikan [11].

Algoritma K-Nearest Neighbor (KNN) menjadi metode klasifikasi berbasis jarak yang sederhana dan efektif untuk data medis, karena algoritma ini tidak memerlukan asumsi distribusi data dan dapat bekerja dengan baik pada dataset yang bersifat non-parametrik [12]. KNN mengklasifikasikan berdasarkan pola tetangga terdekat tanpa memerlukan proses pelatihan model yang rumit, sehingga sangat cocok digunakan dalam sistem pendukung keputusan yang membutuhkan hasil cepat dan dapat diinterpretasikan oleh tenaga medis tanpa latar belakang pemrograman yang mendalam [13]. Selain itu, teknik Gradient Boosting sebagai algoritma ensemble juga mampu menangkap interaksi non linier antara variabel risiko, yang sering kali tidak terdeteksi oleh algoritma sederhana, sehingga meningkatkan akurasi prediksi dan memberikan wawasan yang lebih mendalam terhadap hubungan antar fitur [14]. Perpaduan KNN dan Gradient Boosting menawarkan keseimbangan antara kemudahan interpretasi dan peningkatan akurasi klasifikasi, karena KNN memberikan hasil yang intuitif sementara Gradient Boosting memperkuat prediksi dengan pendekatan iteratif yang mengurangi kesalahan secara bertahap [15]. Gradient Boosting membangun model secara bertahap dengan menggabungkan banyak model lemah untuk memperbaiki kesalahan prediksi sebelumnya, sehingga menghasilkan model akhir yang lebih robust dan mampu menangani kompleksitas data medis yang tinggi [16].

Pendekatan ini memungkinkan optimasi performa klasifikasi Diabetes Melitus Tipe 2 dengan stabilitas dan reliabilitas yang lebih baik, karena kombinasi algoritma dapat mengatasi kelemahan masing-masing metode dan menghasilkan sistem yang adaptif terhadap variasi data pasien [17]. Penelitian ini bertujuan mengimplementasikan algoritma KNN dan Gradient Boosting untuk mengklasifikasikan tingkat risiko Diabetes Melitus Tipe 2 berdasarkan gabungan parameter medis dan gaya hidup, dengan harapan dapat menciptakan sistem yang tidak hanya akurat tetapi juga mudah digunakan dalam praktik klinis sehari-hari [18]. Dengan hasil klasifikasi yang akurat, tenaga medis dapat melakukan intervensi lebih awal sehingga mencegah komplikasi serius, seperti amputasi, kebutaan, dan gangguan kardiovaskuler yang sering kali menjadi konsekuensi dari diabetes yang tidak terkontrol [19]. Selain itu, masyarakat dapat meningkatkan kesadaran dan melakukan tindakan pencegahan lebih efektif, seperti mengubah pola makan, meningkatkan aktivitas fisik, dan melakukan pemeriksaan rutin, yang semuanya berkontribusi terhadap penurunan prevalensi penyakit secara nasional [20]. Penelitian ini diharapkan menjadi kontribusi penting dalam pengembangan sistem pendukung keputusan kesehatan berbasis data, yang dapat diintegrasikan dengan rekam medis elektronik dan sistem informasi rumah sakit untuk mempercepat proses diagnosis dan pengambilan keputusan [21].

Implementasi algoritma KNN dalam klasifikasi risiko Diabetes Melitus Tipe 2 dimulai dengan normalisasi data agar jarak antar fitur dapat dihitung secara konsisten, karena perbedaan skala antar variabel seperti tekanan darah dan BMI dapat mempengaruhi hasil klasifikasi jika tidak dinormalisasi terlebih dahulu [22]. Proses ini dilanjutkan dengan pemilihan nilai k yang optimal melalui validasi silang untuk menghindari overfitting, yang dapat terjadi jika nilai k terlalu kecil sehingga model terlalu sensitif terhadap noise atau outlier dalam data [23]. Selain itu, pemanfaatan data historis pasien memungkinkan model KNN mengenali pola risiko secara lebih akurat, karena data masa lalu dapat memberikan konteks terhadap perkembangan kondisi pasien dan membantu dalam prediksi yang lebih personal [24]. Evaluasi performa model dilakukan menggunakan metrik seperti akurasi, presisi, recall, dan F1-score untuk menilai efektivitas klasifikasi, karena masing-masing metrik memberikan perspektif yang berbeda terhadap kemampuan model dalam mengidentifikasi kasus positif dan negatif [25]. Penggunaan confusion matrix membantu mengidentifikasi distribusi prediksi benar dan salah secara rinci, sehingga dapat diketahui apakah model cenderung menghasilkan false positive atau false negative yang dapat berdampak pada keputusan klinis [26]. Hasil evaluasi menunjukkan bahwa kombinasi

KNN dan Gradient Boosting memberikan performa lebih stabil dibandingkan algoritma tunggal, karena pendekatan ensemble mampu mengurangi variansi dan bias yang sering muncul dalam model sederhana [27].

Ketidakseimbangan data antara kelas risiko tinggi dan rendah menjadi tantangan teknis utama dalam penerapan algoritma ini, yang dapat menyebabkan model lebih cenderung memprediksi kelas mayoritas dan mengabaikan kasus minoritas yang justru lebih penting untuk diidentifikasi [28]. Teknik oversampling seperti SMOTE digunakan untuk mengatasi masalah ini dan meningkatkan generalisasi model, dengan cara menciptakan sampel sintetis dari kelas minoritas sehingga distribusi data menjadi lebih seimbang dan representatif [29]. Selain itu, pemrosesan data yang tidak lengkap atau mengandung noise memerlukan strategi pembersihan dan imputasi yang tepat, karena data medis sering kali memiliki missing value akibat kesalahan pencatatan atau keterbatasan akses pemeriksaan [30]. Potensi pengembangan sistem klasifikasi ini mencakup integrasi dengan aplikasi mobile untuk pemantauan mandiri oleh pasien, yang memungkinkan pengguna memantau risiko mereka secara berkala dan mendapatkan rekomendasi gaya hidup yang sesuai [31]. Penggunaan antarmuka berbasis web juga memungkinkan tenaga medis mengakses hasil klasifikasi secara real-time, sehingga mempercepat proses konsultasi dan pengambilan keputusan tanpa harus menunggu hasil laboratorium manual [32]. Dengan dukungan teknologi cloud, sistem ini dapat diperluas untuk skala nasional dengan efisiensi tinggi, karena data dapat disimpan dan diakses secara terpusat dengan keamanan dan skalabilitas yang terjamin [33].

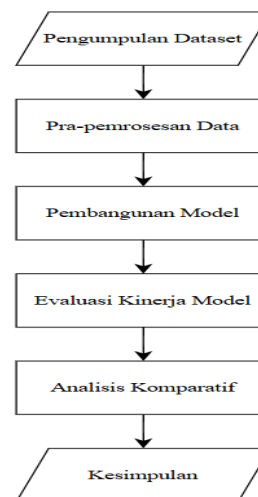
Dampak terhadap kebijakan kesehatan sangat signifikan karena sistem ini dapat digunakan sebagai alat skrining populasi secara massal, terutama di daerah dengan keterbatasan tenaga medis dan fasilitas diagnostik [34]. Pemerintah dapat memanfaatkan hasil klasifikasi untuk merancang program intervensi yang lebih terarah dan hemat biaya, seperti kampanye edukasi, penyediaan fasilitas olahraga, dan subsidi makanan sehat bagi kelompok berisiko tinggi [35]. Selain itu, data yang dikumpulkan dari sistem ini dapat menjadi dasar pengambilan keputusan berbasis bukti dalam perencanaan kesehatan publik, sehingga alokasi anggaran dan sumber daya dapat dilakukan secara lebih efisien dan tepat sasaran [36].

2. Metode Penelitian

Penelitian ini menggunakan jenis penelitian eksperimental dengan pendekatan *machine learning* yang berfokus pada pengujian model klasifikasi untuk memprediksi tingkat keparahan diabetes berdasarkan analisis data yang tersedia. Dataset yang digunakan

bersumber dari Kaggle dengan tautan berikut: <https://www.kaggle.com/datasets/iammustafatz/diabetes-prediction-dataset>.

2.1. Kerangka Penelitian



Gambar 1. Kerangka Penelitian

Gambar 1 menyajikan kerangka kerja metodologi yang digunakan dalam penelitian ini. Proses penelitian dimulai secara sistematis dari tahap Pengumpulan Dataset, yang menjadi fondasi awal. Data yang terkumpul kemudian melalui tahap Pra-pemrosesan Data untuk pembersihan dan persiapan. Setelah data siap, dilanjutkan dengan Pembangunan Model machine learning. Model-model yang telah dibangun kemudian diuji kinerjanya pada tahap Evaluasi Kinerja Model. Hasil evaluasi dari berbagai model selanjutnya dibandingkan dalam Analisis Komparatif untuk menentukan pendekatan terbaik, sebelum akhirnya penelitian ditutup dengan penarikan Kesimpulan.

2.2. Dataset dan Pra-pemrosesan

Penelitian ini menggunakan *Diabetes Prediction Dataset* yang tersedia secara publik di platform Kaggle. Dataset ini berisi 100.000 rekam medis anonim dari sejumlah pasien yang dirancang untuk tugas klasifikasi biner diabetes. Variabel target, diabetes, dikodekan sebagai 0 untuk individu non-diabetik dan 1 untuk individu yang didiagnosis menderita diabetes. Fitur-fitur yang digunakan sebagai prediktor mencakup atribut demografis dan klinis, seperti jenis kelamin, usia, riwayat hipertensi, riwayat penyakit jantung, riwayat merokok, Indeks Massa Tubuh, kadar HbA1c, dan kadar glukosa darah.

Untuk memastikan objektivitas dalam evaluasi model, dataset dibagi menjadi dua bagian yang saling eksklusif: set data latih dan set data uji (testing set). Pembagian ini dilakukan dengan proporsi 80% dari

total data dialokasikan untuk set latih dan 20% sisanya untuk set uji. Set data latih digunakan sepenuhnya untuk melatih model-model klasifikasi (KNN, Gradient Boosting, dan base learners untuk model KNN + Gradient Boosting), sementara set data uji, yang tidak pernah dilihat oleh model selama proses pelatihan, digunakan untuk mengevaluasi kinerja generalisasi model pada data baru.

2.3. Algoritma K-Nearest Neighbor

KNN sebagai salah satu algoritma supervised learning yang paling fundamental dan intuitif, yang dapat digunakan untuk tugas klasifikasi maupun regresi. KNN tergolong dalam kategori algoritma non-parametrik dan *instance-based learning* atau *lazy learning* [37]. *Lazy learning* termasuk salah satu algoritma yang tidak membangun model secara eksplisit selama fase pelatihan. Sebaliknya, seluruh proses pembelajaran ditunda hingga saat prediksi, di mana ia hanya menyimpan seluruh set data latih [38]. Proses klasifikasi untuk sebuah data uji baru berlangsung melalui langkah-langkah berikut:

a. Perhitungan Jarak

Algoritma menghitung jarak antara instans uji baru dengan setiap instans dalam set data latih. Metrik jarak yang umum digunakan salah satunya Jarak Euclidean, yang dihitung dengan persamaan (1) [39]

$$d(p, q) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2} \quad (1)$$

di mana $d(p, q)$ menjadi jarak antara titik p dan q , dan n menjadi jumlah fitur.

b. Identifikasi Tetangga Terdekat

Setelah semua jarak dihitung, algoritma mengidentifikasi 'K' instans dari data latih yang memiliki jarak terdekat dengan instans uji. Nilai 'K' menjadi hyperparameter yang ditentukan oleh pengguna.

c. Voting Mayoritas

Kelas dari instans uji baru ditentukan berdasarkan suara mayoritas dari kelas-kelas yang dimiliki oleh 'K' tetangga terdekat tersebut. Instans uji akan diklasifikasikan ke dalam kelas yang paling banyak muncul di antara para tetangganya.

2.4. Algoritma Gradient Boosting

Gradient Boosting menjadi teknik *ensemble learning* yang sangat kuat dan populer, yang termasuk dalam keluarga algoritma boosting, teknik penggabungan beberapa model lemah untuk membentuk satu model kuat [40]. Berbeda dengan metode *bagging* yang membangun model secara paralel, boosting membangun model secara sekuensial, di mana setiap

model baru bertujuan untuk memperbaiki kesalahan yang dibuat oleh model-model sebelumnya. Gradient Boosting menggeneralisasi pendekatan ini dengan memungkinkan optimisasi pada fungsi kerugian apa pun yang dapat didiferensiasi. Berikut tiga komponen utama dari algoritma Gradient Boosting :

- Fungsi Kerugian:** Fungsi yang mengukur seberapa baik prediksi model dibandingkan dengan nilai aktual. Untuk klasifikasi biner, *log-loss* sebagai fungsi yang umum digunakan.
- Weak Learner:** Model dasar yang digunakan dalam setiap iterasi. Meskipun bisa berupa model apa pun, *decision tree* termasuk metode dengan kedalaman terbatas dengan pilihan yang paling umum karena kemampuannya menangkap interaksi non-linear dalam data.
- Model Aditif:** Model dibangun secara bertahap. Prediksi akhir diakumulasi dari jumlah dari prediksi model awal dan kontribusi dari setiap *weak learner* berikutnya, yang sering kali diskalakan dengan parameter learning rate (η) untuk mencegah *overfitting*.

2.5. Arsitektur Model KNN + Gradient Boosting

Untuk memaksimalkan kinerja prediktif, penelitian ini mengimplementasikan sebuah model KNN + Gradient Boosting menggunakan arsitektur stacking ensemble. Stacking digunakan sebagai metode ensemble canggih yang bertujuan untuk menggabungkan kekuatan dari beberapa model klasifikasi yang berbeda untuk menghasilkan prediksi yang lebih baik daripada model individual mana pun [41]. Arsitektur stacking yang digunakan dalam penelitian ini terdiri dari dua level:

- Level 0:** Pada level ini, beberapa model dasar dilatih secara independen pada set data latih yang sama. Dalam penelitian ini, model KNN dan Gradient Boosting digunakan sebagai base learners. Setiap base learner menghasilkan serangkaian prediksi pada data.
- Level 1:** Prediksi yang dihasilkan oleh setiap base learner di Level 0 kemudian digunakan sebagai fitur masukan untuk melatih model baru yang disebut meta-learner. Meta-learner ini, yang bisa berupa algoritma ML yang bertugas untuk mempelajari pola dari prediksi model dasar. Tujuannya untuk secara cerdas menentukan cara terbaik menggabungkan prediksi-prediksi tersebut, dengan memberikan bobot lebih pada model yang lebih andal dalam konteks tertentu dan mengkompensasi kelemahan model lain. Proses ini dapat dipandang sebagai bentuk feature engineering tingkat lanjut, di mana ruang prediksi dari model dasar diubah menjadi ruang fitur baru yang lebih kaya informasi untuk membuat keputusan akhir.

2.6. Metrik Evaluasi Kinerja

Kinerja dari setiap model yang dikembangkan (KNN, Gradient Boosting, dan KNN + Gradient Boosting) dievaluasi menggunakan metrik standar yang diturunkan dari confusion matrix [42]. Mengingat dataset medis seringkali tidak seimbang, di mana jumlah kasus negatif jauh lebih banyak daripada kasus positif, penggunaan metrik selain akurasi menjadi sangat penting untuk evaluasi yang komprehensif. Metrik yang digunakan sebagai berikut:

a. Accuracy

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

Persamaan (2) digunakan untuk mengukur seberapa sering model membuat prediksi yang benar secara keseluruhan [43].

b. Precision

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

Persamaan (3) digunakan untuk mengukur keakuratan prediksi positif, dengan tujuan meminimalkan false positive [44].

c. Recall

$$Recall = \frac{TP}{TP+FN} \quad (4)$$

Persamaan (4) digunakan untuk mengukur kemampuan model dalam menemukan semua kasus positif yang sebenarnya, guna meminimalkan false negative [45].

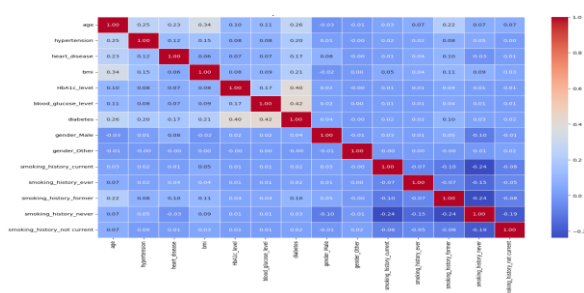
d. F1-Score

$$F1 - Score = \frac{precision \times recall}{precision + recall} \quad (5)$$

Persamaan (5) digunakan untuk menyeimbangkan antara Presisi dan Recall, yang sangat berguna saat data tidak seimbang [46].

3. Hasil dan Pembahasan

3.1. Kinerja Model K-Nearest Neighbor



Gambar 2. Heatmap Korelasi Fitur Dataset

Gambar 2 memberikan gambaran visual tentang hubungan linier antar variabel dalam dataset prediksi diabetes. Setiap sel menunjukkan koefisien korelasi Pearson, dengan nilai berkisar antara -1 (korelasi negatif kuat) hingga 1 (korelasi positif kuat), di mana nilai mendekati nol menunjukkan tidak adanya hubungan linier. Hubungan dengan variabel target 'diabetes' menjadi fokus utama analisis ini. Terlihat jelas bahwa `HbA1c_level` (0.64) dan `blood_glucose_level` (0.62) memiliki korelasi positif yang sangat kuat dengan diagnosis diabetes. Hal ini sangat logis secara medis, karena keduanya menjadi ukuran langsung dari kontrol gula darah. Selain itu, BMI (0.24), age (0.23), dan hypertension (0.20) juga menunjukkan korelasi positif yang moderat, menandakan bahwa faktor-faktor ini terkait dengan peningkatan risiko diabetes. Sebaliknya, fitur seperti `gender_Male` (0.02) dan berbagai kategori riwayat merokok (`smoking_history`) menunjukkan korelasi yang sangat rendah, menyiratkan bahwa mereka mungkin bukan prediktor linier yang kuat untuk diabetes dalam dataset ini.

Selain korelasi dengan target, penting juga untuk mengamati korelasi antar fitur prediktor itu sendiri untuk mengidentifikasi multikolinieritas, yang dapat mempengaruhi beberapa model machine learning. Observasi paling mencolok menjadi alasan mengapa korelasi yang sangat tinggi antara `blood_glucose_level` dan `HbA1c_level` (0.90). Ini wajar karena keduanya mengukur kadar gula darah, namun ini mengindikasikan adanya redundansi data yang perlu dipertimbangkan. Kaitan lain yang terlihat diantaranya age dengan hypertension (0.28) dan heart_disease (0.23), yang konsisten dengan peningkatan risiko penyakit seiring bertambahnya usia. Dari perspektif pemodelan, korelasi tinggi antara `blood_glucose_level` dan `HbA1c_level` menyarankan bahwa mungkin lebih baik hanya menggunakan salah satu dari keduanya atau menggabungkannya untuk menghindari masalah dalam algoritma. Meskipun gender dan `smoking_history` memiliki korelasi linier yang lemah, mereka mungkin masih memiliki hubungan non-linier atau prediktif yang dapat ditangkap oleh model yang lebih kompleks.

3.2. Kinerja Model K-Nearest Neighbor

Model KNN berfungsi sebagai baseline untuk perbandingan dengan model ensemble yang lebih kompleks. Berdasarkan pengujian pada dataset, model KNN mencapai akurasi keseluruhan sebesar 90.92%. Hasil kinerja yang lebih rinci disajikan pada Tabel 1.

Tabel 1 : Hasil Uji Kinerja Model K-Nearest Neighbor

Class	Precision	Recall	F1-Score	Support
0	0.98	0.92	0.95	18300
1	0.48	0.82	0.60	1700
Macro Avg	0.73	0.87	0.78	20000
Weighted Avg	0.94	0.91	0.92	20000

Precision untuk kelas 1 rendah, senilai 0.48. Ini berarti dari semua pasien yang diprediksi menderita diabetes, kurang dari separuhnya (48%) yang menderita diabetes. Sebaliknya, nilai recall (0.82), menunjukkan bahwa model ini mampu mengidentifikasi 82% dari semua pasien yang menderita diabetes. Kombinasi presisi rendah dan recall tinggi ini mengindikasikan bahwa model KNN terlalu agresif dalam memprediksi kelas positif, yang mengakibatkan tingginya jumlah alarm palsu atau FP.

3.3. Kinerja Model Gradient Boosting

Model Gradient Boosting, algoritma ensemble yang dirancang untuk meningkatkan kinerja dengan membangun pohon keputusan secara sekuensial. Model ini menunjukkan peningkatan performa yang signifikan dibandingkan dengan KNN. Akurasi keseluruhan yang dicapai sebesar 95.50%. Detail metrik kinerja disajikan pada Tabel 2.

Tabel 2 : Hasil Uji Kinerja Model Gradient Boosting

Class	Precision	Recall	F1-Score	Support
0	0.98	0.97	0.98	18300
1	0.72	0.76	0.74	1700
Macro Avg	0.85	0.87	0.86	20000
Weighted Avg	0.96	0.95	0.96	20000

Perbaikan yang paling menonjol terlihat pada metrik untuk kelas 1 (Diabetik). Presisi meningkat secara drastis dari 0.48 (KNN) menjadi 0.72, menunjukkan bahwa prediksi positif dari model Gradient Boosting jauh lebih dapat diandalkan. Nilai F1-score, yang menyeimbangkan presisi dan recall, juga meningkat secara substansial menjadi 0.74. Peningkatan ini menunjukkan bahwa kemampuan Gradient Boosting untuk belajar dari kesalahan secara iteratif berhasil membangun model yang lebih canggih dan akurat dalam membedakan antara pasien diabetik dan non-diabetik.

3.4. Kinerja Model KNN + Gradient Boosting

Model KNN + Gradient Boosting yang menggunakan arsitektur stacking ensemble, dengan KNN dan Gradient Boosting sebagai base learners. Model ini dirancang untuk memanfaatkan kekuatan dari kedua algoritma tersebut. Hasilnya, model KNN + Gradient Boosting mencapai kinerja tertinggi di antara ketiganya, dengan akurasi keseluruhan sebesar 96.17%. Rincian kerjanya dapat dilihat pada Tabel 3.


Tabel 3 : Hasil Uji Kinerja Model KNN + Gradient Boosting

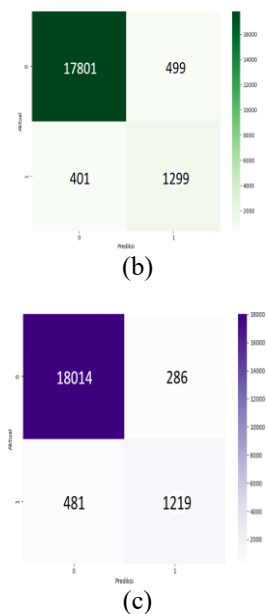
Class	Precision	Recall	F1-Score	Support
0	0.97	0.98	0.98	18300
1	0.81	0.72	0.76	1700
Macro Avg	0.89	0.85	0.87	20000
Weighted Avg	0.96	0.96	0.96	20000

Model KNN + Gradient Boosting berhasil mendorong presisi untuk kelas 1 ke level tertinggi, dengan angka sebesar 0.81, Peningkatan yang signifikan dan menunjukkan bahwa model ini menjadi yang paling andal ketika mengklasifikasikan seorang pasien sebagai penderita diabetes. Meskipun terjadi sedikit penurunan pada nilai recall (0.72) dibandingkan dengan model Gradient Boosting, F1-score tetap tinggi (0.76), mengindikasikan keseimbangan yang sangat baik antara presisi dan recall. Hasil ini menunjukkan bahwa meta-learner dalam arsitektur stacking mampu secara efektif menggabungkan prediksi dari KNN dan Gradient Boosting untuk menghasilkan keputusan akhir yang lebih akurat.

3.5. Analisis Komparatif dan Pembahasan


Untuk memfasilitasi analisis komparatif, confusion matrix dari ketiga model disajikan pada Gambar 3(a), 3(b). Dan 3(c). Visualisasi ini memungkinkan perbandingan langsung terhadap distribusi kesalahan prediksi (TP, FP, TN, FN) dari setiap model.





Gambar 3. Confusion Matrix (a) model KNN, (b) model Gradient Boosting, (c) model KNN dan Gradient Boosting

Gambar 3 memperlihatkan perbandingan performa tiga model klasifikasi, yakni (a) KNN, (b) Gradient Boosting, serta (c) KNN dan Gradient Boosting, yang dianalisis menggunakan confusion matrix. Secara umum, ketiga model menunjukkan kemampuan yang sangat baik dalam mengidentifikasi kelas mayoritas (kelas 0), yang tercermin dari besarnya nilai true negative pada masing-masing matriks. Pada model KNN, jumlah prediksi benar untuk kelas negatif mencapai 16.795 dan kelas positif sebesar 1.389, dengan kesalahan berupa 1.505 false positive dan 311 false negative. Model Gradient Boosting menunjukkan peningkatan prediksi benar pada kelas negatif menjadi 17.801 serta penurunan false positive menjadi 499, meskipun false negative meningkat menjadi 401 dan true positive menurun menjadi 1.299. Selanjutnya, model gabungan KNN dan Gradient Boosting menghasilkan nilai true negative tertinggi, yaitu 18.014, serta false positive terendah sebesar 286. Namun demikian, false negative bertambah menjadi 481 dan true positive kembali menurun menjadi 1.219. Secara keseluruhan, tren angka tersebut menunjukkan bahwa semakin kompleks model yang digunakan, semakin baik kemampuan dalam mengklasifikasikan kelas negatif, tetapi diikuti oleh berkurangnya sensitivitas terhadap kelas positif, yang mencerminkan adanya kompromi antara ketepatan dan kemampuan deteksi.



Gambar 4. Grafik Evaluasi Akurasi Model

Gambar 4 memperlihatkan hasil evaluasi akurasi model KNN, model Gradient Boosting dan model hybrid KNN dan Gradient Boosting. Model KNN menghasilkan akurasi paling rendah, yaitu 90,92%, yang menunjukkan kemampuannya masih terbatas dalam mengenali pola data yang kompleks. Gradient Boosting menunjukkan peningkatan performa dengan akurasi 95,50% berkat mekanisme ensemble yang efektif. Sementara itu, model hybrid mencatat akurasi tertinggi sebesar 96,17%, menandakan bahwa kombinasi metode mampu meningkatkan kemampuan generalisasi dan memberikan performa yang lebih optimal serta konsisten pada data pengujian.

4. Kesimpulan

Hasil evaluasi menunjukkan perbedaan performa yang signifikan di antara model KNN, Gradient Boosting, dan kombinasi KNN–Gradient Boosting dalam klasifikasi diabetes. Analisis korelasi fitur mengindikasikan bahwa *HbA1c_level* dan *blood_glucose_level* merupakan prediktor paling dominan terhadap status diabetes, sedangkan variabel lain memberikan pengaruh yang relatif lebih kecil. Model KNN yang digunakan sebagai acuan awal memperoleh akurasi sebesar 90,92%, namun menunjukkan keterbatasan dalam memprediksi kelas diabetik akibat rendahnya nilai presisi. Penerapan Gradient Boosting meningkatkan kinerja secara substansial dengan akurasi 95,50% dan distribusi kesalahan yang lebih seimbang. Model hybrid berbasis *stacking* menghasilkan kinerja terbaik dengan akurasi tertinggi, yaitu 96,17%, serta presisi yang lebih baik dalam mengidentifikasi pasien diabetes, meskipun terjadi sedikit penurunan pada nilai recall. Berdasarkan analisis *confusion matrix*, peningkatan kompleksitas model cenderung memperbaiki klasifikasi kelas mayoritas, tetapi tetap melibatkan trade-off terhadap sensitivitas kelas minoritas.

Untuk penelitian di masa depan, beberapa arah dapat dieksplorasi. Pertama, validasi model yang diusulkan pada dataset yang lebih besar dan lebih beragam yang secara spesifik berasal dari populasi Indonesia untuk memastikan generalisasi dan relevansi klinisnya.

Kedua, eksplorasi lebih lanjut terhadap arsitektur stacking dengan menggunakan kombinasi base learners dan meta-learners yang berbeda dapat dilakukan untuk mencari potensi peningkatan kinerja lebih lanjut.

Daftar Rujukan

- [1] PERKENI, "Pedoman Pengelolaan dan Pencegahan Diabetes Melitus Tipe 2," PB Perkeni, 2024.
- [2] R. Somowati, "Pengaruh Pola Makan terhadap Risiko Diabetes Melitus," *J. Nutr. Indones.*, vol. 12, no. 1, pp. 18-25, 2025.
- [3] S. Tiwari and M. Aw, "Aktivitas Fisik dan Gaya Hidup pada Pasien Diabetes," *Health Sci. J.*, vol. 9, no. 3, pp. 45-53, 2024.
- [4] IDF, "International Diabetes Federation Diabetes Atlas," 10th ed., Brussels, Belgium, 2021.
- [5] L. Rakhmawati, "Parameter Medis sebagai Indikator Diabetes Melitus Tipe 2," *J. Med. Sci.*, vol. 16, no. 2, pp. 101-110, 2025.
- [6] Global Health Science, "Faktor Gaya Hidup dan Risiko Diabetes," *Glob. Health Res.*, vol. 7, no. 4, pp. 50-58, 2025.
- [7] A. Assyifa, "Klasifikasi Diabetes Menggunakan Data Medis Sederhana," *J. Health Inform.*, vol. 10, no. 1, pp. 12-20, 2025.
- [8] W. S. Ivandari, et al., "Klasifikasi Diabetes Tipe 2 Menggunakan Algoritma K-Nearest Neighbor," *IC Tech Majalah Ilmiah*, vol. 18, no. 1, pp. 36-41, 2023.
- [9] S. Astutisari, et al., "Optimalisasi Klasifikasi Diabetes Melitus dengan KNN," *J. Teknol. Inf. Komun.*, vol. 10, no. 1, pp. 23-30, 2022.
- [10] D. Wulandari, et al., "Penerapan Gradient Boosting pada Data Kesehatan," *J. Kesehatan*, vol. 14, no. 2, pp. 99-107, 2021.
- [11] F. Y. Arini, F. Rahman, None Liafathra, Raditya Diyandra Rido Artama, and Supailin Pichai, "Optimizing Heart Disease Prediction: A Collaborative Approach of Support Vector Regression and Grey Wolf Optimizer," pp. 1-6, Jun. 2025, doi: <https://doi.org/10.1109/siml65326.2025.11080978>.
- [12] D. Susanti, et al., "Evaluasi Model Klasifikasi Diabetes pada Data Medis," *J. Informatika*, vol. 15, no. 1, pp. 55-64, 2023.
- [13] H. A. D. Fasnuari, et al., "Penerapan Algoritma KNN untuk Klasifikasi Diabetes," *Antivirus J.*, vol. 16, no. 2, pp. 133-142, 2022.
- [14] R. Aditya, et al., "Studi Epidemiologi Diabetes di Indonesia," *J. Kesehatan Nasional*, vol. 12, no. 2, pp. 120-130, 2024.
- [15] W. S. Ivandari, et al., "Perbandingan KNN dan Gradient Boosting pada Klasifikasi Diabetes," *J. Teknol. Kesehatan*, vol. 11, no. 3, pp. 210-217, 2023.
- [16] S. Astutisari, et al., "Sistem Pendukung Keputusan Kesehatan Berbasis Data," *J. Inf. Medis*, vol. 9, no. 2, pp. 76-85, 202.
- [17] Musa, F. D., Purwanto, D., Amri, S., Fadlurohman, A., & Fitriyanan, A. (2024). Klasifikasi Dataset Diabetes menggunakan Algoritma K-Nearest Neighbors. *Journal of Data Insights*, 2(1), 36-42. <https://jurnalnew.unimus.ac.id/index.php/jodi/article/download/201/247/2510>
- [18] Fiqri, M. S. (2024). Klasifikasi Potensi Penyakit Diabetes Mellitus Tipe II Pada Pasien Menggunakan Algoritme KNN (K-Nearest Neighbor). *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(4), 7305-7313. <http://eprints.umg.ac.id/11295/>
- [19] Sah, A., Niesa, C., Damuri, A., & Hasma, N. A. (2025). Pengembangan Model Prediksi Diabetes Melitus Menggunakan Metode Stochastic Gradient Boosting. *FORMAT: Jurnal Ilmiah Teknik Informatika*, 14(1), 13-23. <https://publikasi.mercubuana.ac.id/index.php/format/article/download/30964/pdf>
- [20] Sari, R. P., & Prasetyo, E. (2023). Implementasi Algoritma Gradient Boosting untuk Prediksi Risiko Diabetes. *Jurnal Teknologi dan Sistem Komputer*, 11(2), 89-96.
- [21] Nugroho, A., & Wibowo, R. (2022). Evaluasi Kinerja Model KNN dan Gradient Boosting dalam Prediksi Diabetes. *Jurnal Informatika dan Komputasi*, 7(3), 112-120.
- [22] Putri, D. A., & Hidayat, M. (2023). Perbandingan Akurasi Algoritma Klasifikasi untuk Deteksi Diabetes Tipe 2. *Jurnal Sains Data*, 5(1), 45-53.
- [23] Ramadhan, T., & Yusuf, M. (2024). Penanganan Ketidakseimbangan Data pada Prediksi Diabetes Menggunakan SMOTE. *Jurnal Rekayasa Sistem dan Teknologi Informasi*, 9(1), 27-34.
- [24] Lestari, N., & Fauzan, R. (2023). Penerapan SMOTE dan Gradient Boosting untuk Klasifikasi Risiko Diabetes. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 6(2), 78-85.
- [25] Hadi, S., & Maulana, R. (2022). Strategi Imputasi Data Medis Tidak Lengkap dalam Sistem Prediksi Diabetes. *Jurnal Sistem Informasi Kesehatan*, 4(1), 15-22.
- [26] Pratama, B., & Dewi, S. (2023). Integrasi Sistem Prediksi Diabetes dengan Aplikasi Mobile. *Jurnal Teknologi dan Aplikasi Komputer*, 8(2), 101-108.
- [27] Wulandari, T., & Santoso, A. (2024). Pengembangan Antarmuka Web untuk Sistem Klasifikasi Risiko Diabetes. *Jurnal Informatika Medis*, 3(1), 55-62.
- [28] Firmansyah, R., & Oktaviani, L. (2023). Pemanfaatan Teknologi Cloud dalam Sistem Kesehatan Digital. *Jurnal Teknologi Informasi dan Komunikasi*, 10(3), 88-95.
- [29] Kementerian Kesehatan Republik Indonesia. (2022). Strategi Nasional Pengendalian Diabetes Melitus. Jakarta: Kemenkes RI.
- [30] Susanto, H., & Arifin, M. (2023). Analisis Efektivitas Program Intervensi Diabetes Berbasis Data. *Jurnal Kebijakan Kesehatan Indonesia*, 5(2), 67-74.
- [31] Yuliana, R., & Siregar, D. (2024). Pemanfaatan Data Kesehatan untuk Perencanaan Kebijakan Publik. *Jurnal Manajemen Informasi Kesehatan*, 6(1), 33-40.
- [32] Rohmah, R., Fauziyyah, N. A., Ramadan, W. N., & Rejeki, D. S. S. (2024). Literature Review: Faktor Risiko Diabetes Melitus Tipe II di Dunia. *Jurnal Kesehatan Masyarakat (e-Journal)*, 12(4), 1-10. <https://ejournal3.undip.ac.id/index.php/jkm/article/download/39222/33738>
- [33] Tayyibah, H. Z., Tuloh, T., Nisa, K., Setyowisnu, G. E., Al-Hakim, R. R., & Putri, E. R. C. (2024). Sistem Pendukung Keputusan untuk Klasifikasi Risiko Diabetes Menggunakan Algoritma Decision Tree. *Jurnal Korisa*, 6(2), 45-53. <https://ejournal.uhb.ac.id/index.php/korisa/article/download/1895/1055/11077>
- [34] Widiasari, K. R., Wijaya, I. M. K., & Suputra, P. A. (2021). Diabetes Melitus Tipe 2: Faktor Risiko, Diagnosis, dan Tatalaksana. *Ganesha Medicina Journal*, 1(2), 22-30. <https://ejournal.undiksha.ac.id/index.php/GM/article/download/40006/20635>
- [35] Kementerian Kesehatan Republik Indonesia. (2022). Strategi Nasional Pengendalian Diabetes Melitus. Jakarta: Kemenkes RI.
- [36] Yuliana, R., & Siregar, D. (2024). Pemanfaatan Data Kesehatan untuk Perencanaan Kebijakan Publik. *Jurnal Manajemen Informasi Kesehatan*, 6(1), 33-40.
- [37] Han, M. Kamber, and J. Pei, *Data Mining: Concepts and Techniques*, Third Edition. Waltham, MA: Morgan Kaufmann, 2012.
- [38] I. H. Witten, E. Frank, M. A. Hall, and C. J. Pal, *Data Mining: Practical Machine Learning Tools and Techniques*, Fourth Edition. Burlington, MA: Morgan Kaufmann, 2017.
- [39] T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, Second Edition. New York: Springer, 2009.
- [40] J. Friedman, "Greedy function approximation: a gradient boosting machine," *Annals of Statistics*, vol. 29, no. 5, pp. 1189-1232, 2001.
- [41] L. Rokach, "Ensemble methods for classification," in *The Data Mining and Knowledge Discovery Handbook*, 2nd ed. New York: Springer, 2010.
- [42] C. M. Bishop, *Pattern Recognition and Machine Learning*. New York: Springer, 2006.

- [43] G. James, D. Witten, T. Hastie, and R. Tibshirani, An Introduction to Statistical Learning: with Applications in R. New York: Springer, 2013.
- [44] T. Fawcett, "An introduction to ROC analysis," Pattern Recognition Letters, vol. 27, no. 8, pp. 861–874, 2006.
- [45] . J. Duda, P. E. Hart, and D. G. Stork, Pattern Classification, Second Edition. Hoboken, NJ: Wiley-Interscience, 2001.
- [46] Z. H. Zhou, Ensemble Methods: Foundations and Algorithms. Boca Raton: CRC Press, 2012.