

Implementasi Artificial Intelligence Dalam Prediksi Penyakit Diabetes Menggunakan Algoritma Binary Classification

Implementation of Artificial Intelligence for Diabetes Prediction Using Binary Classification Algorithm

Hanna Yunita¹⁾, Ellbert Hutabri²⁾

¹⁾Teknik Informatika, Teknik dan Komputer, Universitas Putera Batam
Jalan R. Soeprapto, Kelurahan Kibing, Kecamatan Batu Aji, Batam, Kepulauan Riau
Telp : (29439) 083191166265
E-mail : pb210210062@upbatam.ac.id¹, ellbert.hutabri@gmail.com²

Abstract

Early detection of diabetes mellitus risk is a crucial step in preventing the growing burden of chronic diseases. This study aims to develop an automated predictive model using Artificial Intelligence (AI) with a binary classification approach. The model was implemented through AutoAI in IBM Cloud Pak for Data, utilizing a structured dataset containing 724 records and eight medical input parameters, including glucose level, BMI, insulin, and age. Data preprocessing was conducted manually to ensure quality before the dataset was divided into training and testing sets. AutoAI automated the selection of algorithms, feature engineering, and model evaluation. Gradient Boosted Classifier was selected as the best-performing model with a holdout accuracy of 81.8%, precision of 66.7%, and recall of 90.9%. The results demonstrate that the model is capable of identifying complex patterns in medical data, providing reliable predictions for diabetes risk. This research confirms the potential of AutoAI as a powerful tool to support early detection of chronic diseases, particularly in clinical decision-making processes.

Keywords: Artificial Intelligence, AutoAI, Binary Classification, Diabetes Prediction, IBM Cloud Pak for Data

Abstrak

Deteksi dini terhadap risiko diabetes melitus menjadi langkah penting dalam upaya pencegahan penyakit kronis yang terus meningkat. Penelitian ini bertujuan mengembangkan model prediksi otomatis menggunakan pendekatan klasifikasi biner berbasis kecerdasan buatan (Artificial Intelligence). Implementasi dilakukan melalui AutoAI dalam IBM Cloud Pak for Data, menggunakan dataset terstruktur yang terdiri dari 724 data dan delapan parameter medis, seperti kadar glukosa, BMI, insulin, dan usia. Proses pra-proses data dilakukan secara manual sebelum dibagi menjadi data latih dan data uji. AutoAI mengotomatiskan proses pemilihan algoritma, rekayasa fitur, dan evaluasi model. Algoritma Gradient Boosted Classifier terpilih sebagai model terbaik dengan akurasi holdout sebesar 81,8%, precision 66,7%, dan recall 90,9%. Hasil ini menunjukkan bahwa model mampu mengenali pola kompleks dalam data medis dan memberikan prediksi risiko diabetes yang andal. Penelitian ini menegaskan potensi AutoAI sebagai alat yang efektif untuk mendukung deteksi dini penyakit kronis, khususnya dalam proses pengambilan keputusan klinis.

Kata kunci: Kecerdasan Buatan, AutoAI, Klasifikasi Biner, Prediksi Diabetes, IBM Cloud Pak for Data

1. Pendahuluan

Kesehatan merupakan aspek penting dalam meningkatkan kualitas hidup masyarakat, terutama dalam menghadapi tantangan penyakit tidak menular yang kian meningkat. Salah satu penyakit tidak menular yang menjadi perhatian global adalah diabetes melitus. Menurut *World Health Organization* (WHO), diabetes menjadi penyebab kematian yang signifikan di dunia dan memiliki dampak besar terhadap produktivitas, ekonomi, serta kualitas hidup penderitanya [1]. Di Indonesia, khususnya di Kota Batam, jumlah penderita diabetes juga menunjukkan tren fluktuatif yang mengkhawatirkan, yakni tercatat sebanyak 20.338 kasus pada tahun 2021, menurun menjadi 20.111 pada tahun 2022, dan kembali meningkat menjadi 20.988 pada tahun 2023 berdasarkan laporan Dinas Kesehatan Provinsi Kepulauan Riau [2].

Diabetes melitus merupakan penyakit kronis yang prevalensinya terus meningkat dan menjadi salah satu penyebab kematian terbanyak secara global. Penyakit ini disebabkan oleh gangguan metabolik yang ditandai dengan meningkatnya kadar glukosa dalam darah. Jika tidak terdeteksi dan ditangani secara dini, diabetes dapat menimbulkan berbagai komplikasi serius seperti gagal ginjal, kebutaan, hingga penyakit jantung [3][4]. Menurut American Diabetes Association (ADA), pendekatan tanpa dukungan laboratorium dapat menghasilkan akurasi diagnosis hanya sekitar 60–75%, sehingga meningkatkan risiko keterlambatan pengobatan [5].

Seiring berkembangnya teknologi, kecerdasan buatan (*Artificial Intelligence/AI*) telah banyak digunakan dalam bidang kesehatan untuk mendukung proses

diagnosis. Salah satu cabang penting dalam AI adalah *Machine Learning* (ML), yang merupakan bagian dari AI dan berfokus pada pengembangan algoritma yang memungkinkan sistem belajar dari data. Salah satu pendekatannya adalah metode *binary classification*, yang mampu mengklasifikasikan data menjadi dua kategori, seperti positif atau negatif terhadap penyakit [6]. Sebuah penelitian membuktikan bahwa penerapan *machine learning* untuk prediksi diabetes dapat meningkatkan akurasi model dan membantu tenaga medis dalam mengambil keputusan klinis secara cepat dan tepat [7].

Berbagai penelitian sebelumnya telah membuktikan efektivitas machine learning dalam prediksi diabetes. Salah satu studi menggunakan algoritma SVM dengan metode *Radial Basis Function* dan mencapai akurasi hingga 91,2% setelah melakukan pemilihan fitur menggunakan *forward selection* [8]. Penelitian lain membandingkan algoritma *Random Forest* dan *XGBoost*, dan menunjukkan bahwa *XGBoost* memiliki akurasi lebih tinggi, yakni 76% [9]. Algoritma *K-Nearest Neighbor* (KNN) juga telah diterapkan pada dataset berukuran besar, dan akurasinya meningkat setelah dilakukan seleksi fitur menggunakan *Information Gain*, meskipun masih menghadapi kendala dalam pemilihan parameter dan tahap pra-pemrosesan [10]. Selain itu, algoritma C4.5 dengan pendekatan seleksi fitur menggunakan heatmap dilaporkan mencapai akurasi sebesar 76%, lebih baik dibandingkan algoritma SVM pada studi sebelumnya [11]. Namun, implementasi algoritma-algoritma tersebut membutuhkan keahlian pemrograman dan proses *tuning* parameter yang kompleks.

Meskipun algoritma-algoritma tersebut telah menunjukkan performa tinggi, implementasinya membutuhkan keahlian teknis dalam pemrograman dan pengaturan parameter yang kompleks. Oleh karena itu, penelitian ini mengimplementasikan AutoAI, fitur dari IBM Cloud Pak for Data yang dirancang untuk mengotomatisasi proses pengembangan model *machine learning* secara menyeluruh. AutoAI secara otomatis melakukan seleksi fitur, pemilihan algoritma terbaik, dan evaluasi model berdasarkan data yang dimasukkan [12]. Pendekatan ini tidak hanya meningkatkan efisiensi, tetapi juga memungkinkan pengguna non-teknis untuk membangun model prediksi dengan kualitas tinggi.

Penelitian ini bertujuan mengembangkan sistem prediksi risiko diabetes menggunakan AutoAI dengan pendekatan *binary classification* terhadap delapan parameter medis. Model yang dibangun diharapkan dapat membantu dalam proses skrining awal secara akurat dan efisien untuk mencegah komplikasi lanjutan pada penderita diabetes.

2. Tinjauan Pustaka

2.1 Artificial Intelligence

Artificial Intelligence (kecerdasan buatan) merupakan cabang ilmu komputer yang berfokus pada pengembangan sistem yang mampu menjalankan tugas-tugas yang umumnya memerlukan kemampuan intelektual manusia [13]. AI memiliki kemampuan untuk menganalisis data besar dan kompleks, mengenali pola tersembunyi, serta memberikan prediksi yang akurat berdasarkan data historis [14]. AI bekerja dengan menganalisis data dalam jumlah besar untuk mengidentifikasi pola, membuat prediksi, dan mengambil keputusan secara otomatis. Dalam bidang kesehatan, AI digunakan untuk membantu proses diagnosa dan prediksi penyakit secara cepat dan akurat.

2.2 Machine Learning

Machine Learning (ML) merupakan bagian dari AI yang memungkinkan sistem belajar dari data tanpa perlu diprogram secara eksplisit [15]. ML bekerja dengan mempelajari pola dari data historis untuk membuat prediksi terhadap data baru. Algoritma yang digunakan dalam ML dibagi menjadi tiga jenis utama, yaitu *supervised learning*, *unsupervised learning*, serta *reinforcement learning*. Dengan pendekatan ini, ML mampu meningkatkan akurasi dalam pemrosesan data dan pengambilan keputusan.

2.3 Binary Classification

Binary classification adalah salah satu metode dalam *supervised learning* yang digunakan untuk mengklasifikasikan data ke dalam dua kategori, seperti "positif" atau "negatif" [16]. Dalam prosesnya, data pelatihan yang berisi label digunakan untuk mengajarkan model mengenali pola klasifikasi. Algoritma populer yang digunakan untuk *binary classification* antara lain *Logistic Regression*, *Gradient Boosting*, *Support Vector Machine* (SVM), *Decision Tree*, dan *Neural Network*. Teknik ini sangat umum digunakan dalam bidang kesehatan untuk mendeteksi adanya penyakit atau kondisi tertentu berdasarkan parameter yang tersedia.

2.4 Diabetes

Diabetes melitus adalah penyakit kronis yang ditandai dengan tingginya kadar glukosa dalam darah dan dapat menimbulkan komplikasi serius seperti kerusakan saraf, kebutaan, dan penyakit jantung [17].

Berdasarkan klasifikasinya, diabetes terbagi menjadi empat tipe utama: tipe 1, tipe 2, MODY (*Maturity-Onset Diabetes of the Young*), dan gestasional. Tipe 2 adalah yang paling umum dan sering dikaitkan dengan gaya hidup tidak sehat, seperti kurangnya aktivitas fisik dan pola makan yang buruk [18]. Untuk mendeteksi risiko diabetes, digunakan delapan parameter medis

dari Kaggle yaitu *Pregnancies*, *Glucose*, *Blood Pressure*, *Skin Thickness*, *Insulin*, *BMI*, *Diabetes Pedigree Function*, dan *Age*.

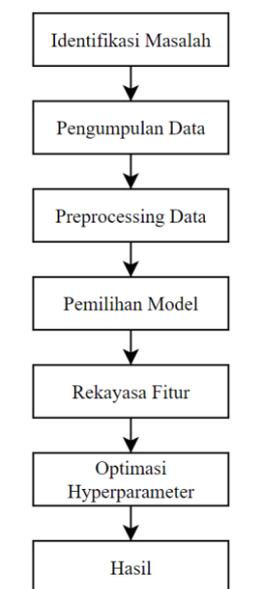
2.5 AutoAI

AutoAI adalah fitur canggih yang disediakan oleh IBM dalam platform IBM Cloud Pak for Data, yang memungkinkan pengguna membangun dan mengimplementasikan model *machine learning* secara otomatis tanpa memerlukan kemampuan pemrograman. Fitur ini dirancang untuk menyederhanakan proses model dengan mengotomatiskan seluruh tahapan penting dalam siklus *machine learning*, seperti pemilihan algoritma, pemodelan, dan evaluasi performa.

3. Metodologi Penelitian

3.1 Desain Penelitian

Desain penelitian ini berbentuk predictive modeling menggunakan algoritma klasifikasi biner (*binary classification*). Pemodelan dilakukan secara otomatis melalui fitur AutoAI yang terdapat dalam IBM Cloud Pak for Data. AutoAI bekerja dengan mengotomatisasi pemilihan algoritma, rekayasa fitur, pemrosesan data, hingga hasil.



Gambar 1. Desain Penelitian

3.2 Dataset

a. Pengumpulan Data

Data pada penelitian ini bersumber dari open dataset yang dapat diakses secara publik melalui platform Kaggle, berisi informasi medis yang mendukung deteksi risiko diabetes dan kerap dimanfaatkan dalam studi berbasis klasifikasi kesehatan. Pada gambar 2 Dataset terdiri dari 768 entri data yang masing-masing memiliki delapan fitur prediktor serta satu label target klasifikasi.

1	Pregnancies	Glucose	BloodPressure	SkinThickness	Insulin	BMI	DiabetesPedigreeFunction	Age	Outcome
2	6	148	72	35	0	33.6	0.627	50	1
3	1	85	66	29	0	26.6	0.351	31	0
4	0	183	64	0	0	23.3	0.672	32	1
5	1	89	66	23	94	28.1	0.167	21	0
6	0	137	40	35	168	43.1	2.288	33	1
7	5	116	74	0	0	25.6	0.201	30	0
8	3	78	50	32	88	31	0.248	26	1
9	10	115	0	0	0	35.3	0.134	29	0
10	2	197	70	45	543	30.5	0.158	53	1
11	8	125	96	0	0	0	0.232	54	1
12	4	110	92	0	0	37.6	0.191	30	0
13	4	168	74	0	0	38	0.537	34	1
14	5	139	80	0	0	27.1	1.441	57	0
15	1	189	60	23	846	30.1	0.398	59	1
16	5	166	72	19	175	25.8	0.587	51	1
17	7	100	0	0	0	30	0.484	32	1
18	0	118	84	47	230	45.8	0.551	31	1
19	5	107	74	0	0	29.6	0.254	31	1
20	1	103	30	38	83	43.3	0.183	33	0

Gambar 2. Dataset

Delapan fitur tersebut meliputi jumlah kehamilan (*Pregnancies*), kadar glukosa darah (*Glucose*), tekanan darah diastolik dalam satuan mmHg (*Blood Pressure*), ketebalan lipatan kulit trisep dalam mm (*Skin Thickness*), kadar insulin dalam darah (*Insulin*), indeks massa tubuh atau BMI (*Body Mass Index*), fungsi riwayat keturunan diabetes (*Diabetes Pedigree Function*), dan usia pasien (*Age*) dalam tahun. Sementara itu, label atau variabel target ditandai dengan kolom *Outcome*, yang menunjukkan dua kemungkinan hasil, yaitu nilai 0 untuk tidak berisiko menderita diabetes dan nilai 1 untuk berisiko menderita diabetes.

Seluruh data memiliki tipe numerik dan telah terstruktur dengan baik. File data disimpan dalam format CSV (*Comma Separated Values*) dan selanjutnya diunggah ke dalam platform IBM Cloud Pak for Data. Pemrosesan dan pemodelan dilakukan secara otomatis menggunakan fitur AutoAI yang tersedia dalam platform tersebut.

b. Preprocessing Data

Sebelum digunakan dalam proses pelatihan model, dataset diproses melalui tahap pembersihan (*pre-processing*) guna memastikan data dalam kondisi bersih, lengkap, dan memiliki format numerik yang sesuai. Proses ini dilakukan secara manual tanpa bantuan skrip pemrograman, meliputi pemeriksaan nilai kosong, penghapusan baris yang memiliki parameter penting tidak terisi, serta penghapusan data ganda yang dapat memengaruhi akurasi prediksi. Selain itu, setiap entri diperiksa untuk memastikan kesesuaian tipe data numerik. Setelah tahap pembersihan selesai, jumlah data menyusut dari 768 menjadi 724 baris, dengan 44 baris dihapus karena dinilai tidak valid akibat adanya nilai kosong maupun ketidaksesuaian format.

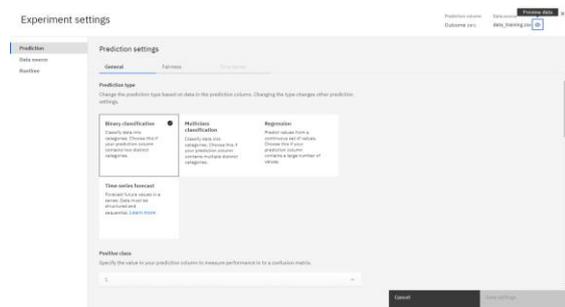
Langkah selanjutnya adalah pembagian dataset menjadi dua bagian utama, yaitu data pelatihan (*training data*) dan data pengujian (*testing data*). Tujuan dari pembagian data adalah untuk melatih model berdasarkan sebagian data dan kemudian mengujinya menggunakan data lain yang belum pernah dikenali, sehingga performa model dapat dievaluasi secara objektif. Dalam penelitian ini, sebanyak 652 data dimanfaatkan sebagai data *training*, sementara 72 data lainnya digunakan untuk menguji performa model. Pada data *training*, terdapat delapan variabel *input* beserta label klasifikasi (*Outcome*) yang digunakan untuk

membantu model memahami pola hubungan antara fitur dan kategori. Adapun data *test* hanya terdiri dari delapan parameter tanpa menyertakan kolom *Outcome*, sehingga prediksi dilakukan secara mandiri oleh model tanpa mengetahui label asli.

3.3 Perancangan

Perancangan sistem prediksi dalam penelitian ini dilakukan menggunakan fitur AutoAI yang tersedia dalam platform IBM Cloud Pak for Data. AutoAI merupakan teknologi otomatisasi dalam pengembangan model *machine learning* yang mampu membangun *pipeline* secara menyeluruh tanpa perlu campur tangan pemrograman manual. Tahapan perancangan dimulai dengan *input* data *training*, pengaturan eksperimen, hingga pemilihan algoritma terbaik secara otomatis berdasarkan hasil evaluasi performa.

Langkah awal yang dilakukan adalah mengunggah data *training* yang telah dibersihkan ke dalam proyek AutoAI dalam format CSV. Setelah dataset berhasil dimuat, pengguna perlu menetapkan kolom *Outcome* sebagai target klasifikasi, yang merepresentasikan status risiko diabetes. Kolom ini memiliki nilai biner, yakni 0 untuk individu tanpa risiko diabetes dan 1 untuk individu yang berisiko. Delapan kolom lainnya, seperti *Glucose*, *BMI*, *Age*, dan parameter medis lainnya, digunakan sebagai fitur *input* yang mendukung proses klasifikasi.



Gambar 3. Experiment Settings

Usai menetapkan kolom target dan fitur *input*, pengguna kemudian melakukan pengaturan eksperimen sebagaimana ditampilkan pada gambar 3. Salah satu aspek penting dalam tahap ini adalah penentuan jenis prediksi. Pada penelitian ini, jenis prediksi yang digunakan adalah *binary classification*, karena model dirancang untuk mengelompokkan data ke dalam dua kategori, yakni berisiko dan tidak berisiko diabetes. Selain *binary classification*, AutoAI juga mendukung tipe lain seperti *multiclass classification*, *regression*, dan *time series forecasting*, namun tidak digunakan dalam penelitian ini. Pengguna juga dapat menentukan algoritma apa saja yang akan diikuti sertakan dalam proses pelatihan. AutoAI menyediakan berbagai opsi algoritma *binary classification* seperti *Logistic Regression*, *Random Forest*, *Gradient Boosted Classifier*, dan *Support Vector Machine (SVM)*, dengan

rekomendasi awal dari sistem, namun tetap dapat disesuaikan.

Rank	Name	Algorithm	Accuracy (Optimized) Cross Validation	Accuracy (Optimized) Holdout
1	Pipeline 16	Gradient Boosting Classifier	0,773	0,818
2	Pipeline 15	Gradient Boosting Classifier	0,770	0,818
3	Pipeline 14	Gradient Boosting Classifier	0,770	0,818
4	Pipeline 4	Random Forest Classifier	0,768	0,788

Gambar 4. Pipeline Leaderboard

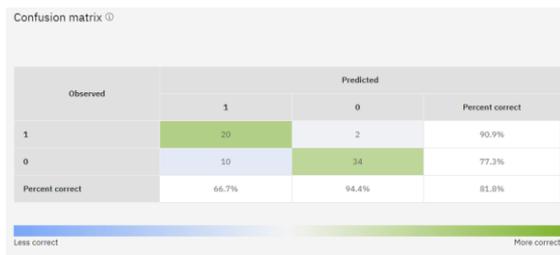
Setelah seluruh pengaturan eksperimen dikonfirmasi, AutoAI menjalankan proses pelatihan dan evaluasi beberapa *pipeline* model secara otomatis sebagaimana ditampilkan pada gambar 5. *Pipeline-pipeline* tersebut kemudian disusun berdasarkan kinerja pada *leaderboard*. Hasil eksperimen menunjukkan bahwa *Pipeline 16*, yang menggunakan algoritma *Gradient Boosting Classifier*, menempati peringkat tertinggi dengan akurasi *holdout* sebesar 0,818 dan skor *cross-validation* sebesar 0,773. *Pipeline* ini dipilih sebagai model final karena mampu memberikan hasil yang paling akurat dan konsisten dibandingkan *pipeline* lain, termasuk *Pipeline 15* dan *14* yang juga menggunakan algoritma serupa, serta *Pipeline 4* yang mengimplementasikan *Random Forest* namun menunjukkan akurasi terendah.

4. Hasil dan Pembahasan

Penelitian ini menghasilkan sebuah model prediksi risiko diabetes berbasis algoritma klasifikasi biner yang dibangun secara otomatis menggunakan teknologi AutoAI dalam IBM Cloud Pak for Data. AutoAI melakukan eksplorasi *pipeline* secara menyeluruh mulai dari pemrosesan data, pemilihan algoritma terbaik, pelatihan model, hingga evaluasi performa tanpa memerlukan skrip pemrograman. Model terbaik dipilih secara otomatis berdasarkan hasil evaluasi tertinggi terhadap data pelatihan dan data validasi.

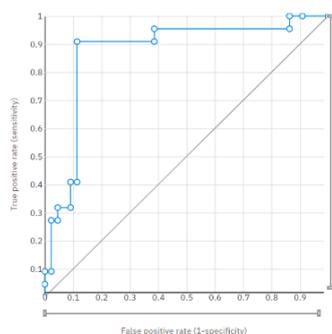
4.1 Hasil Evaluasi

Model klasifikasi terbaik yang dipilih AutoAI menggunakan algoritma *Gradient Boosting Classifier*, dengan skor akurasi tertinggi sebesar 81,8% pada data uji (*holdout*) dan 77,3% pada validasi silang (*cross-validation*). Pada gambar 5 Evaluasi performa model dilakukan dengan menggunakan *confusion matrix* yang secara otomatis dihasilkan oleh sistem. *Confusion matrix* menunjukkan bahwa dari total 66 data uji, terdapat 20 data positif yang berhasil diklasifikasikan dengan benar (*True Positive*), 34 data negatif yang juga diklasifikasikan dengan benar (*True Negative*), serta masing-masing 10 data *False Positive* dan 2 data *False Negative*.



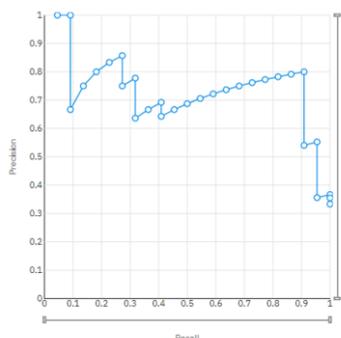
Gambar 5. Confusion Matrix

Berdasarkan hasil tersebut, perhitungan metrik evaluasi menghasilkan nilai akurasi sebesar 81,8%, *precision* sebesar 66,7%, *recall* sebesar 90,9%, dan *F1-score* sebesar 76,9%. Nilai *recall* yang tinggi menunjukkan bahwa model sangat sensitif dalam mendeteksi data berisiko diabetes, yang dalam konteks klinis merupakan hal yang penting untuk mencegah keterlambatan diagnosis. Sementara itu, meskipun *precision* tidak terlalu tinggi, nilai *F1-score* yang seimbang menunjukkan bahwa model cukup andal dalam menjaga ketepatan dan sensitivitas prediksi



Gambar 6. ROC Curve

Pada gambar 6 evaluasi lebih lanjut terhadap performa model dilakukan melalui analisis *ROC Curve*. *ROC Curve* memperlihatkan bahwa model memiliki kinerja klasifikasi yang optimal, ditunjukkan oleh grafik yang mendekati sudut kiri atas, sehingga menandakan kemampuan model dalam membedakan kelas positif dan negatif secara efektif. Walaupun nilai AUC tidak dicantumkan secara eksplisit, bentuk *ROC Curve* yang menanjak tajam mengindikasikan bahwa nilai AUC berada mendekati 1.



Gambar 7. Precision-Recall Curve

Gambar 7 *Precision-Recall Curve* menunjukkan kinerja model yang konsisten, dengan mayoritas titik berada di atas nilai *precision* 0,6 serta didukung oleh tingkat *recall* yang tinggi. Ini mengindikasikan bahwa model tidak hanya efektif dalam mengenali data berisiko, tetapi juga cukup tepat dalam menghindari klasifikasi positif palsu. Evaluasi melalui grafik ini sangat relevan dalam konteks distribusi kelas yang mungkin tidak seimbang, seperti pada kasus prediksi risiko penyakit.

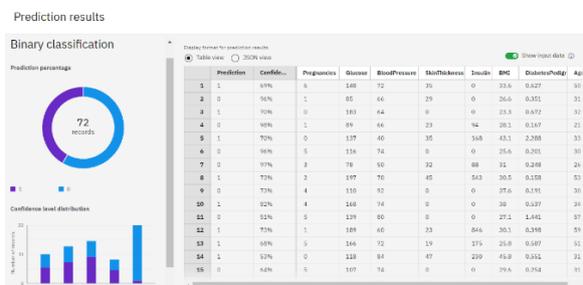
Measures	Holdout score	Cross validation score
Accuracy	0.818	0.773
Area under ROC	0.872	0.815
Precision	0.667	0.701
Recall	0.909	0.569
F1	0.769	0.627
Average precision	0.749	0.670
Log loss	0.431	0.499

Gambar 8. Evaluation Measure

Pada gambar 8 AutoAI menyajikan ringkasan performa dalam bentuk tabel evaluasi yang mencakup nilai *holdout score* dan *cross-validation score*. Akurasi model pada data uji mencapai 81,8%, sedangkan hasil validasi silang menunjukkan akurasi sebesar 77,3%. Tingginya nilai *recall* pada data *test* menandakan kemampuan model yang baik dalam mendeteksi kasus positif, meskipun pada validasi silang *recall* menurun hingga 56,9%, kemungkinan akibat perbedaan distribusi data pada setiap subset selama proses validasi. Selain itu, nilai AUC sebesar 0,872 semakin menegaskan bahwa model memiliki kemampuan yang baik dalam membedakan kelas, sementara nilai *log loss* yang rendah menunjukkan prediksi yang dihasilkan cukup akurat.

4.2 Hasil Uji

Setelah model dilatih, proses selanjutnya adalah menguji model dengan 72 data *test* yang tidak mengandung label *outcome*. Pada gambar 9 AutoAI menghasilkan hasil prediksi terhadap seluruh data uji yang telah ditentukan sebelumnya. Dari hasil pengujian, sebanyak 30 data diprediksi positif (berisiko diabetes) dan 42 data diprediksi negatif (tidak berisiko diabetes).



Gambar 9. Hasil Output Prediksi

AutoAI kemudian secara otomatis memproses delapan parameter *input* dan menghasilkan label prediksi beserta tingkat keyakinan (*confidence level*) untuk setiap hasil

prediksi. Hasil prediksi ditampilkan dalam bentuk visualisasi distribusi, baik dari sisi jumlah prediksi per kelas (0 atau 1) maupun dari sisi kepercayaan prediksi model.

Dari total 72 data testing, model mengklasifikasikan 30 data sebagai berisiko (*Outcome* = 1) dan 42 data sebagai tidak berisiko (*Outcome* = 0). Setiap prediksi juga disertai dengan nilai *confidence*, yang umumnya berada dalam rentang 60–90%, menunjukkan bahwa model memiliki tingkat kepercayaan yang tinggi terhadap keputusan klasifikasi yang diambil.

Hasil penelitian ini menunjukkan bahwa AutoAI dapat membangun model klasifikasi risiko diabetes yang cukup efektif tanpa memerlukan pemrograman manual. Penggunaan delapan parameter medis sebagai *input*, seperti glukosa, BMI, usia, dan lainnya, terbukti cukup representatif dalam membentuk model prediksi. AutoAI tidak hanya menyajikan hasil klasifikasi dalam bentuk numerik, tetapi juga memberikan visualisasi *pipeline*, metrik evaluasi, dan grafik pendukung seperti ROC dan *Precision-Recall Curve* yang mempermudah pemahaman terhadap performa model.

NO	Pregnancies	Glucose	Blood Pressure	Skin Thickness	Insulin	BMI	DPF	Age	Keterangan
1	0	137	40	35	168	43.1	2.288	33	BMI sangat tinggi (obesitas parah), riwayat keluarga sangat kuat (DPF sangat tinggi), insulin di atas normal
2	2	197	70	45	543	30.5	0.158	53	Glukosa sangat tinggi, insulin tinggi, usia di atas 50 tahun
3	1	189	60	23	846	30.1	0.398	59	Glukosa dan insulin sangat tinggi, BMI di atas 30, usia lanjut
4	5	166	72	19	175	25.8	0.587	51	Glukosa tinggi, riwayat keturunan (DPF > 0.5), usia di atas 50 tahun, jumlah kehamilan tinggi
5	0	118	84	47	230	45.8	0.551	31	BMI ekstrem, tekanan darah tinggi, DPF di atas 0.5. Meski glukosa belum tinggi, kombinasi faktor lain memengaruhi hasil

Gambar 10. Hasil Evaluasi

Salah satu kekuatan dari sistem ini adalah kemampuannya dalam mengenali pola kombinasi antar variabel, bukan hanya mengandalkan satu parameter tunggal. Pada gambar 10 menunjukkan bukti melalui evaluasi terhadap lima data yang diklasifikasikan sebagai berisiko diabetes. Meskipun salah satu data memiliki nilai glukosa dalam batas normal, model tetap mengklasifikasikannya sebagai positif karena kombinasi parameter lainnya menunjukkan pola risiko yang tinggi, seperti BMI yang sangat tinggi, tekanan darah di atas normal, dan nilai DPF yang signifikan.

Dengan akurasi sebesar 81,8%, *recall* 90,9%, dan *F1-score* 76,9%, model ini dapat dikatakan cukup layak digunakan sebagai sistem pendukung keputusan dalam skrining awal risiko diabetes. Temuan ini konsisten dengan hasil penelitian sebelumnya yang juga menunjukkan efektivitas pendekatan AI dalam bidang kesehatan, khususnya untuk deteksi dini penyakit tidak menular.

5. Kesimpulan

Kesimpulan ini berisi simpulan atas hasil penelitian serta saran yang dapat dijadikan acuan untuk pengembangan di masa mendatang.

5.1 Simpulan

Penelitian ini mengimplementasikan teknologi *Artificial Intelligence* melalui AutoAI dalam IBM Cloud Pak for Data untuk membangun model klasifikasi risiko diabetes. AutoAI secara otomatis memilih algoritma terbaik dan melakukan proses pelatihan, evaluasi, serta prediksi tanpa memerlukan pemrograman manual. Model terbaik yang dihasilkan menggunakan algoritma *Gradient Boosting Classifier* dengan akurasi 81,8%, *recall* 90,9%, dan *F1-score* 76,9%, menunjukkan bahwa sistem mampu mendeteksi individu berisiko secara akurat dan sensitif. Hasil ini membuktikan bahwa pendekatan otomatisasi AI efektif digunakan untuk *skrining* awal risiko penyakit tidak menular. Ke depan, model ini dapat dikembangkan lebih lanjut dengan menambahkan fitur pendukung, diuji pada dataset yang lebih luas, dan diintegrasikan ke dalam sistem digital untuk mendukung pengambilan keputusan medis yang lebih efisien.

5.2 Saran

Penelitian selanjutnya disarankan menggunakan dataset yang lebih besar dan beragam, termasuk data dari berbagai sumber dan populasi, agar model dapat memiliki daya generalisasi yang lebih baik. Penambahan parameter medis lain, seperti kadar kolesterol, tekanan darah sistolik, riwayat aktivitas fisik, serta gaya hidup, juga dapat meningkatkan akurasi prediksi. Selain itu, penerapan pendekatan *explainable AI* (XAI) disarankan agar hasil prediksi dapat disertai dengan penjelasan yang lebih transparan, sehingga dapat meningkatkan kepercayaan tenaga medis terhadap rekomendasi model. Integrasi model ke dalam aplikasi berbasis web atau mobile juga perlu dipertimbangkan, sehingga hasil penelitian ini dapat dimanfaatkan secara luas oleh tenaga medis maupun masyarakat untuk deteksi dini risiko diabetes secara *real time*. Uji coba lapangan (*field testing*) juga dapat dilakukan untuk mengukur kinerja sistem pada data nyata sekaligus memastikan kemanfaatan praktisnya sebagai alat bantu dalam pengambilan keputusan klinis.

Daftar Rujukan

- [1] M. G. C. Yuantari, “KAJIAN LITERATUR: HUBUNGAN ANTARA POLA MAKAN DENGAN KEJADIAN DIABETES MELITUS,” *JKM (Jurnal Kesehatan Masyarakat) Cendekia Utama*, vol. 9, no. 2, 2022, doi: 10.31596/jkm.v9i2.672.
- [2] “DINAS KESEHATAN - PPID Pemprov Kepri.” Accessed: Apr. 30, 2025. [Online].

- Available: <https://ppid.kepriprov.go.id/daftar-ppid/lihat/13>
- [3] D. Wira, T. Putra, and R. Andriani, "Unified Modelling Language (UML) dalam Perancangan Sistem Informasi Permohonan Pembayaran Restitusi SPPD," vol. 7, no. 1, 2019.
- [4] H. T. Sihotang, "Perancangan Aplikasi Sistem Pakar Diagnosa Diabetes Dengan Metode Bayes," *Jurnal Manik Penusa*, vol. 1, no. 1, 2017.
- [5] American Diabetes Association, "Diagnosis and Classification of Diabetes Mellitus," *Diabetes Care*, vol. 37, no. Supplement_1, pp. S81–S90, Jan. 2014, doi: 10.2337/dc14-S081.
- [6] D. N. Fitriani, "Prediksi PREDIKSI TINGKAT OBESITAS MENGGUNAKAN NEURAL NETWORK: PENDEKATAN KLASIFIKASI BINER," *PARAMETER: Jurnal Matematika, Statistika dan Terapannya*, vol. 3, no. 01, pp. 85–92, Apr. 2024, doi: 10.30598/parameterv3i01pp85-92.
- [7] I. Tasin, T. U. Nabil, S. Islam, and R. Khan, "Diabetes prediction using machine learning and explainable AI techniques," *Healthc Technol Lett*, vol. 10, no. 1–2, 2023, doi: 10.1049/htl2.12039.
- [8] H. S. W. Hovi, A. Id Hadiana, and F. Rakhmat Umbara, "Prediksi Penyakit Diabetes Menggunakan Algoritma Support Vector Machine (SVM)," *Informatics and Digital Expert (INDEX)*, vol. 4, no. 1, 2022, doi: 10.36423/index.v4i1.895.
- [9] M. Salsabil, N. L. Azizah, and A. Eviyanti, "Implementasi Data Mining Dalam Melakukan Prediksi Penyakit Diabetes Menggunakan Metode Random Forest Dan Xgboost," *Jurnal Ilmiah Komputasi*, vol. 23, no. 1, pp. 51–58, 2024.
- [10] D. Devian, P. Nurul Sabrina, and A. Komarudin, "PREDIKSI PENYAKIT DIABETES DENGAN METODE K-NEAREST NEIGHBOR (KNN) DAN SELEKSI FITUR INFORMATION GAIN," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 6, pp. 11320–11326, Nov. 2024, doi: 10.36040/jati.v8i6.11364.
- [11] R. P. Fadhillah, R. Rahma, A. Sepharni, R. Mufidah, B. N. Sari, and A. Pangestu, "Klasifikasi Penyakit Diabetes Mellitus Berdasarkan Faktor-Faktor Penyebab Diabetes menggunakan Algoritma C4.5," *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 7, no. 4, 2022, doi: 10.29100/jupi.v7i4.3248.
- [12] IBM, "Documentation for Cloud Pak for Data as a Service - Docs | IBM Cloud Pak for Data as a Service." Accessed: May 13, 2025. [Online]. Available: <https://dataplatform.cloud.ibm.com/docs/content/wsj/getting-started/welcome-main.html?context=cpdaas>
- [13] A. J. E. Oktavianus, L. Naibaho, and D. A. Rantung, "Pemanfaatan Artificial Intelligence pada Pembelajaran dan Asesmen di Era Digitalisasi," *JURNAL KRIDATAMA SAINS DAN TEKNOLOGI*, vol. 5, no. 02, 2023, doi: 10.53863/kst.v5i02.975.
- [14] Wilianto, Yuliana, A. Suwandhi, Jimmy, and J. Putra, "Penerapan AI dalam Menentukan Harga Mobil Bekas Berdasarkan Tahun Perakitan," *Jurnal Minfo Polgan*, vol. 13, no. 1, pp. 550–560, Jun. 2024, doi: 10.33395/jmp.v13i1.13728.
- [15] A. Fathurohman, "Machine Learning Untuk Pendidikan: Mengapa Dan Bagaimana," *Jurnal Informatika dan Teknologi Komputer (JITEK)*, vol. 1, no. 3, 2021.
- [16] D. Sebastian, "Implementasi Algoritma K-Nearest Neighbor untuk Melakukan Klasifikasi Produk dari beberapa E-marketplace," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 5, no. 1, 2019, doi: 10.28932/jutisi.v5i1.1581.
- [17] M. A. Wiratama and W. M. Pradnya, "Optimasi Algoritma Data Mining Menggunakan Backward Elimination untuk Klasifikasi Penyakit Diabetes," *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, vol. 11, no. 1, p. 1, Apr. 2022, doi: 10.23887/janapati.v11i1.45282.
- [18] M. K. Murtiningsih, K. Pandelaki, and B. P. Sedli, "Gaya Hidup sebagai Faktor Risiko Diabetes Melitus Tipe 2," *e-CliniC*, vol. 9, no. 2, 2021, doi: 10.35790/ecl.v9i2.32852.