



## Klasifikasi Indikator Kesehatan Diabetes Menggunakan Algoritma Random Forest

Haura Syahla<sup>1\*</sup>, Haris Izzudin<sup>2</sup>, Fariz Aditya Pratama<sup>3</sup>, Beni Rahmatullah<sup>4</sup>, Ahmad Jurnaidi Wahidin<sup>5</sup>, Ika Kurniawati<sup>6</sup>

<sup>1-6</sup>Teknik Informatika, Fakultas Teknik & Informatika, Universitas Bina Sarana Informatika, Indonesia

Email: [hsyahla28@gmail.com](mailto:hsyahla28@gmail.com)<sup>1</sup>, [harissoleh1753@gmail.com](mailto:harissoleh1753@gmail.com)<sup>2</sup>,  
[Farizadityapratama72@gmail.com](mailto:Farizadityapratama72@gmail.com)<sup>3</sup>, [Beni.brh@bsi.ac.id](mailto:Beni.brh@bsi.ac.id)<sup>4</sup>, [Ahmad.ajn@bsi.ac.id](mailto:Ahamd.ajn@bsi.ac.id)<sup>5</sup>,  
[ika.iki@nusamandiri.ac.id](mailto:ika.iki@nusamandiri.ac.id)<sup>6</sup>

\*Penulis Korespondensi: [hsyahla28@gmail.com](mailto:hsyahla28@gmail.com)

**Abstract.** Diabetes continues to rise as a global health concern, highlighting the need for analytical methods that can assist in earlier and more accurate detection. This study aims to classify diabetes conditions using the Random Forest algorithm implemented through the Orange Data Mining platform. The dataset used contains various health-related attributes such as glucose levels, blood pressure, body mass index, age, and other clinical indicators associated with diabetes risk. Random Forest was selected due to its ability to produce stable models, handle large and complex datasets, and minimize overfitting by combining multiple decision trees. The research process includes data preprocessing, splitting the dataset into training and testing portions, building the Random Forest model, and evaluating its performance using metrics such as accuracy, precision, recall, F1-score, and confusion matrix. The results indicate that Random Forest delivers strong and consistent performance in classifying diabetes conditions based on the given health indicators. These findings suggest that employing data mining techniques especially Random Forest within Orange—can serve as a practical and reliable approach to support medical analysis and assist healthcare practitioners in achieving earlier and more accurate diabetes detection.

**Keywords:** Classification; Data Mining; Diabetes; Orange; Random Forest.

**Abstrak.** Diabetes menjadi salah satu masalah kesehatan yang terus meningkat dan membutuhkan upaya deteksi yang lebih cepat serta akurat agar risiko komplikasi dapat diminimalkan. Penelitian ini bertujuan mengklasifikasikan kondisi diabetes menggunakan algoritma Random Forest melalui aplikasi Orange Data Mining sebagai alat bantu analisis. Dataset yang digunakan berisi berbagai informasi kesehatan, seperti kadar glukosa, tekanan darah, indeks massa tubuh, usia, dan beberapa parameter lain yang berpengaruh terhadap risiko munculnya diabetes. Algoritma Random Forest dipilih karena dikenal mampu menghasilkan model yang stabil, bekerja dengan baik pada data berukuran besar, serta efektif dalam mengurangi overfitting melalui proses penggabungan banyak pohon keputusan. Tahapan penelitian dilakukan mulai dari pembersihan dan persiapan data, pembagian data menjadi training dan testing, pembangunan model, hingga evaluasi performa menggunakan akurasi, presisi, recall, F1-score, serta confusion matrix. Berdasarkan hasil pengujian, model Random Forest menunjukkan kinerja yang kuat dan konsisten dalam memprediksi kondisi diabetes berdasarkan indikator kesehatan yang tersedia. Temuan ini menunjukkan bahwa pemanfaatan teknologi data mining, khususnya Random Forest pada platform Orange, dapat menjadi solusi praktis untuk mendukung proses analisis medis dan membantu tenaga kesehatan dalam mendeteksi diabetes secara lebih dini dan tepat sasaran.

**Kata Kunci:** Data Mining; Diabetes; Klasifikasi; Orange; Random Forest.

### 1. LATAR BELAKANG

Diabetes merupakan salah satu penyakit kronis yang jumlah penderitanya terus bertambah setiap tahun dan kini menjadi salah satu masalah kesehatan yang paling banyak mendapat perhatian (Sahgal, 2024). Penyakit ini dapat menimbulkan beragam komplikasi serius jika tidak terdeteksi sejak dini, sehingga proses identifikasi risiko sangat penting untuk dilakukan secara cepat dan tepat (Olina et al., 2024). Di tengah perkembangan teknologi, metode data mining dan pembelajaran mesin mulai banyak dimanfaatkan untuk membantu

tenaga medis dalam menganalisis data kesehatan (Sari et al., 2024). Berbagai penelitian terdahulu telah menggunakan algoritma seperti Decision Tree, Logistic Regression, dan Support Vector Machine untuk memprediksi diabetes (Mandias & Manoppo, 2025). namun beberapa di antaranya masih memiliki kelemahan, terutama dalam menghadapi data yang kompleks, berjumlah besar, atau memiliki banyak variabel yang saling berkaitan (Homepage et al., 2024).

Kesenjangan tersebut menunjukkan perlunya metode yang mampu menghasilkan prediksi lebih stabil dan akurat. Random Forest menjadi salah satu algoritma yang menawarkan keunggulan tersebut melalui pendekatan ensemble yang menggabungkan banyak pohon keputusan, sehingga dapat mengurangi risiko overfitting dan meningkatkan performa model secara keseluruhan. Selain itu, belum banyak penelitian yang mengeksplorasi penggunaan platform Orange Data Mining secara mendalam, padahal aplikasi ini memiliki keunggulan berupa workflow visual yang memudahkan proses analisis tanpa memerlukan kemampuan pemrograman (Muhamrom, 2023).

Dengan mempertimbangkan hal tersebut, penelitian ini dilakukan untuk menerapkan algoritma Random Forest pada dataset diabetes menggunakan Orange Data Mining. Tujuan utamanya adalah mengevaluasi sejauh mana model ini mampu mengklasifikasikan risiko diabetes dengan akurat. Hasil penelitian diharapkan dapat memberikan kontribusi terhadap pemanfaatan teknologi data dalam bidang kesehatan, khususnya dalam mendukung proses deteksi dini diabetes secara lebih efisien dan informatif.

## **2. KAJIAN TEORITIS**

### **Diabetes dan Faktor Risiko**

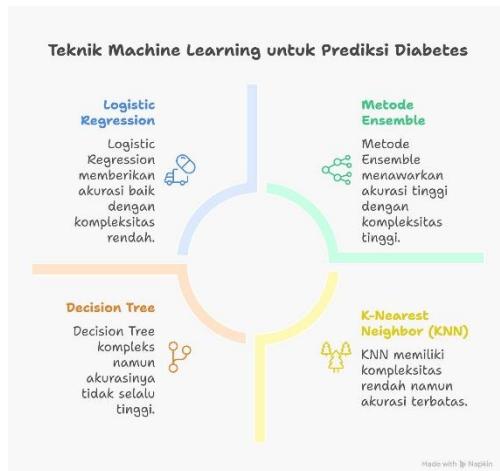
Diabetes merupakan gangguan metabolismik yang ditandai oleh tingginya kadar glukosa dalam darah akibat gangguan pada produksi atau fungsi insulin (Putu et al., 2024). Berbagai faktor dapat memengaruhi risiko terjadinya diabetes, seperti kadar glukosa, tekanan darah, indeks massa tubuh, usia, riwayat keluarga, serta pola hidup (Mahmudah et al., 2025). Dalam penelitian data mining, informasi kesehatan biasanya dimanfaatkan untuk membantu memprediksi kemungkinan terjadinya penyakit, termasuk diabetes. Pemahaman mengenai faktor-faktor risiko ini menjadi dasar dalam pembangunan model klasifikasi untuk membantu proses deteksi dini.



**Gambar 1.** Alur Deteksi Data Diabetes.

### Data Mining dan Machine Learning dalam Kesehatan

Data mining merupakan proses pengolahan dan analisis data untuk menemukan pola, informasi tersembunyi, atau hubungan antarvariabel (Sembiring & Sembiring, 2023). Dalam bidang kesehatan, data mining digunakan untuk mendukung keputusan klinis, memprediksi penyakit, hingga mengidentifikasi faktor risiko. Teknik machine learning, terutama model klasifikasi, sangat bermanfaat dalam mengolah data medis yang biasanya memiliki kompleksitas tinggi. Metode klasifikasi seperti Decision Tree, K-Nearest Neighbor, Logistic Regression, hingga teknik ensemble sering digunakan dalam penelitian prediksi diabetes (Huda et al., 2024).

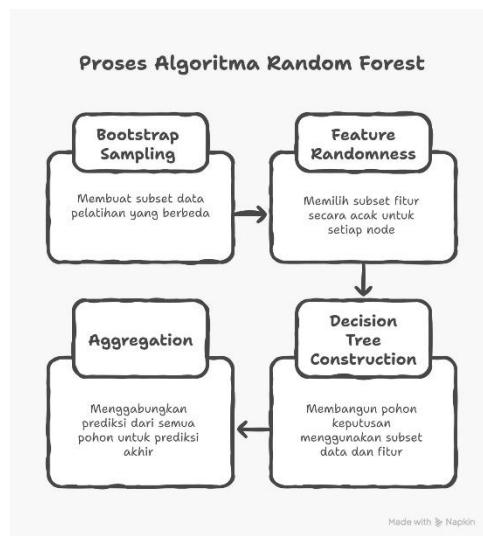


**Gambar 2.** Teknik Machine Learning untuk Prediksi Diabetes.

### Algoritma Random Forest

Random Forest merupakan algoritma ensemble learning yang menggabungkan banyak pohon keputusan (decision tree) untuk menghasilkan prediksi yang lebih stabil dan akurat. Setiap pohon dilatih pada subset data yang berbeda dengan teknik bootstrap, sedangkan pemilihan fitur dilakukan secara acak pada setiap node (Iskandar et al., 2024). Kombinasi banyak pohon ini membuat Random Forest lebih tahan terhadap overfitting dibandingkan

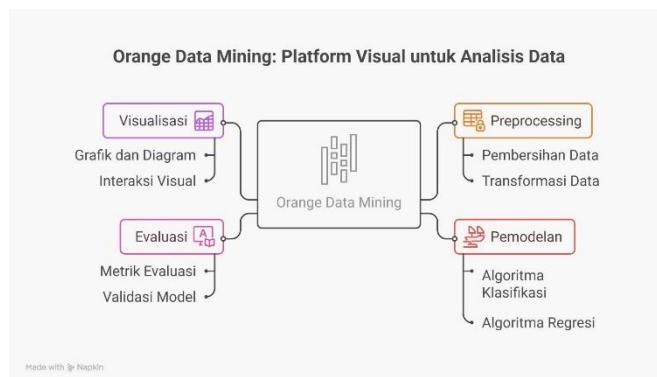
metode tunggal, serta mampu menangani data berdimensi tinggi (Inonu et al., 2025). Keunggulan inilah yang membuat Random Forest populer dalam penelitian klasifikasi medis, termasuk prediksi diabetes (Salsabil et al., 2024).



**Gambar 3.** Proses Algoritma Random Forest.

### Platform Orange Data Mining

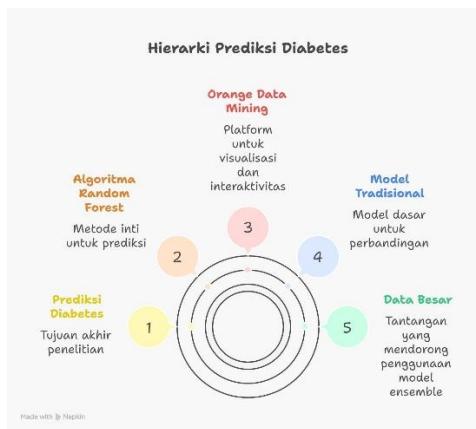
Orange Data Mining adalah perangkat lunak analisis data berbasis visual workflow yang menyediakan berbagai komponen untuk preprocessing, pemodelan, evaluasi, dan visualisasi data (Muharrom, 2023). Platform ini banyak digunakan dalam penelitian karena mudah dioperasikan tanpa memerlukan kemampuan pemrograman, namun tetap menawarkan algoritma dan fitur analisis yang lengkap (Pranadjaya et al., 2024). Penggunaan Orange memungkinkan peneliti membangun pipeline analisis secara cepat dan transparan, sehingga memudahkan proses eksperimen dan validasi model.



**Gambar 4.** Fitur Orange Data Mining.

## Penelitian Terdahulu yang Relevan

Berbagai penelitian sebelumnya telah memanfaatkan machine learning untuk prediksi diabetes. Studi menggunakan Decision Tree dan Logistic Regression menunjukkan hasil yang cukup baik, namun sering mengalami keterbatasan akurasi pada data besar (Sutarman et al., 2024). Penelitian lain menunjukkan bahwa model ensemble seperti Random Forest dan Gradient Boosting cenderung memberikan akurasi lebih tinggi dan kestabilan yang lebih baik (Dwipa Jaya, 2023). Meskipun begitu, masih terbatas penelitian yang mengevaluasi performa Random Forest menggunakan platform Orange Data Mining secara komprehensif. Hal ini menunjukkan adanya ruang kontribusi dan landasan teoritis bagi penelitian ini untuk mengisi gap tersebut.



**Gambar 5.** Hierarki Prediksi Diabetes.

### 3. METODE PENELITIAN

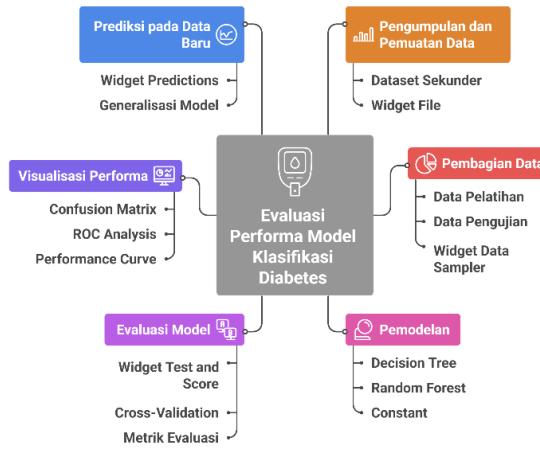
#### Tahapan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan analisis data serta pemodelan klasifikasi berbasis machine learning. Tujuan utamanya adalah menilai kinerja algoritma Decision Tree dan Random Forest dalam mengelompokkan indikator kesehatan yang berkaitan dengan diabetes. Seluruh proses dilakukan menggunakan Orange Data Mining, yang memudahkan pengolahan data secara visual tanpa perlu melakukan pemrograman manual.

Proses penelitian diawali dengan memuat dataset melalui widget File, kemudian membaginya menjadi data pelatihan dan pengujian menggunakan Data Sampler agar evaluasi model berjalan objektif. Data tersebut selanjutnya dialirkan ke tiga algoritma, yaitu Tree, Random Forest, dan Constant. Tree dan Random Forest menjadi model utama yang diuji, sementara Constant berfungsi sebagai baseline untuk melihat perbedaan performa dibandingkan model yang lebih kompleks.

Setiap model dievaluasi menggunakan widget Test and Score melalui metode cross-validation, sehingga menghasilkan metrik seperti akurasi, precision, recall, F1-score, dan AUC (Jurnal & Teknologi, n.d.). Hasil evaluasi ditampilkan melalui Confusion Matrix, ROC Analysis, dan Performance Curve sebagai gambaran menyeluruh dari performa model. Pada tahap akhir, widget Predictions digunakan untuk menguji kemampuan model dalam melakukan prediksi terhadap data baru sehingga dapat dipastikan bahwa model tidak hanya bekerja baik pada data pelatihan, tetapi juga memiliki kemampuan generalisasi yang baik.

Evaluasi Performa Model Klasifikasi Diabetes



Made with Napkin

Gambar 6. Evaluasi Model Klasifikasi Diabetes.

## Pengumpulan Data

Dataset yang digunakan dalam penelitian ini berasal dari platform Kaggle, yang dikenal sebagai penyedia data terbuka untuk analisis data dan machine learning, berikut ini alamat dataset : <https://www.kaggle.com/datasets/mohankrishnathalla/diabetes-health-indicators-dataset>.

#	age	gender	ethnicity	education_level	income_level	employment_status	smoking_status	smokintensity	smoke_hours	preme_hournhistory	diension	livesvascular_hi	bmi	t_to_ip	ip_ystolic	ip_diastolic	ip_cholester	ip_triglyceride	ip_faste	ip_postpr	ip_sulin	ip_lev	hba1c	hts_risk	betes_stressed	diabetes				
1	58	Male	Asian	Highschool	income_level	Employed	Never	0	215	5.7	7.9	0	0	30.5	0.89	134	78	68	239	41	160	145	136	236	8.18	29.6	Type 2	1		
2	50	Female	White	Postgraduate	income_level	Employed	Former	1	141	4.8	6.9	0	0	30.5	0.89	134	78	68	239	41	160	145	136	236	8.18	29.6	Type 2	1		
3	60	Male	Hispanic	Highschool	income_level	Unemployed	Never	1	57	6.4	10.0	8.1	1	0	22.2	0.81	115	73	74	213	66	99	36	118	195	5.07	7.51	44.7	Type 2	1
4	74	Female	Black	Highschool	income_level	Retired	Never	0	49	3.4	6.6	5.2	0	0	26.8	0.88	120	93	68	171	50	79	140	139	253	5.28	9.03	38.2	Type 2	1
5	46	Male	White	Graduate	income_level	Retired	Never	1	109	7.2	7.4	5.0	0	0	21.2	0.78	92	67	67	210	50	125	160	137	184	12.74	7.2	23.3	Type 2	1
6	27	Female	White	Postgraduate	income_level	Retired	Never	1	234	4.2	4.2	4.0	0	0	24.9	0.81	129	77	77	231	49	170	120	130	183	6.31	12.3	30.5	Type 2	1
7	79	Male	White	Graduate	income_level	Retired	Never	0	53	9.2	7.8	8.0	0	1	25.1	0.88	129	77	71	238	46	161	135	101	100	10.14	5.24	36.1	e-Diabetis	0
8	62	Male	Black	Postgraduate	income_level	Unemployed	Current	1	75	4.1	9.0	12.9	0	1	23.9	0.88	128	83	76	241	49	159	120	110	189	8.9	7.04	34.2	Type 2	1
9	42	Male	Black	Highschool	income_level	Employed	Former	1	114	6.7	8.5	8.5	0	0	24.7	0.84	103	71	72	187	33	132	98	114	172	5.7	6.9	26.7	Type 2	1
10	21	Female	White	Postgraduate	income_level	Employed	Former	1	108	4.1	7.3	7.3	0	0	23.9	0.81	129	70	70	191	52	131	109	109	169	8.49	5.97	30.5	Type 2	1
11	49	Female	White	Highschool	income_level	Employed	Never	1	118	7.5	5.2	5.4	0	0	24.8	0.86	109	85	66	144	44	79	182	124	177	14.48	7.34	25.3	Type 2	1
12	43	Female	White	Highschool	income_level	Employed	Former	1	167	7.2	6.9	5.1	0	1	22.3	0.76	119	69	66	163	59	61	49	117	183	12.93	7.4	18.5	Type 2	1
13	54	Male	White	Highschool	income_level	Employed	Former	2	13	6.7	6.9	7.7	0	0	31.2	0.94	120	84	79	196	40	118	222	123	150	17.86	6.88	37.5	Type 2	1
14	19	Male	White	Postgraduate	income_level	Employed	Former	1	94	5.9	6.9	2.0	0	0	24.9	0.84	104	76	76	231	44	128	128	128	137	9.37	5.97	30.5	Type 2	1
15	22	Male	Asian	Highschool	income_level	Employed	Never	3	105	2.0	9.2	1.9	0	0	31.4	0.81	113	69	62	188	47	100	131	103	152	16.58	5.88	21.1	e-Diabetis	0
16	43	Male	Hispanic	Highschool	income_level	Student	Never	0	99	6.6	5.7	3.7	0	0	25.9	0.86	118	76	62	127	54	61	140	110	147	10.14	6.05	24.1	e-Diabetis	0
17	41	Male	White	Highschool	income_level	Retired	Current	2	31	5.3	6.3	8.4	0	1	20.3	0.83	107	70	87	206	56	112	73	103	187	6.63	6.88	23.1	Type 2	1
18	34	Male	White	Postgraduate	income_level	Retired	Never	1	34	4.1	7.0	7.0	0	0	24.9	0.81	129	73	73	191	52	131	109	109	188	8.49	5.97	30.5	Type 2	1
19	39	Male	White	Graduate	income_level	Employed	Current	0	14	5.4	7.8	8.2	0	0	18.0	0.77	100	76	82	184	40	114	148	101	167	2.0	6.61	26.1	Type 2	1
20	27	Male	White	No formal	income_level	Student	Former	2	164	8.6	9.3	9.0	0	0	22.8	0.84	99	58	74	150	61	63	148	91	170	10.0	6.23	16.0	e-Diabetis	0
21	73	Male	White	Graduate	income_level	Retired	Never	3	118	4.8	7.2	6.3	0	0	29.8	0.75	126	81	63	220	72	103	140	121	145	3.29	6.51	34.3	e-Diabetis	0
22	29	Female	White	Postgraduate	income_level	Employed	Former	2	247	7.2	7.2	7.2	0	0	23.8	0.86	136	95	91	247	47	147	147	147	147	24.7	7.04	30.5	Type 2	1
23	53	Female	White	Graduate	income_level	Retired	Former	1	241	8.8	4.5	2.0	0	0	27.4	0.84	91	76	77	208	73	96	89	99	117	6.09	5.42	19.6	e-Diabetis	0
24	27	Female	Hispanic	Graduate	income_level	Employed	Never	0	105	6.2	5.6	7.5	1	0	25.4	0.84	90	76	77	206	73	96	44	132	163	2.15	7.18	35.0	Type 2	1
25	41	Female	White	Highschool	income_level	Employed	Former	0	185	3.7	7.6	7.4	0	0	26.2	0.88	118	69	64	167	57	68	172	117	164	18.18	7.01	23.3	Type 2	1
26	27	Female	White	Postgraduate	income_level	Employed	Former	1	298	4.2	7.0	7.0	0	0	21.9	0.81	149	70	70	201	51	121	119	119	147	9.37	5.97	30.5	Type 2	1
27	32	Female	White	Highschool	income_level	Retired	Former	0	148	4.5	8.0	8.4	1	0	27.8	0.92	109	74	62	213	57	136	163	107	194	13.5	7.39	38.2	Type 2	1
28	56	Male	White	Postgraduate	income_level	Employed	Never	5	88	7.0	6.8	4.2	0	0	24.6	0.86	134	73	62	222	64	121	52	103	148	16.67	6.89	26.4	Type 2	1
29	40	Male	Hispanic	Highschool	income_level	Retired	Current	2	29	3.3	4.9	5.2	0	1	18.5	0.76	113	71	65	155	59	71	118	107	167	8.07	6.6	24.4	Type 2	1
30	31	Female	White	Postgraduate	income_level	Employed	Former	1	215	13.1	5.1	8.1	1	0	24.9	0.81	139	71	71	145	49	150	120	120	148	18.13	7.04	30.5	Type 2	1
31	40	Male	White	Highschool	income_level	Employed	Never	3	182	5.9	5.1	5.9	0	0	20.6	0.85	95	58	68	160	67	59	68	100	146	10.32	6.45	17.3	e-Diabetis	0
32	80	Female	White	Highschool	income_level	Employed	Never	2	48	5.2	7.2	5.7	0	0	30.7	0.95	143	84	70	196	63	95	121	110	146	13.71	6.25	39.0	e-Diabetis	0
33	50	Female	White	Postgraduate	income_level	Employed	Never	2	106	6.7	7.4	5.1	0	0	19.6	0.78	122	59	58	168	59	121	104	104	120	2.0	7.09	23.1	Type 2	1
34	35	Male	White	Postgraduate	income_level	Employed	Former	1	215	4.9	5.9	5.9	0	0	24.2	0.81	129	67	67	191	49	106	218	211	222	24.7	7.04	30.5	Type 2	1
35	63	Male	White	Highschool	income_level	Employed	Never	0	53	8.4	5.8	5.4	1	0	29.4	0.87	122	77	74	235	51	142	140	119	167	16.61	6.78	49.6	Type 2	1
36	37	Female	Black	Highschool	income_level	Employed	Current	0	170	0.8	5.9	3.9	0	1	20.8	0.85	97	58	76	182	46	107	124	175	175	7.09	18.7	Type 2	1	
37	53	Female	White	Postgraduate	income_level	Employed	Former	1	72	7.4	7.6	5.3	0	0	24.1	0.91	114	90	82	196	44	117	93	109	140	10.15	6.06	28.4	e-Diabetis	0
38	30	Female	White	Highschool	income_level	Employed	Current	1	131	0.8	5.9	1	0	0	24.2	0.81	129	70	70	149	50	103	127	127	148	7.09	5.97	30.5	Type 2	1
39	60	Female	White	Highschool	income_level	Employed	Never	3	34	5.4	6.8	8.8	1	0	20.2	0.79	111	79	87	162	59	74	46	120	168	11.11	7.52	36.8	Type 2	1
40	53	Female	Asian	Highschool	income_level	Employed	Former	0	78	7.4	6.8	9.0	0	1	23.4	0.85	124	60	65	176	65	74	82	112	158	9.23	6.42	26.6	e-Diabetis	0
41	62	Male	Black	Highschool	income_level	Employed	Current	3	59	5.5	7.2	5.8	1	0	20.6	0.87	112	76	85	237	47	163	188	120	159	22.04	6.68	51.9	Type 2	1
42	53	Male	Hispanic	Highschool	income_level	Retired	Current																							

Data tersebut berisi berbagai indikator kesehatan yang berkaitan dengan risiko diabetes, seperti kadar glukosa darah, tekanan darah, usia, indeks massa tubuh (BMI), serta atribut pendukung lainnya. Dataset diunduh dalam format CSV dan diimpor ke aplikasi Orange Data Mining melalui widget File.

Columns (Double click to edit)			
	Name	Type	Role
25	glucose_fasting	N numeric	feature
26	glucose_postpr...	N numeric	feature
27	insulin_level	N numeric	feature
28	hba1c	N numeric	feature
29	diabetes_risk_sc...	N numeric	feature
30	diabetes_stage	C categorical	target
			Gestational, No Diabetes, Pre-Diabetes...
31	diagnosed_diab...	C categorical	feature
			0, 1

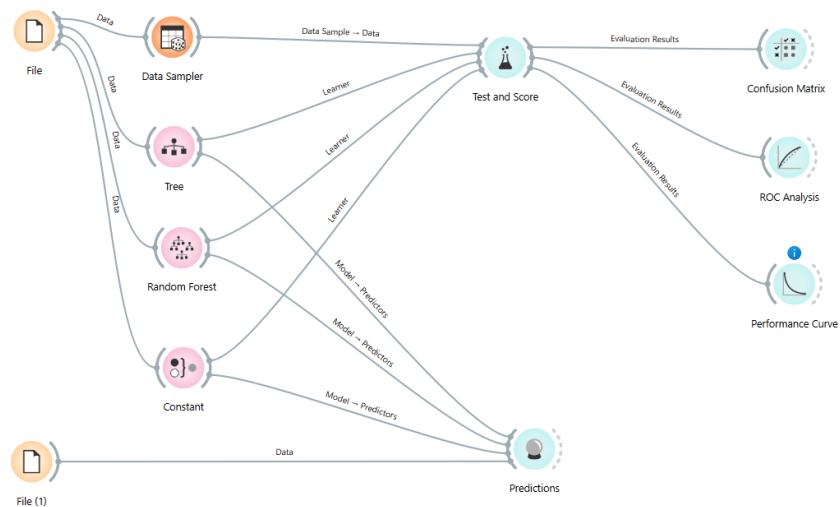
**Gambar 8.** Format Columns.

Setelah data berhasil dimuat, proses verifikasi dilakukan pada menu Columns untuk memastikan setiap atribut berada pada tipe dan peran yang benar. Pada tahap ini, variabel seperti glucose\_fasting, glucose\_postprandial, insulin\_level, hba1c, dan diabetes\_risk\_score teridentifikasi sebagai fitur bertipe numerik, sedangkan beberapa atribut lain seperti diagnosed\_diabetes terdeteksi sebagai fitur kategorikal. Variabel diabetes\_stage ditetapkan sebagai target klasifikasi dengan nilai kategori seperti Gestational, No Diabetes, dan Pre-Diabetes. Pemeriksaan ini juga memastikan bahwa tidak ada kesalahan penempatan role serta seluruh tipe data sudah sesuai dengan kebutuhan pemodelan. Setelah seluruh atribut terdefinisi dengan benar, dataset kemudian siap digunakan untuk proses pelatihan, pengujian, dan evaluasi performa model klasifikasi dalam penelitian ini.

## Analisa Data

Analisis data pada penelitian ini dilakukan menggunakan tiga algoritma klasifikasi, yaitu Decision Tree, Random Forest, dan Constant Model, yang seluruh prosesnya dibangun melalui workflow Orange Data Mining. Dataset terlebih dahulu dimuat dan dibagi menjadi data latih dan uji menggunakan Data Sampler, kemudian masing-masing model diterapkan dengan konfigurasi yang konsisten agar hasil evaluasi tetap objektif. Decision Tree menyusun struktur pohon berdasarkan atribut paling informatif, lalu performanya dinilai menggunakan Test & Score, Confusion Matrix, dan ROC untuk melihat kemampuan pemisahan kelas (Hozairi et al., 2021). Random Forest menjadi model utama karena memanfaatkan banyak pohon keputusan melalui teknik bootstrap, sehingga memberikan prediksi yang lebih stabil dan umumnya

menghasilkan akurasi paling tinggi (Hidayah & Rosadi, 2024). Sebagai pembanding, Constant Model digunakan sebagai baseline yang hanya menebak kelas mayoritas tanpa proses pembelajaran, sehingga skor akurasi maupun AUC relatif rendah dan mendekati prediksi acak. Seluruh hasil model kemudian divisualisasikan melalui Predictions untuk melihat kecenderungan keluaran pada data uji. Secara ringkas, analisis ini menggambarkan efektivitas masing-masing algoritma dalam mengklasifikasikan data diabetes dan menunjukkan keunggulan Random Forest sebagai model terbaik dalam workflow penelitian.



**Gambar 9.** Workflow Klasifikasi Diabetes.

#### 4. HASIL DAN PEMBAHASAN

Pengolahan data pada penelitian ini dilakukan menggunakan workflow analisis berbasis machine learning pada aplikasi Orange Data Mining, yang melibatkan tahapan pemuatan data, pemisahan dataset, pembangunan model, hingga evaluasi performa menggunakan berbagai metrik. Tiga algoritma utama yang digunakan yaitu Decision Tree, Random Forest, dan Constant Model sebagai model pembanding (baseline). Seluruh proses analisis mengikuti alur kerja pada workflow, dimulai dari File → Data Sampler → (Decision Tree / Random Forest / Constant Model) → Test & Score → Confusion Matrix → ROC Analysis → Predictions. Tahapan ini memungkinkan proses pemodelan dilakukan secara sistematis serta memudahkan peneliti dalam membandingkan performa antar algoritma secara objektif.

Evaluation results for target (None, show average over classes)						
Model	AUC	CA	F1	Prec	Recall	MCC
Random Forest	-1.692	0.996	0.994	0.992	0.996	0.992
Tree	-1.697	0.996	0.994	0.992	0.996	0.992
Constant	-0.843	0.598	0.448	0.358	0.598	0.000

**Gambar 10.** Hasil Tes & Score.

Hasil evaluasi menunjukkan bahwa Random Forest dan Decision Tree memiliki performa yang hampir sama dan sangat tinggi, dengan akurasi, F1-score, precision, recall, dan MCC berada pada rentang 0.992–0.996. Nilai ini mencerminkan kemampuan prediksi yang sangat stabil dan kuat, sementara AUC yang tampil negatif merupakan karakteristik visualisasi Orange pada kasus multi-kelas dan tidak menunjukkan penurunan performa. Di sisi lain, Constant Model memiliki kinerja yang jauh lebih rendah dengan akurasi 0.598 dan metrik lain yang juga rendah, menandakan bahwa model ini hanya mengandalkan tebakan kelas mayoritas. Dengan demikian, Random Forest dan Decision Tree terbukti jauh lebih unggul dibandingkan model baseline.

### Pengolahan Menggunakan Decision Tree

Model Decision Tree dibangun menggunakan widget *Tree* untuk membentuk struktur pohon keputusan berdasarkan atribut yang paling informatif dalam membedakan kelas diabetes. Dataset yang telah dibagi melalui *Data Sampler* kemudian dilatih menggunakan algoritma ini, dan hasilnya dievaluasi melalui *Test & Score*. Hasil evaluasi ini selanjutnya diteruskan ke widget Confusion Matrix, ROC Analysis, dan Performance Curve untuk melihat kinerja model dari berbagai sisi.

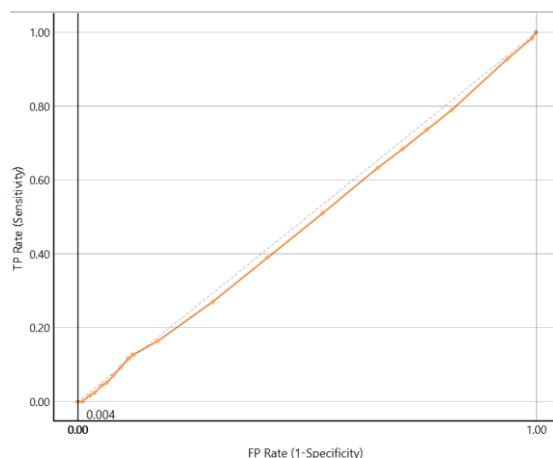
### Confusion Matrix

		Predicted					$\Sigma$
		Gestational	No Diabetes	Pre-Diabetes	Type 1	Type 2	
Actual	Gestational	0	31	87	0	182	300
	No Diabetes	0	8330	0	0	0	8330
	Pre-Diabetes	0	0	33440	0	0	33440
	Type 1	0	23	40	0	67	130
	Type 2	0	0	0	0	62800	62800
		$\Sigma$	0	8384	33567	0	63049
							105000

**Gambar 11.** Hasil Confusion Matrix Decision Tree.

Hasil evaluasi ditinjau lewat Confusion Matrix, yang pada gambar menunjukkan bahwa model sangat tepat dalam mengenali kelas **Pre-Diabetes** (33.440 prediksi benar) dan **Type 2** (62.800 prediksi benar). Sebaliknya, kelas **Gestational** banyak salah diprediksi terutama sebagai **Type 2**, kelas **No Diabetes** hanya terklasifikasi benar pada 8.330 kasus, dan kelas **Type 1** masih tercampur dengan prediksi ke Pre-Diabetes dan Type 2. Analisis kemampuan pemisahan tiap kelas dilanjutkan melalui ROC Analysis, sementara widget Predictions digunakan untuk menampilkan hasil prediksi akhir pada data uji.

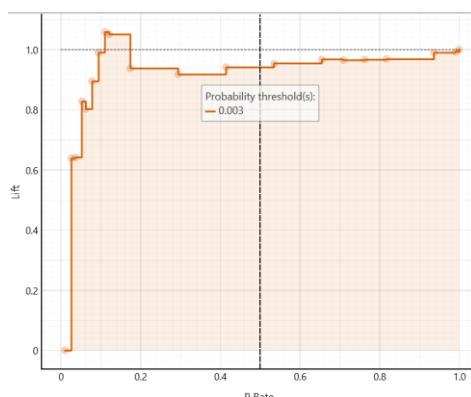
#### **ROC Analysis**



**Gambar 12.** Hasil ROC Analysis Decision Tree.

Hasil evaluasi ditinjau dengan ROC Analysis, yang menunjukkan Kurva Decision Tree berada dekat dengan garis diagonal, menunjukkan performa yang lemah dalam mendeteksi kelas Gestational. Model ini kurang mampu memisahkan kelas karena data Gestational yang sedikit dan kecenderungan Tree untuk overfitting.

#### **Performance Curve**



**Gambar 13.** Hasil Performance Curve Decision Tree.

Hasil evaluasi ditinjau dengan Performance Curve, yang menunjukkan Kurva Decision Tree terlihat mendekati nilai lift = 1, yang berarti performanya hanya sedikit lebih baik daripada tebakan acak. Lift yang rendah dan fluktuatif menunjukkan bahwa Decision Tree tidak mampu

menangkap pola yang cukup kuat untuk mendeteksi kelas Gestational yang jumlahnya sangat kecil. Area under the curve 0.921 menunjukkan performa yang lemah dan hampir tidak memberikan keuntungan dibandingkan baseline.

### Pengolahan Menggunakan Random Forest

Random Forest diterapkan sebagai model utama karena kemampuannya menggabungkan banyak pohon keputusan sehingga menghasilkan prediksi yang lebih stabil dan tahan terhadap overfitting (Putra, 2025). Evaluasi melalui Test & Score, Confusion Matrix, ROC Analysis, dan Performance Curve menunjukkan bahwa model ini bekerja sangat baik.

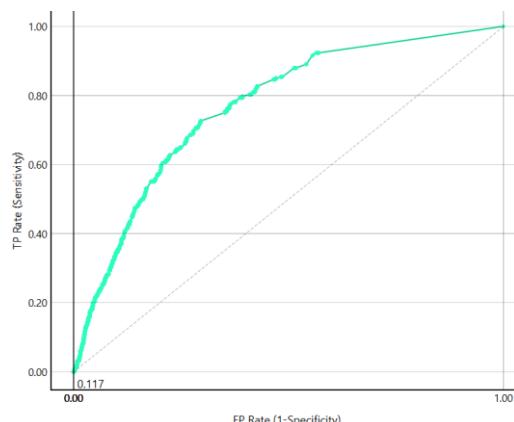
#### *Confusion Matrix*

		Predicted					$\Sigma$
		Gestational	No Diabetes	Pre-Diabetes	Type 1	Type 2	
Actual	Gestational	0	31	87	0	182	300
	No Diabetes	0	8323	7	0	0	8330
	Pre-Diabetes	0	0	33440	0	0	33440
	Type 1	0	23	40	0	67	130
	Type 2	0	0	0	0	62800	62800
		$\Sigma$	0	8377	33574	0	63049
							105000

**Gambar 14.** Hasil Confusion Matrix Random Forest.

Berdasarkan Confusion Matrix, Random Forest mampu mengklasifikasikan kelas besar seperti Pre-Diabetes (33.440 benar) dan Type 2 (62.800 benar) hampir tanpa kesalahan, serta mengidentifikasi No Diabetes secara konsisten dengan 8.323 prediksi akurat. Meski kelas minor seperti Gestational dan Type 1 masih mengalami sedikit salah klasifikasi, performanya tetap jauh lebih unggul dibanding Decision Tree maupun Constant Model. Secara keseluruhan, Random Forest terbukti paling efektif dalam menangkap pola kompleks pada dataset dan memberikan akurasi prediksi yang sangat tinggi.

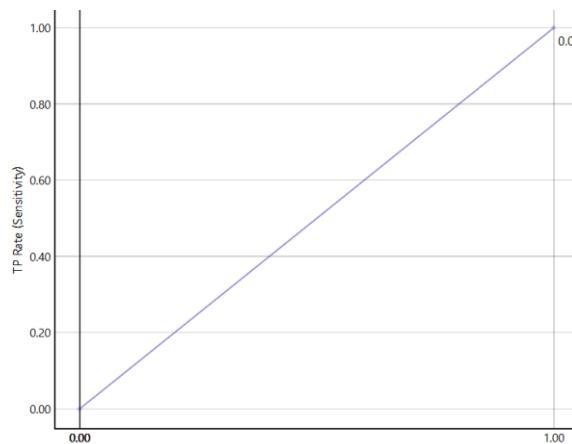
#### *ROC Analysis*



**Gambar 15.** ROC Analysis Random Forest.

Berdasarkan ROC Analysis Kurva ROC Random Forest tampak naik tajam dan berada jauh di atas garis diagonal, menunjukkan kemampuan yang jauh lebih baik dalam membedakan kelas Gestational. Model ini memiliki sensitivitas yang lebih stabil dan akurat meskipun jumlah data Gestational sangat kecil.

### **Performance Curve**



**Gambar 16.** Performance Curve Random Forest.

Berdasarkan Performance Curve, Lift Curve Random Forest naik sangat tinggi di awal karena model ini mampu mengenali kelas Gestational yang jumlahnya sangat sedikit. Nilai lift kemudian menurun secara bertahap namun tetap berada di atas baseline, menunjukkan performa yang konsisten lebih baik. Pola ini sejalan dengan hasil Confusion Matrix yang menunjukkan bahwa Random Forest bekerja paling efektif.

### **Pengolahan Menggunakan Constant Model**

Constant Model digunakan sebagai model baseline yang hanya memprediksi satu kelas, yaitu kelas mayoritas. Evaluasi melalui Test & Score, Confusion Matrix, ROC Analysis, dan Performance Curve.

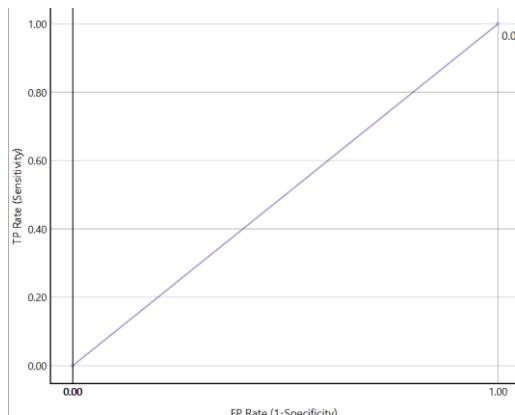
### **Confusion Matrix**

		Predicted					$\Sigma$
		Gestational	No Diabetes	Pre-Diabetes	Type 1	Type 2	
Actual	Gestational	0	0	0	0	300	300
	No Diabetes	0	0	0	0	8330	8330
	Pre-Diabetes	0	0	0	0	33440	33440
	Type 1	0	0	0	0	130	130
	Type 2	0	0	0	0	62800	62800
$\Sigma$		0	0	0	0	105000	105000

**Gambar 17.** Hasil Confusion Matrix Constan Model.

Pada Confusion Matrix terlihat bahwa seluruh data—termasuk Gestational, No Diabetes, Pre-Diabetes, maupun Type 1—dipetakan menjadi Type 2, sehingga tidak ada klasifikasi benar pada keempat kelas lainnya. Kondisi ini menghasilkan akurasi yang rendah dan performa yang tidak informatif karena model tidak melakukan pembelajaran apa pun. Meski sangat sederhana, model ini tetap penting sebagai pembanding untuk menunjukkan bahwa Random Forest dan Decision Tree memberikan peningkatan performa yang signifikan dalam proses klasifikasi.

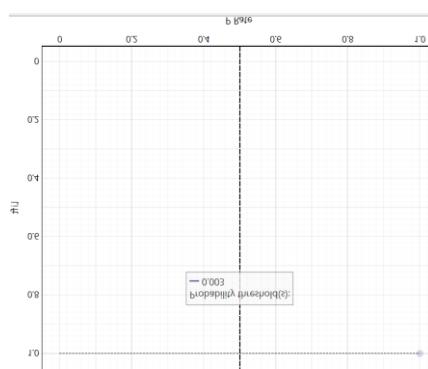
### ***ROC Analysis***



**Gambar 18.** ROC Analysis Constan Model.

Berdasarkan Kurva Constant tepat mengikuti garis diagonal, menandakan performa setara prediksi acak. Model ini berfungsi sebagai pembanding dasar untuk melihat apakah model lain bekerja lebih baik dari baseline.

### ***Performance Curve***



**Gambar 19.** Hasil Performance Curve Constan Model.

Model Constant membentuk garis datar pada  $\text{lift} = 1$  sepanjang kurva. Hal ini wajar karena model ini tidak melakukan proses klasifikasi dan hanya menjadi pembanding dasar untuk melihat apakah model lain memberikan peningkatan performa.

## Interpretasi Hasil Prediksi

Pada tahap akhir, widget Predictions digunakan untuk menampilkan keluaran dari setiap model terhadap data baru yang tidak digunakan selama proses pelatihan. Hasil prediksi memperlihatkan bagaimana ketiga algoritma Random Forest, Decision Tree, dan Constant Model, memberikan klasifikasi untuk setiap entri berdasarkan variabel input yang tersedia.

	Random Forest	Tree	Constant	age	gender	ethnicity	education_level	income_level	employment_status	smoking_status	consumption_pc	activity_minutes	diet
1	Type 2	Type 2	Type 2	58	Male	Asian	Highschool	Lower Middle	Employed	Never	0	215	5.7
2	No Diabetes	No Diabetes	Type 2	48	Female	White	Highschool	Middle	Employed	Former	1	143	6.7
3	Type 2	Type 2	Type 2	60	Male	Hispanic	Highschool	Middle	Unemployed	Never	1	57	6.4
4	Type 2	Type 2	Type 2	74	Female	Black	Highschool	Low	Retired	Never	0	49	3.4
5	Type 2	Type 2	Type 2	46	Male	White	Graduate	Middle	Retired	Never	1	109	7.2
6	Pre-Diabetes	Pre-Diabetes	Type 2	46	Female	White	Highschool	Upper Middle	Employed	Never	2	124	5.0
7	Pre-Diabetes	Pre-Diabetes	Type 2	75	Female	White	Graduate	Upper Middle	Retired	Never	0	53	5.2
8	Type 2	Type 2	Type 2	62	Male	Postgraduate	Middle	Unemployed	Current	1	75	4.1	
9	Type 2	Type 2	Type 2	42	Male	Black	Highschool	Lower Middle	Employed	Current	1	114	6.7
10	No Diabetes	No Diabetes	Type 2	59	Female	White	Graduate	Middle	Employed	Current	2	86	3.2
11	Type 2	Type 2	Type 2	43	Female	White	Highschool	Middle	Employed	Never	1	118	7.5
12	Type 2	Type 2	Type 2	43	Female	White	Highschool	Middle	Employed	Former	1	167	7.2
13	Type 2	Type 2	Type 2	54	Female	White	Highschool	Middle	Employed	Never	2	13	6.7
14	No Diabetes	No Diabetes	Type 2	19	Male	White	Graduate	Lower Middle	Employed	Former	0	364	5.7
15	Pre-Diabetes	Pre-Diabetes	Type 2	22	Male	Asian	Highschool	Lower Middle	Employed	Never	1	105	7.0
16	Pre-Diabetes	Pre-Diabetes	Type 2	41	Male	Hispanic	Highschool	Lower Middle	Student	Never	0	99	6.6
17	Type 2	Type 2	Type 2	34	Male	White	Highschool	Middle	Retired	Current	2	31	5.3
18	Type 2	Type 2	Type 2	55	Female	Black	Graduate	Lower Middle	Retired	Never	1	54	3.4
19	Type 2	Type 2	Type 2	35	Male	White	Graduate	High	Employed	Current	0	14	5.4
20	Pre-Diabetes	Pre-Diabetes	Type 2	27	Male	White	No formal	Middle	Student	Former	2	164	8.6
21	Pre-Diabetes	Pre-Diabetes	Type 2	73	Male	White	Graduate	Upper Middle	Retired	Never	2	128	4.8
22	Pre-Diabetes	Pre-Diabetes	Type 2	46	Female	Black	Highschool	Middle	Unemployed	Former	1	147	5.0
23	No Diabetes	No Diabetes	Type 2	51	Male	Hispanic	Graduate	Lower Middle	Retired	Former	1	241	8.8
24	Type 2	Type 2	Type 2	27	Female	Hispanic	Highschool	Low	Employed	Never	0	105	6.2
25	Type 2	Type 2	Type 2	41	Female	White	Highschool	Lower Middle	Employed	Never	0	185	5.7

Gambar 20. Hasil Prediksi.

Dari keluaran tersebut terlihat bahwa Random Forest mampu menghasilkan prediksi yang lebih konsisten dan selaras dengan pola data, dibandingkan dengan Decision Tree yang cenderung mengalami variasi keputusan, serta Constant Model yang hanya berfungsi sebagai tolok ukur dasar tanpa kemampuan prediktif yang signifikan. Temuan ini menegaskan bahwa Random Forest merupakan metode yang paling andal dalam memetakan tahap diabetes pada dataset penelitian ini, berkat akurasi yang lebih tinggi serta performa generalisasi yang lebih baik terhadap data baru.

## 5. KESIMPULAN DAN SARAN

Penelitian ini bertujuan mengelompokkan tahapan diabetes menggunakan algoritma Random Forest, Decision Tree, dan Constant Model melalui platform Orange Data Mining. Dari seluruh proses evaluasi yang dilakukan, Random Forest terbukti memberikan performa paling kuat dan stabil dalam memprediksi kelas diabetes dibandingkan dua model lainnya. Decision Tree masih menunjukkan kinerja yang cukup baik namun cenderung kurang konsisten pada kelas dengan jumlah data kecil, sedangkan Constant Model hanya berfungsi sebagai acuan dasar karena tidak mempelajari pola data dan selalu memprediksi kelas mayoritas. Berdasarkan temuan tersebut, dapat disimpulkan bahwa Random Forest merupakan metode yang paling efektif untuk klasifikasi tahap diabetes pada dataset penelitian ini, meskipun generalisasinya

tetap perlu dilakukan dengan hati-hati mengingat penelitian hanya menggunakan satu sumber data dan satu lingkungan analisis.

Untuk pengembangan penelitian selanjutnya, disarankan agar dilakukan pengujian menggunakan algoritma lain seperti Gradient Boosting, XGBoost, atau model berbasis jaringan saraf guna mengetahui apakah terdapat pendekatan yang mampu mengungguli Random Forest. Peningkatan kualitas data melalui teknik penyeimbangan seperti SMOTE juga dapat dilakukan agar model lebih optimal dalam mengenali kelas minor yang jumlahnya terbatas, seperti Gestational dan Type 1. Selain itu, penggunaan dataset dari sumber yang lebih beragam maupun data klinis langsung dari institusi kesehatan akan membantu menghasilkan model yang lebih representatif dan relevan pada kondisi di lapangan..

## **UCAPAN TERIMA KASIH**

Penulis mengucapkan apresiasi yang sebesar-besarnya kepada semua pihak yang telah memberikan dukungan selama penelitian ini berlangsung, baik berupa fasilitas, arahan, maupun kesempatan untuk menyelesaikan studi ini. Ketersediaan dataset dari Kaggle serta pemanfaatan platform Orange Data Mining sangat membantu dalam memperlancar proses analisis. Ucapan terima kasih juga penulis sampaikan kepada dosen pembimbing dan institusi pendidikan yang telah memberikan bimbingan akademik serta ruang bagi penulis untuk mengembangkan penelitian ini hingga tuntas.

## **DAFTAR REFERENSI**

- Dwipa Jaya, M. K. (2023). Perbandingan Random Forest, Decision Tree, Gradient Boosting, Logistic Regression untuk klasifikasi penyakit jantung. *JNATIA*, 2(November), 1–5.
- Hidayah, L., & Rosadi, M. I. (2024). Penerapan algoritma Random Forest untuk memprediksi jumlah santri baru. *Jurnal Informatika dan Teknik Elektro Terapan*, 12(3S1). <https://doi.org/10.23960/jitet.v12i3s1.5237>
- Homepage, J., Dwinnie, C., Dwynne, C., Islam, M. J., & Universitas Islam Negeri Sultan Syarif Kasim Riau. (2024). Comparison of machine learning algorithms in diabetes risk classification. *IJATIS: Indonesian Journal of Applied Technology and Innovation Science*, 1(2), 54–60.
- Hozairi, H., Anwari, A., & Alim, S. (2021). Implementasi Orange Data Mining untuk klasifikasi kelulusan mahasiswa dengan model K-Nearest Neighbor, Decision Tree serta Naive Bayes. *Network Engineering Research Operation*, 6(2), 133. <https://doi.org/10.21107/nero.v6i2.237>
- Huda, R. N., Fitriadi, R., & Wibowo, A. (2024). Optimization product recommendation using K-Means, Agglomerative Clustering and FP-Growth algorithm. *Jurnal Teknik Informatika (JUTIF)*, 5(4), 953–960. <https://doi.org/10.52436/1.jutif.2024.5.4.1901>

- Inonu, O. Y., Magda, K., & Amarudin, A. (2025). Analisis kinerja algoritma Random Forest dengan model machine learning pada dataset penyakit diabetes. *EXPERT: Jurnal Manajemen Sistem Informasi dan Teknologi*, 15(1), 1. <https://doi.org/10.36448/expert.v15i1.4312>
- Iskandar, R. F. N., Gutama, D. H., Wijaya, D. P., & Danianti, D. (2024). Klasifikasi menggunakan metode Random Forest untuk awal deteksi Diabetes Melitus Tipe 2. *Jurnal Teknik Industri Terintegrasi*, 7(3), 1620–1626. <https://doi.org/10.31004/jutin.v7i3.26916>
- Jurnal H., & Teknologi, F. (n.d.). Penerapan Orange Data Mining untuk pembelajaran sistem gambar hewan berbasis machine learning. *X(X)*, 42–49.
- Mahmudah, M., Izza, N., Indrawati, L., Paramita, A., & Indriani, D. (2025). The contributing factors to the risk of diabetes mellitus among Indonesian urban workers. *Nurse Media Journal of Nursing*, 15(1), 98–109. <https://doi.org/10.14710/nmjn.v15i1.56916>
- Mandias, G. F., & Manoppo, I. J. (2025). Analisis komparatif algoritma klasifikasi untuk prediksi diabetes menggunakan pembelajaran mesin. 27(1), 49–56.
- Muharrom, M. (2023). Analisis penggunaan Orange Data Mining untuk prediksi harga USDT/BIDR Binance. *Bulletin of Information Technology (BIT)*, 4(2), 178–184. <https://doi.org/10.47065/bit.v4i2.654>
- Olina, Y. B., Aisah, S., Setyawati, D., Baidhowy, A. S., Nurkharistna, M., Jihad, A., & Arifianto, N. (2024). Meningkatkan kesadaran hidup sehat melalui skrining deteksi dini penyakit tidak menular di lingkungan Universitas Muhammadiyah Semarang. 4(1).
- Pranadjaya, E., Pangestu, E. S., Sereati, C. O., Octaviani, S., & Darmawan, M. (2024). Perbandingan algoritma machine learning menggunakan Orange Data Mining untuk klasifikasi jenis kendaraan pada sistem tilang digital. *Jurnal Elektro*, 17(1), 41–47. <https://doi.org/10.25170/jurnalelektron.v17i1.5429>
- Putra, H. (2025). Comparative study of logistic regression, Random Forest, and XGBoost for bank loan approval classification. 9(5), 2822–2835.
- Putu, N., Dharmayanti, D., Darmini, A. A. A. Y., Wayan, N., Dharmapatni, K., & Keperawatan. (2024). Pengetahuan penderita diabetes mellitus tentang pencegahan ulkus diabetik melalui penyuluhan. *Jurnal Abdimas ITEKES*, 3(2), 70–74. <https://ejournal.itekes-bali.ac.id/jai>
- Sahgal, A. (2024). Опыт аудита обеспечения качества и безопасности медицинской деятельности... *Вестник Росздравнадзора*, 4(1), 9–15.
- Salsabil, M., Lutvi, N., & Eviyanti, A. (2024). Implementasi data mining dalam melakukan prediksi penyakit diabetes menggunakan metode Random Forest dan XGBoost. *Jurnal Ilmiah Komputasi*, 23(1), 51–58. <https://doi.org/10.32409/jikstik.23.1.3507>
- Sari, Z. D. R., Jasimir, J., & Arvita, Y. (2024). Penerapan data mining untuk prediksi penyakit diabetes. *Jurnal Informatika dan Rekayasa Komputer (JAKAKOM)*, 4(April), 827–834.
- Sembiring, Y. A. B., & Sembiring, E. A. (2023). Implementasi data mining menggunakan algoritma Apriori dalam menentukan persediaan barang. *ADA Journal of Information System Research*, 1(1), 1–8. <https://doi.org/10.64366/adajisr.v1i1.7>
- Sutarman, S., Siringoringo, R., Arisandi, D., Kurniawan, E., & Nababan, E. B. (2024). Model klasifikasi dengan Logistic Regression dan Recursive Feature Elimination pada data tidak seimbang. *Jurnal Teknologi Informatika dan Ilmu Komputer*, 11(4), 735–742. <https://doi.org/10.25126/jtiik.1148198>