

KOMPARASI PERFORMA MODEL BERBASIS ALGORITMA RANDOM FOREST DAN LIGHTGBM DALAM MELAKUKAN KLASIFIKASI DIABETES MELITUS GESTASIONAL

Bagus Rizky Prasetyo¹, Eka Dyar Wahyuni², Prisa Marga Kusumantara³

^{1,2,3} Program Studi Sistem Informasi; Fakultas Ilmu Komputer; Universitas Pembangunan Nasional “Veteran” Jawa Timur; Jl. Rungkut Madya No.1, Gn. Anyar, Kec. Gn. Anyar, Surabaya, Jawa Timur 60294

Received: 10 Juli 2024
Accepted: 31 Juli 2024
Published: 7 Agustus 2024

Keywords:

Random Forest; LightGBM;
Diabetes Melitus Gestasional;
Klasifikasi

Correspondent Email:

bagusprasetyo877@gmail.com

Abstrak. Diabetes melitus gestasional (DMG) merupakan suatu kondisi yang ditandai dengan adanya kenaikan level dalam kandungan gula darah seorang ibu pada masa kehamilan. Ibu yang terindikasi menderita diabetes melitus gestasional berpotensi mengidap beberapa komplikasi serius apabila tidak ditangani dengan baik. Deteksi dini melalui penggunaan data rekam medis dilakukan sebagai langkah preventif pencegahan komplikasi dikemudian hari. Kerangka kerja CRISP-DM digunakan dalam pembangunan model. Data diperoleh dari poli kandungan Rumah Sakit Islam Surabaya Jemursari dengan jumlah 270 baris dan 20 kolom. Setelah melalui fase persiapan data, tersisa 267 baris dan 11 kolom yang digunakan untuk pembuatan model. Pemodelan dilakukan dalam 18 skenario. Skenario terbaik merupakan random forest parameter default dengan penanganan class imbalance menggunakan ADASYN pada proporsi data 70:30. Model tersebut menghasilkan accuracy sebesar 88%, precision sebesar 27%, recall sebesar 100%, dan f1 sebesar 43%.

Abstract. Gestational diabetes mellitus (GDM) is a condition characterized by elevated blood sugar levels in pregnant women. Mothers diagnosed with gestational diabetes mellitus are at risk of serious complications if not properly managed. Early detection through the use of medical records is a preventive measure to avoid future complications. The CRISP-DM framework was employed in model development. The data was obtained from the obstetrics clinic at Surabaya Islamic Hospital Jemursari, consisting of 270 rows and 20 columns. After the data preparation phase, 267 rows and 11 columns remained for model creation. Modeling was performed in 18 scenarios. The best scenario was the default parameter random forest with class imbalance handling using ADASYN on a 70:30 data split. This model achieved an accuracy of 88%, a precision of 27%, a recall of 100%, and an F1 score of 43%.

1. PENDAHULUAN

Diabetes Melitus Gestasional (DMG) merupakan salah satu komplikasi kehamilan umum yang dapat mengancam kesehatan ibu dan janin yang dikandungnya [1]. Sebanyak 21,3 juta atau 16,2% kelahiran global berhubungan dengan hiperglikemia dalam

kehamilan dimana diabetes melitus gestasional menyumbang 86,4% dari seluruh kasus yang ada [2]. Data Federasi Diabetes Internasional (IDF) yang menunjukkan bahwa pada tahun 2021, terdapat peningkatan prevalensi diabetes melitus gestasional di wilayah Timur Tengah dan Afrika Utara

(MENA), Asia Tenggara (SEA), Pasifik Barat (WP), dan Afrika (AFR) dengan angka sebesar 27,6%, 20,8%, 14,7%, dan 14,2% [3]. Indonesia mencatatkan angka prevalensi sebesar 1,9 – 3,6% pada studi yang dilakukan sebelum tahun 2000. Kecilnya hasil yang didapat disebabkan oleh sedikitnya studi yang berkaitan dengan angka prevalensi di Indonesia hingga saat ini [4].

Minimnya penelitian yang mempelajari tentang diabetes melitus gestasional tidak lantas membuat penyakit ini dapat diremehkan. Seorang ibu yang terindikasi menderita diabetes melitus gestasional berpotensi mengidap beberapa komplikasi dimasa mendatang, seperti hipertensi, dislipidemia, inflamasi kronis, penyakit ginjal kronis, disfungsi vascular, hingga diabetes tipe 2 [5]. Sementara itu, bayi yang lahir dari ibu pengidap diabetes melitus gestasional memiliki risiko yang lebih tinggi untuk menderita komplikasi jangka pendek, seperti makrosomia, persalinan prematur, hipoglikemia neonatal, distosia bahu, hingga kesulitan pernafasan [6].

Deteksi dini merupakan suatu proses yang dilakukan sebagai langkah identifikasi awal untuk mencegah risiko yang lebih besar terjadi dimasa depan. Hal itu dilakukan melalui identifikasi awal menggunakan rekam medis. Pemanfaatan rekam medis elektronik dalam melakukan analisis prediktif mampu memberikan hasil yang cukup menjanjikan terhadap pelayanan klinis [7]. Kerangka kerja CRISP-DM digunakan dalam analisis prediktif atas kemampuan pendekatannya yang berbasis tujuan sehingga masih digunakan secara luas untuk proyek penambangan data hingga saat ini [8].

Pada penelitian ini dilakukan deteksi dini pada diabetes melitus gestasional menggunakan dataset rekam medis melalui proses klasifikasi. Deteksi dini dilakukan dengan cara mengklasifikasikan hasil pemeriksaan pasien menjadi risiko rendah atau risiko tinggi diabetes melitus gestasional. Algoritma *random forest* dan *lightgbm* dipilih untuk basis pembuatan model. Algoritma *random forest* digunakan atas dasar kelebihanannya yang mampu memberikan hasil akhir klasifikasi yang baik dengan error yang lebih rendah [9]. Sementara itu, *lightgbm* dipilih sebagai algoritma pembanding karena kapabilitasnya yang baik dalam memproses data yang mengalami ketidakseimbangan kelas

[10]. Keduanya dipilih untuk mengetahui manakah algoritma berbasis *decision tree* yang memiliki performa terbaik dalam melakukan klasifikasi pada dataset diabetes melitus gestasional. Kedua algoritma tersebut akan dibandingkan performanya dalam melakukan klasifikasi menggunakan metrik *accuracy*, *precision*, *recall*, *f1*, *cpu usage*, *processing time*, dan *learning curve*. Beberapa skenario pembagian data, penanganan *class imbalance* dan tuning *hyperparameter* juga akan diterapkan untuk menguji algoritma yang paling unggul dalam melakukan klasifikasi.

2. TINJAUAN PUSTAKA

2.1. *Diabetes Melitus Gestasional*

Diabetes Melitus Gestasional merupakan suatu kondisi yang hanya akan dijumpai selama masa kehamilan hingga persalinan. Penyakit ini dapat terdeteksi pada minggu ke-24 hingga minggu ke-28 pada masa kehamilan yang ditandai dengan adanya kenaikan level dalam kandungan gula darah seorang ibu [11]. Diabetes melitus gestasional yang tidak ditangani dengan tepat akan berpotensi menimbulkan berbagai komplikasi dikemudian hari, seperti halnya makrosomia, kelahiran prematur, infeksi, masalah pernafasan, bayi besar sebelum lahir, hingga diabetes tipe 2 [12], [13].

2.2. *Data Mining*

Data Mining adalah prosedur penemuan pola atau informasi penting pada suatu himpunan data yang sudah ditentukan melalui penggunaan metode, teknik, atau algoritma yang sejalan dengan penelitian yang dilakukan [14]. Umumnya, *data mining* dikategorikan menjadi dua fungsionalitas, yaitu deskriptif dan prediktif. Fungsi deskriptif bertujuan pada penjelasan karakter data dalam suatu dataset, sedangkan prediktif merupakan upaya melaksanakan induksi pada data yang diperoleh untuk membuat suatu prediksi [15].

2.3. *Random Forest*

Random Forest adalah algoritma klasifikasi yang dibuat menggunakan sekumpulan prediktor pohon keputusan dan termasuk pada metode pembelajaran terarah atau *supervised learning* [16]. Umumnya, teknik ini bekerja dengan cara mengambil n buah datapoint dari suatu dataset kemudian

menyatukannya untuk menghasilkan keputusan yang stabil. Apabila terdapat banyak tebakan, maka nilai rata-rata keseluruhan prediksi akan digunakan [17].

2.4. *LightGBM*

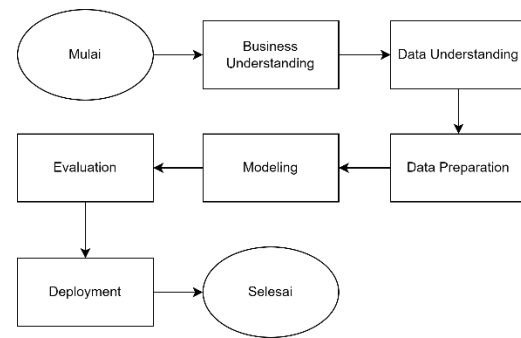
LightGBM merupakan suatu kerangka kerja yang diluncurkan oleh Microsoft pada tahun 2017 dengan basis algoritma *decision tree*. Algoritma ini bekerja dengan cara strategi pertumbuhan berdasarkan daun dengan batas kedalaman untuk menemukan node daun dengan keuntungan split terbesar di antara semua node daun saat ini, lalu membaginya, dan seterusnya. Metode ini memberikan keuntungan dengan meminimalisir tingkat kesalahan, sehingga dapat mencapai akurasi yang lebih tinggi [18].

2.5. *ADASYN*

ADASYN atau *Adaptive Synthetic* merupakan prosedur penanganan ketidakseimbangan data yang bekerja dengan cara menggunakan distribusi berbobot untuk contoh kelas minoritas berdasarkan tingkat kesulitan belajarnya. Pada proses duplikasi nantinya lebih banyak data dibuat untuk contoh yang lebih sulit dipelajari daripada yang mudah. Sehingga, dapat meningkatkan pembelajaran melalui dua cara. Pertama, mengurangi ketidakseimbangan kelas. Kedua, mendorong batas keputusan secara adaptif menuju sampel yang lebih menantang [19].

3. METODE PENELITIAN

Pada penelitian ini diimplementasikan kerangka kerja CRISP-DM atau *Cross Industry Process Model for Data Mining* sebagai prosedur pengolahan data dari hulu ke hilir. Prosedur ini terdiri enam tahapan yang diantaranya adalah *business understanding*, *data understanding*, *data preparation*, *modeling*, *evaluation*, dan *deployment*. Untuk lebih jelasnya dapat dilihat pada Gambar 1.



Gambar 1. Metode CRISP-DM

3.1. *Business Understanding*


Pada tahapan ini dilakukan pencarian sumber informasi melalui studi literatur dan wawancara dengan bagian rekam medis RSI Surabaya Jemursari pada tanggal 16 Mei 2023. Data yang diperoleh nantinya akan dihimpun pada dokumen digital berbentuk csv ataupun format lain yang dapat dikenali oleh Microsoft Excel.

3.2. *Data Understanding*

Pada fase ini akan dilakukan *screening* terhadap data yang diperoleh melalui penggunaan teknik visual, seperti histogram, *box plot* ataupun *pie chart*. Sehingga, nantinya didapatkan informasi yang berguna untuk mempermudah proses persiapan data.

3.3. *Data Preparation*

Tahap *data preparation* dilakukan untuk memastikan data yang digunakan dalam pembuatan model adalah yang terbaik, sehingga memberikan hasil yang cukup akurat. Proses ini dilaksanakan melalui tiga tahapan, yaitu *data cleaning*, *data transformation*, dan *feature selection*. Alurnya dapat dilihat pada Gambar 2.



Gambar 2. Alur Data Preparation

3.4. Modeling

Pada fase *modeling*, data yang telah siap selanjutnya diolah menggunakan model dengan basis algoritma yang telah ditentukan. Nantinya, beberapa skenario pembagian data, penanganan ketidakseimbangan kelas, dan penyetelan *hyperparameter* akan diimplementasikan untuk menguji ketangguhan dari kedua algoritma.

3.5. Evaluation

Fase *evaluation* akan berfokus untuk menilai seberapa baik performa setiap model yang telah dibuat sebelumnya. Masing – masing skenario pemodelan yang telah dibuat akan dinilai berdasarkan tiga macam penilaian, yaitu *confusion matrix*, *cpu usage*, *processing time*, dan *learning curve*. Model yang mampu unggul dengan performa paling optimal berdasarkan kriteria yang disebutkan sebelumnya, akan digunakan pada tahapan *deployment*.

3.6. Deployment

Tahap *deployment* merupakan langkah terakhir dalam metode CRISP-DM yang berfokus pada produk yang dihasilkan dari keseluruhan pemrosesan data yang telah dilakukan sebelumnya. Model terbaik yang diperoleh pada fase *evaluation* akan digunakan sebagai model utama pada sistem website yang dibuat menggunakan *html* dan *flask*.

4. HASIL DAN PEMBAHASAN

Setelah gambaran umum proses penelitian selesai dijabarkan pada tahap sebelumnya, maka berikut adalah hasil temuan selama penelitian dilakukan pada setiap tahapannya.

4.1. Business Understanding

Hasil wawancara yang dilakukan menunjukkan bahwa data pemeriksaan pada pasien diabetes melitus gestasional diperoleh dari poli kandungan RSI Surabaya Jemursari. Data berasal dari rentang Januari 2023 hingga Maret 2023. Selain itu, pada tahap ini diketahui juga bahwa terdapat indikasi data yang tidak seimbang karena jumlah pasien yang terdiagnosa diabetes melitus gestasional cukup sedikit pada rentang waktu yang digunakan.

4.2. Data Understanding

Data yang diperoleh berjumlah 270 baris atau *records* dengan atribut sebanyak 20 kolom. Data terdiri atas atribut tanggal kunjungan, nomor rekam medis, nama dokter, status pelayanan, debitur, ku, rps, tekanan darah, penunjang, suhu, spo2, tinggi badan, berat badan, assesment, soap plan, dan nama poli. Dari 270 baris yang didapatkan, 251 baris teridentifikasi sebagai label negatif dan 19 lainnya label positif. Tampilan dari data mentah yang didapatkan dapat dilihat pada Tabel 1.

Tabel 1. Data Mentah

tgl_kunjungan	tgl_ac t	ku	...	assesment
2023-01-02	31-12-2022 07:07:59	benjolan di perut kadang 2 nyeri	...	Myoma Uteri
2023-01-02	31-12-2022 08:21:56	-	...	GIII P2-2 29/30 mg THIU + BSC 2x + Obesitas + LETLI. TBJ 1500gr

tgl_kunjungan	tgl_ac t	ku	...	assesment
2023-01-02	02-01-2023 05:15:45		...	GII P1-1 35/36 mg TH + Primitu a Sekund er + Hepatit is B kronis + Obesita s + letkep. TBJ 2400gr
2023-01-02	02-01-2023 06:43:21	pusing	...	GIII P2-2 32/33 mg TH + Primitu a Sekund er + Usia >35th + letkep. TBJ 1600gr
2023-01-02	02-01-2023 06:49:52	px menge luh sering BAK, kencen g2 sering tiap 15 mnt, keluar lendir darah -	...	GII P1001 35/36 mgg THIU + letkep + BSC + TBJ 2400


Pengolahan awal pada data mentah dilakukan karena data yang diperoleh tidak dapat dilakukan pengolahan visualisasi secara langsung. Oleh karena itu, manipulasi string dilakukan untuk membuat atribut baru dari

atribut yang sebelumnya telah tersedia. Salah satunya adalah pemisahan kolom tekanan menjadi dua kolom, yaitu sistol dan diastol. Potongan *source code* yang digunakan dapat dilihat pada Gambar 3.

```
# Membagi kolom tekanan agar dapat diolah lanjut.
nospace_df[['Sistol', 'Diastol']] = nospace_df['tekanan'].str.split('/', expand=True)
nospace_df.head(5)
```

Gambar 3. Potongan Source Code Manipulasi String

Hasil manipulasi string memunculkan 8 atribut baru, yaitu sistol, diastol, gravida, para, usia > 35, obesitas, hipertensi, dan target. Selanjutnya dilakukan visualisasi pada atribut baru menggunakan histogram untuk melihat persebaran data, seperti yang terlihat pada Gambar 4.



Gambar 4. Outliers Pada Berat Badan

Grafik memperlihatkan adanya outliers pada data yang digunakan, normalnya hal ini ditangani dengan mengganti value atau melakukan penghapusan pada data. Namun, karena jumlah data yang sedikit dan data cukup penting bagi penelitian karena merupakan unsur medis maka tetap dibiarkan.

4.3. Data Preparation

Pada tahap ini dilakukan pembersihan pada data dengan melakukan pembersihan data, transformasi data, dan seleksi fitur yang berguna agar data yang digunakan pada tahap pemodelan berkualitas baik. Pertama, pembersihan data dilakukan dengan cara melakukan penanganan *missing values*. Hal ini salah satunya dapat dilakukan dengan mengisi nilai kosong pada sebuah atribut dengan nilai rata – ratanya. Implementasinya dapat dilihat pada Gambar 5.

```
# Melakukan penanganan missing value dengan mengisi nilai
# rata-rata berdasarkan 'Hipertensi' pada kolom 'Sistol' & 'Diastol'
mean_sistol_by_hipertensi = data.groupby('Hipertensi')['Sistol'].mean()
data['sistol'].fillna(data['Hipertensi'].map(mean_sistol_by_hipertensi), inplace=True)
mean_diastol_by_hipertensi = data.groupby('Hipertensi')['Diastol'].mean()
data['diastol'].fillna(data['Hipertensi'].map(mean_diastol_by_hipertensi), inplace=True)
```

Gambar 5. Penanganan Missing Value Atribut Sistol dan Diastol

Kedua, transformasi data dilakukan untuk menyamakan seluruh jenis atribut menjadi bertipe numerik. Hal ini dilakukan untuk mempermudah algoritma dalam membaca pola pada tahap *modeling*. Prosedur transformasi dilakukan melalui *encoding* dan juga *standarization*. Melalui proses *encoding*, atribut dengan value ya dan tidak akan diubah menjadi 1 dan 0. Sedangkan, *standarization* akan mengubah data numerik agar memiliki rentang nilai yang sama. Implementasi keduanya dapat dilihat pada Gambar 6 dan Gambar 7.

```
# Buat fungsi untuk mengubah data kategorikal menjadi nominal
def map_categorikal_to_numeric(data, column_name):
    mapping = {'Tidak': 0, 'Iya': 1}
    data[column_name] = data[column_name].apply(lambda x: mapping.get(x))

# Gunakan fungsi sebelumnya untuk melakukan encoding pada kolom 'Usia', 'Obesitas', dan 'Hipertensi'
map_categorikal_to_numeric(data, 'Usia > 35')
map_categorikal_to_numeric(data, 'Obesitas')
map_categorikal_to_numeric(data, 'Hipertensi')

data.head(5)
```

Gambar 6. Proses Encoding Pada Atribut Usia, Obesitas dan Hipertensi

```
# Lakukan standarisasi pada kolom 'Gravida', 'Para', dan 'Skor Risiko DMG'
from sklearn.preprocessing import StandardScaler

# List kolom yang akan distandarisasi
columns_to_standardize = ['Sistol', 'Diastol', 'Gravida', 'Para', 'Berat Badan']

# Lakukan standarisasi pada kolom terkait
scaler = StandardScaler()
data[columns_to_standardize] = scaler.fit_transform(data[columns_to_standardize])

# Tampilkan hasil standarisasi
data.head(5)
```

Gambar 7. Proses Standarization Pada Atribut Bertipe Numerik

Terakhir adalah tahapan *feature selection* yang dilakukan untuk menghilangkan atribut tidak penting untuk fase *modeling*. Pembuatan *correlation heatmap* juga dilakukan untuk melihat korelasi antar variabel sebelum dilakukan pemodelan. Potongan *source code* untuk implementasi tahap ini dapat dilihat pada Gambar 8 dan Gambar 9.

```
# Buang variabel yang tidak dibutuhkan
clean = data.drop(['Tanggal Kunjungan', 'No. RM'], axis=1)
```

Gambar 8. Potongan Source Code Proses Seleksi Fitur



Gambar 9. Correlation Heatmap

4.4. Modeling

Tahap modeling dilakukan pembagian data menjadi data model dan data validasi. Data model akan dibagi menjadi beberapa skenario sesuai dengan kebutuhan pemodelan. Sementara data validasi akan digunakan untuk pengujian pada model terbaik. Proporsi 90:10 digunakan untuk pembagian data dengan data model sebanyak 240 records dan data validasi sebanyak 27 records. Sebanyak 240 data kemudian dibagi menjadi 3 skenario pembagian, yaitu 70:30, 80:20, dan 90:10. Masing-masing pembagian akan memiliki 6 macam skenario. Sehingga, total skenario pemodelan yang dibuat sebanyak 18 model dengan rincian berikut:

Tabel 2. Skenario Pemodelan

Nama Model	Deskripsi
Model 1	Random Forest (RF) Default with 30% Test Size
Model 2	RF Default + ADASYN with 30% Test Size
Model 3	RF Hyperparameter + ADASYN with 30% Test Size
Model 4	LightGBM (LGBM) Default with 30% Test Size
Model 5	LGBM Default + ADASYN with 30% Test Size
Model 6	LGBM Hyperparameter + ADASYN with 30% Test Size
Model 7	Random Forest (RF) Default with 20% Test Size

Nama Model	Deskripsi
Model 8	RF Default + ADASYN with 20% Test Size
Model 9	RF Hyperparameter + ADASYN with 20% Test Size
Model 10	LightGBM (LGBM) Default with 20% Test Size
Model 11	LGBM Default + ADASYN with 20% Test Size
Model 12	LGBM Hyperparameter + ADASYN with 20% Test Size
Model 13	Random Forest (RF) Default with 10% Test Size
Model 14	RF Default + ADASYN with 10% Test Size
Model 15	RF Hyperparameter + ADASYN with 10% Test Size
Model 16	LightGBM (LGBM) Default with 10% Test Size
Model 17	LGBM Default + ADASYN with 10% Test Size
Model 18	LGBM Hyperparameter + ADASYN with 10% Test Size

4.5. Evaluasi

4.5.1. Confusion Matrix

Setiap model yang telah dibuat akan melalui tahap evaluasi untuk mengetahui performa model pada data yang dipelajari. Tahap pertama evaluasi dilakukan melalui confusion matrix yang akan menilai seberapa baik accuracy, precision, recall, dan f1 dari setiap model. Hasilnya dapat dilihat pada Tabel 3.

Tabel 3. Hasil Confusion Matrix

Nama Model	Accu racy	Preci sion	Recal l	F1
Model 1	96%	0%	0%	0%
Model 2	88%	27%	100%	43%
Model 3	88%	27%	100%	43%
Model 4	94%	43%	100%	60%
Model 5	86%	23%	100%	38%
Model 6	86%	18%	67%	29%
Model 7	98%	0%	0%	0%
Model 8	88%	14%	100%	25%

Nama Model	Accu racy	Preci sion	Recal l	F1
Model 9	88%	14%	100%	25%
Model 10	94%	25%	100%	40%
Model 11	88%	14%	100%	25%
Model 12	88%	14%	100%	25%
Model 13	96%	0%	0%	0%
Model 14	88%	25%	100%	40%
Model 15	88%	25%	100%	40%
Model 16	92%	33%	100%	50%
Model 17	88%	25%	100%	40%
Model 18	88%	25%	100%	40%

Berdasarkan Tabel 3 dapat dilihat bahwa model secara keseluruhan memiliki nilai yang buruk pada indikator *precision* dengan 5 model terbaik tidak mampu mencapai angka 50%. Hal ini dapat disebabkan salah satunya oleh dataset yang terlalu tidak seimbang ataupun variasi data yang sempit sehingga membuat model menghasilkan performa yang buruk. Sedangkan, dari *accuracy* dan *recall* mampu mencatatkan performa keseluruhan yang cukup baik meskipun terdapat tiga model yang mendapatkan nilai 0% pada penilaian *recall*. Model tersebut adalah Model 1, Model 7 dan Model 13 yang menggunakan basis *random forest* tanpa menggunakan penanganan kelas tidak seimbang ataupun penyetelan *hyperparameter*.

Penggunaan ADASYN untuk melakukan sintesis kelas dan hyperparameter tuning nampaknya juga tidak memberikan hasil terbaik pada pemodelan. Karena model dengan performa terbaik justru merupakan model tanpa kostumisasi apapun, yaitu model 4 yang menggunakan *lightgbm* default dengan test size 30%. Meskipun begitu, model dengan ADASYN juga memberikan performa yang tidak buruk. Hal ini dibuktikan dengan Model 2 dan Model 3 yang memiliki nilai keseluruhan yang baik apabila dibandingkan dengan Model lainnya. Setelah dilihat secara keseluruhan maka kelima model terbaik adalah Model 4, 10, 16, 2, dan 3.

4.5.2. CPU Usage and Processing Time

Tahap kedua adalah evaluasi berdasarkan penggunaan cpu dan waktu pemrosesan untuk melihat efektifitas kinerja dari setiap model. Hasilnya dapat dilihat pada Tabel 4.


Tabel 4. Hasil CPU Usage dan Processing Time

Nama Model	CPU Usage (%)	Processing Time (seconds)
Model 1	2.3	0.021
Model 2	1.0	0.022
Model 3	3.9	0.024
Model 4	11.9	0.004
Model 5	7.3	0.004
Model 6	6.2	0.004
Model 7	1.8	0.019
Model 8	1.4	0.022
Model 9	2.5	0.024
Model 10	8.6	0.004
Model 11	9.0	0.004
Model 12	7.8	0.004
Model 13	1.0	0.020
Model 14	2.5	0.021
Model 15	1.0	0.023
Model 16	8.0	0.004
Model 17	8.4	0.003
Model 18	7.4	0.003

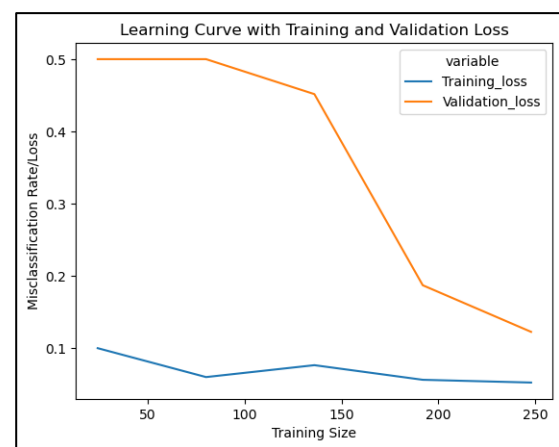
Berdasarkan hasil pada Tabel 4 diketahui pola bahwa model dengan basis *random forest* memiliki keunggulan pada penggunaan cpu yang rendah dengan kisaran antara 1% hingga 3,9%, berbanding terbalik dengan *lightgbm* yang menghabiskan 6,2% hingga 11,9%. Namun, algoritma *lightgbm* secara keseluruhan mencatatkan waktu pemrosesan yang lebih singkat di sekitar 3 hingga mili seconds dibandingkan dengan *random forest* yang berada pada angka 20 mili seconds. Sehingga, dapat disimpulkan bahwa kedua algoritma memiliki keunggulan masing – masing yang saling berbanding terbalik.

4.5.3. Learning Curve

Tahap terakhir yaitu kurva pembelajaran atau *learning curve*. Hal ini dilakukan untuk melihat apakah model yang dibuat sudah cukup stabil atau malah terdapat indikasi *overfitting* ataupun *underfitting*. Contoh implementasi dari kurva pembelajaran dapat dilihat pada Gambar 10 dan Gambar 11.



Gambar 10. Learning Curve Model 4



Gambar 11. Learning Curve Model 2

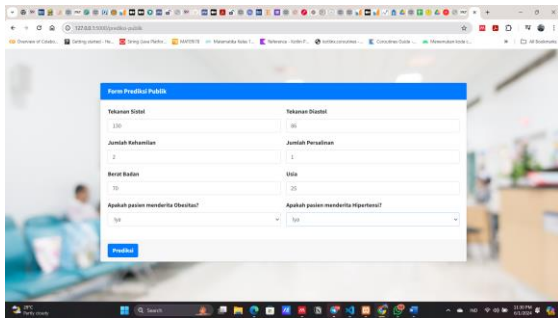
Setelah keseluruhan model dievaluasi menggunakan kurva pembelajaran, hasil menunjukkan bahwa 3 dari 5 model dengan performa terbaik pada tahap *confusion matrix* terindikasi *overfitting*. Model tersebut adalah Model 4, 10, dan 16. Ketiga model tersebut menunjukkan ketidakmampuan dalam melakukan pembelajaran karena gap yang besar dari sisi training dan validation loss. Sementara, Model 2 dan 3 menunjukkan pembelajaran yang cukup stabil karena kurva validation loss dan training loss menunjukkan penurunan yang cukup signifikan seiring mendekati akhir pembelajaran.

4.5.4. Evaluasi Akhir

Berdasarkan hasil penilaian yang telah dilakukan, penggunaan ADASYN pada Model 2 dan 3 yang berbasis *random forest* tampaknya mampu membuat model menjadi lebih stabil dengan meningkatkan jumlah kelas minoritasnya. Model 2 dipilih sebagai model akhir karena waktu pemrosesannya yang lebih singkat apabila dibandingkan dengan Model 3.

4.6. Deployment

Fase *deployment* dilakukan dengan melakukan pembuatan sistem prediksi yang akan digunakan untuk melakukan deteksi dini diabetes melitus gestasional pada ibu hamil dengan nama CheckDMG. Implementasi halaman website yang telah dibuat dapat dilihat pada Gambar 12.



Gambar 12. Halaman Prediksi

Model 2 digunakan pada website ini untuk kemudian dilakukan pengujian pada data validasi yang sebelumnya telah dibagi pada tahap *modeling*. Hasilnya, Model 2 mampu memberikan nilai *accuracy* sebesar 85%, *precision* sebesar 43%, *recall* sebesar 100%, dan *f1* sebesar 60%.

5. KESIMPULAN

- a. Berdasarkan hasil pengujian yang dijalankan, algoritma *lightgbm* mempunyai performa *default* yang lebih baik dalam melakukan klasifikasi pada kelas yang tidak seimbang. Hal ini terbukti dari performa algoritma *default* yang masih mampu melakukan klasifikasi dibandingkan dengan algoritma *random forest* yang memiliki skor 0 pada nilai *precision*, *recall*, dan *f1* di keseluruhan model *default*-nya. Namun, secara keseluruhan model *random forest* mampu mengungguli *lightgbm* karena performanya yang lebih stabil pada Model 2 dan 3 dengan bantuan ADASYN.
- b. Model 2 mencatatkan hasil yang cukup baik pada data validasi dengan nilai *accuracy* sebesar 85%.
- c. Pengujian *cpu usage* dan *processing time* memberikan hasil yang saling berkebalikan. Model dengan

algoritma *random forest* unggul pada penggunaan *cpu* namun kalah dalam waktu pemrosesan, sementara *lightgbm* unggul dalam waktu pemrosesan namun kalah dalam penggunaan *cpu*.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada pihak-pihak terkait yang telah memberi dukungan terhadap penelitian ini.

DAFTAR PUSTAKA

- [1] Y.-N. Chan *dkk.*, "A machine learning approach for early prediction of gestational diabetes mellitus using elemental contents in fingernails," *Sci Rep*, vol. 13, no. 1, hlm. 1–11, 2023, doi: 10.1038/s41598-023-31270-y.
- [2] F. K. Adli, "Diabetes Melitus Gestasional: Diagnosis dan Faktor Risiko," *Jurnal Medika Hutama*, vol. 03, no. 01, hlm. 1545–1551, 2021.
- [3] H. Wang *dkk.*, "IDF Diabetes Atlas: Estimation of Global and Regional Gestational Diabetes Mellitus Prevalence for 2021 by International Association of Diabetes in Pregnancy Study Group's Criteria," *Diabetes Res Clin Pract*, vol. 183, hlm. 109050, 2022, doi: <https://doi.org/10.1016/j.diabres.2021.109050>.
- [4] PB PERKENI, "Pedoman Diagnosis dan Penatalaksanaan Hiperglikemia Dalam Kehamilan 2021," Jul 2021.
- [5] P. Saravanan *dkk.*, "Gestational diabetes: opportunities for improving maternal and child health," *Lancet Diabetes Endocrinol*, vol. 8, no. 9, hlm. 793–800, 2020, doi: [https://doi.org/10.1016/S2213-8587\(20\)30161-3](https://doi.org/10.1016/S2213-8587(20)30161-3).
- [6] E. C. Johns, F. C. Denison, J. E. Norman, dan R. M. Reynolds, "Gestational Diabetes Mellitus: Mechanisms, Treatment, and Complications," *Trends in Endocrinology & Metabolism*, vol. 29, no. 11, hlm. 743–754, 2018, doi: <https://doi.org/10.1016/j.tem.2018.09.004>.
- [7] T. C. Lee, N. U. Shah, A. Haack, dan S. L. Baxter, "Clinical Implementation of Predictive Models Embedded within Electronic Health Record Systems: A Systematic Review," *Informatics*, vol. 7, no. 3, hlm. 25, Jul 2020, doi: 10.3390/informatics7030025.
- [8] J. A. Solano, D. J. Lancheros Cuesta, S. F. Umaña Ibáñez, dan J. R. Coronado-Hernández, "Predictive models assessment based on CRISP-DM methodology for

- students performance in Colombia - Saber 11 Test,” *Procedia Comput Sci*, vol. 198, hlm. 512–517, Jan 2022, doi: 10.1016/J.PROCS.2021.12.278.
- [9] C. Z. V. Junus, T. Tarno, dan P. Kartikasari, “Klasifikasi Menggunakan Metode Support Vector Machine Dan Random Forest Untuk Deteksi Awal Risiko Diabetes Melitus,” *Jurnal Gaussian*, vol. 11, no. 3, hlm. 386–396, 2023, doi: 10.14710/j.gauss.11.3.386-396.
- [10] P. Septiana Rizky, R. Haiban Hirzi, U. Hidayaturrohan, U. Hamzanwadi Selong Jl TGKH Muhammad Zainuddin Abdul Madjid Pancor, dan L. Timur, “Perbandingan Metode LightGBM dan XGBoost dalam Menangani Data dengan Kelas Tidak Seimbang,” 2022. [Daring]. Tersedia pada: www.unipasby.ac.id
- [11] S. Revathy, M. Ramesh, S. Gowri, dan B. Bharathi, “Gestational Diabetics Prediction Using Logistic Regression in R,” dalam *New Trends in Computational Vision and Bio-inspired Computing: Selected works presented at the ICCVBIC 2018, Coimbatore, India*, S. Smys, A. M. Ilyasu, R. Bestak, dan F. Shi, Ed., Cham: Springer International Publishing, 2020, hlm. 739–746. doi: 10.1007/978-3-030-41862-5_73.
- [12] N. El-Rashidy, N. E. ElSayed, A. El-Ghamry, dan F. M. Talaat, “Prediction of gestational diabetes based on explainable deep learning and fog computing,” *Soft comput*, vol. 26, no. 21, hlm. 11435–11450, Nov 2022, doi: 10.1007/s00500-022-07420-1.
- [13] J. Wang dkk., “An early model to predict the risk of gestational diabetes mellitus in the absence of blood examination indexes: application in primary health care centres,” *BMC Pregnancy Childbirth*, vol. 21, no. 1, Des 2021, doi: 10.1186/s12884-021-04295-2.
- [14] M. F. Y. Herjanto dan C. Carudin, “Analisis Sentimen Ulasan Pengguna Aplikasi Sirekap Pada Play Store Menggunakan Algoritma Random Forest Classifier,” *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 2, hlm. 1204–1210, Apr 2024, doi: 10.23960/jitet.v12i2.4192.
- [15] J. Han, J. Pei, dan M. Kamber, *Data Mining: Concepts and Techniques*, Third Edit. dalam The Morgan Kaufmann Series in Data Management Systems. Elsevier Science, 2011. [Daring]. Tersedia pada: <https://books.google.co.id/books?id=pQws07t dpjoC>
- [16] C. C. Olisah, L. Smith, dan M. Smith, “Diabetes mellitus prediction and diagnosis from a data preprocessing and machine learning perspective,” *Comput Methods Programs Biomed*, vol. 220, hlm. 106773, 2022, doi: 10.1016/j.cmpb.2022.106773.
- [17] V. Chang, M. A. Ganatra, K. Hall, L. Golightly, dan Q. A. Xu, “An assessment of machine learning models and algorithms for early prediction and diagnosis of diabetes using health indicators,” *Healthcare Analytics*, vol. 2, no. October, hlm. 100118, 2022, doi: 10.1016/j.health.2022.100118.
- [18] Y. Wang dan T. Wang, “Application of Improved LightGBM Model in Blood Glucose Prediction,” *Applied Sciences (Switzerland)*, vol. 10, no. 9, hlm. 1–16, Mei 2020, doi: 10.3390/app10093227.
- [19] G. Ahmed dkk., “DAD-Net: Classification of Alzheimer’s Disease Using ADASYN Oversampling Technique and Optimized Neural Network,” *Molecules*, vol. 27, no. 20, Okt 2022, doi: 10.3390/molecules27207085.