

OPTIMASI MODEL EXTREME GRADIENT BOOSTING DALAM UPAYA PENENTUAN TINGKAT RISIKO PADA IBU HAMIL BERBASIS BAYESIAN OPTIMIZATION (BOXGB)

Edi Jaya Kusuma^{*1}, Ririn Nurmandhani², Lenci Aryani³, Ika Pantiawati⁴, Guruh Fajar Shidik⁵

^{1,2,3,4,5} Universitas Dian Nuswantoro, Semarang

Email: ¹edi.jaya.kusuma@dsn.dinus.ac.id, ²nurmandhani@dsn.dinus.ac.id, ³lenci.aryani@dsn.dinus.ac.id,
⁴ikapantia13@dsn.dinus.ac.id, ⁵guruh.shidik@dsn.dinus.ac.id

^{*}Penulis Korespondensi

(Naskah masuk: 11 Mei 2024, diterima untuk diterbitkan: 10 Februari 2025)

Abstrak

Kehamilan pada ibu hamil memiliki beragam risiko selama prosesnya seperti preeklampsia, diabetes dan hipertensi *gestational*. Seiring dengan perkembangan teknologi dan pemanfaatan data, implementasi *machine learning* dalam pengembangan *early diagnosis system* untuk tingkat risiko kehamilan telah banyak dilakukan. Namun kendala dalam penerapan *machine learning* adalah sulitnya menemukan konfigurasi parameter yang tepat agar model *machine learning* mampu memberikan akurasi prediksi yang mumpuni. Pada penelitian ini diusulkan metode optimasi berbasis *Bayesian* untuk mengoptimalkan *hyper-parameter* dari model *Decision Tree* (DT) dan *Extreme Gradient Boosting* (XGB). Kedua model teroptimasi tersebut dilatih dan diuji dengan menggunakan data risiko kehamilan yang diperoleh dari hasil pengukuran medis pada ibu hamil. Dari hasil evaluasi diketahui terdapat pengaruh jumlah iterasi pada *Bayesian Optimization* (BO). Implementasi BO pada model *Decision Tree* (BODT) menunjukkan adanya sedikit peningkatan nilai performa dibandingkan dengan penelitian sebelumnya. Sementara itu, capaian performa tertinggi diperoleh oleh kombinasi model XGB dan *Bayesian* (BOXGB) dimana capaian nilai akurasi pada model BOXGB yaitu 87% diikuti dengan nilai rata-rata presisi, *recall*, dan *F1-score* masing-masing sebesar 88%, 87%, dan 88%. Secara keseluruhan implementasi *Bayesian Optimization* mampu memberikan setelan *hyper-parameter* yang dapat meningkatkan kemampuan model *machine learning* khususnya dalam memprediksi tingkat risiko kehamilan pada ibu hamil berdasarkan data pengukuran klinis.

Kata kunci: *bayesian optimization, hyper-parameter, machine learning, tingkat risiko kehamilan*

MACHINE LEARNING OPTIMIZATION IN DETERMINING THE MATERNAL RISK LEVEL BASED ON BAYESIAN OPTIMIZATION

Abstract

During pregnancy process there are various risks such as preeclampsia, gestational diabetes and gestational hypertension. Along with the developments in technology as well as data science, the implementation of machine learning in early diagnosis system for pregnancy risk levels prediction has been widely carried out. However, there is a challenge in implementing machine learning, which is find the suitable yet effective parameter configuration in training machine learning model to provides better prediction accuracy. This research proposes a Bayesian-based Optimization (BO) method to tune up the hyper-parameters of Decision Tree (DT) and Extreme Gradient Boosting (XGB) models. These two optimized models were trained and tested using maternal risk dataset obtained from the clinical-based measurement on pregnant woman. From the evaluation result, it can be found that the number of iterations has high influence on the BO performance. The implementation of BO toward DT model has slight increase in performance result compared to the previous research. Meanwhile, the highest performance result achieved by the combination of BO and XGB (BOXGB) model where the proposed model reaches 87% of accuracy, followed by average value of precision, recall, and F1-score of 88%, 87%, and 88%, respectively. Overall, the implementation of BO is able to direct the hyper-parameter configuration which improves the machine learning performance especially in predicting maternal risk level based on clinical-based measurement data.

Keywords: *bayesian optimization, hyper-parameter, machine learning, maternal risk level*

1. PENDAHULUAN

Kehamilan merupakan salah satu peristiwa penting dalam kehidupan seorang ibu. Namun dalam perjalanannya, proses tersebut memiliki beragam risiko yang dapat mempengaruhi kesehatan ibu dan janin. Preeklampsia, diabetes *gestational*, dan hipertensi *gestational* merupakan beberapa faktor risiko yang dapat muncul selama proses kehamilan.

Hipertensi *gestational* adalah kondisi medis berupa tekanan darah pada ibu hamil yang meningkat seiring dengan proses kehamilan. Risiko ini dapat memicu terjadinya preeklampsia dimana tekanan darah dan kadar protein pada urin meningkat, sehingga dapat mengganggu fungsi organ vital seperti hati dan ginjal (Allaam, Prasetyo and Maulana, 2023). Pada ibu hamil yang mengalami preeklampsia memiliki risiko komplikasi serius seperti terhambatnya pertumbuhan janin, risiko kelahiran prematur, dan yang terburuk adalah risiko kematian baik pada ibu dan janin (Pirmansyah and Berawi, 2023).

Selain kondisi terkait dengan tekanan darah, risiko lain yang dapat muncul selama proses kehamilan pada ibu adalah naiknya kadar gula darah. Kondisi naiknya gula darah pada ibu selama proses kehamilan dinamakan diabetes *gestational* (Pinadito, Wicaksono and Wijoyo, 2023). Kondisi medis tersebut dapat memicu risiko komplikasi pada janin seperti risiko lahir dengan berat badan rendah atau tinggi, serta risiko persalinan prematur.

Penelitian terkait dengan faktor risiko kejadian hipertensi pada ibu hamil telah dilakukan oleh Bunga dkk (Bunga, Flora and Tarigan, 2023). Penelitian tersebut dilakukan di Puskesmas Telaga, Kabupaten Gorontalo. Analisa dilakukan dengan menggunakan teknik *linear regression* untuk mengetahui hubungan faktor risiko terhadap kejadian hipertensi pada ibu hamil. Dari hasil analisis didapatkan bahwa faktor usia, paritas (jumlah pernah melahirkan pada ibu), dan riwayat hipertensi merupakan faktor yang berpengaruh terhadap kejadian hipertensi *gestational* pada ibu hamil. Kemudian penelitian lain yang dilakukan oleh Isyti'aroh dkk (Isyti'aroh et al., 2023) mengkaji mengenai faktor risiko diabetes *gestational* di Puskesmas Bojong I, Kabupaten Pekalongan. Dalam penelitian tersebut dilakukan proses survei dengan menggunakan *instrument* angket di 14 desa yang termasuk dalam area kerja Puskesmas Bojong I. Dari hasil penelitian tersebut didapatkan bahwa paritas merupakan faktor risiko yang berhubungan dengan kejadian diabetes *gestational*.

Di era perkembangan teknologi yang semakin pesat, penerapan teknologi seperti *health monitoring system* menjadi salah satu upaya untuk mengantisipasi risiko kesehatan di masyarakat (Kusuma, Nurmandhani and Handayani, 2022). Dengan memanfaatkan faktor-faktor yang dapat diperoleh tanpa melalui pengujian laboratorium, penggunaan sistem *health monitoring* diharapkan dapat menjadi alternatif terjangkau bagi masyarakat

untuk mendapatkan informasi kesehatan secara instan yang kemudian dapat dijadikan acuan ke pemeriksaan lanjutan (Lu et al., 2023). Pada penelitian (Ahmed et al., 2020), telah diusulkan sebuah sistem yang memanfaatkan teknologi *Internet of things* (IoT) untuk mengawasi kondisi kesehatan ibu hamil. Dalam penelitian tersebut, indikator-indikator kesehatan dikumpulkan dengan menggunakan *wearable device* yang memiliki beberapa sensor. Data-data yang terkumpul kemudian di olah dengan model *machine learning* untuk memberikan informasi terkait dengan status risiko kehamilan pada ibu. Dari hasil penelitian tersebut, dapat diketahui bahwa metode *Logistic Model Tree* (LMT) mampu memberikan nilai akurasi sebesar 97%. Selanjutnya penelitian terkait prediksi tingkat risiko kehamilan juga dilakukan oleh Mutlu dkk (MUTLU et al., 2023). Pada penelitian tersebut dilakukan tahapan evaluasi terhadap beberapa metode *machine learning* yaitu *Decision Tree* (DT), *light Gradient Boost Machine* (GBM), *CatBoost*, *Random Forest* (RF), *Gradient Boost Machine* (GBM), dan *K-Nearest Neighbor* (KNN). Dari hasil evaluasi didapatkan bahwa metode *Decision Tree* (DT) mampu mengungguli metode lainnya dengan perolehan akurasi sebesar 89,16%. Penelitian lanjutan terkait dengan evaluasi model *machine learning* dalam prediksi risiko kehamilan dilakukan oleh Hossain dkk (Hossain et al., 2024). Pada penelitian tersebut diaplikasikan beberapa metode diantaranya DT, KNN, *Extreme Gradient Boosting* (XGB), *Multi-Layer Perceptron* (MLP), *Adaptive Boosting* (ADP), dan RF. Dari hasil evaluasi berdasarkan nilai akurasi, dapat disimpulkan bahwa metode XGB mampu melampaui performa metode lain dengan nilai akurasi sebesar 99%.

Penggunaan *machine learning* dalam penentuan risiko kehamilan menjadi salah satu tantangan tersendiri, terlebih dalam implementasinya, *machine learning* memiliki konfigurasi *hyper-parameter* yang kompleks (Wu et al., 2019). Konfigurasi *Hyper-parameter* yang sesuai merupakan kunci yang penting utamanya dalam melatih *machine learning* untuk menghasilkan performa yang optimal (Bach et al., 2024). Kesalahan dalam proses konfigurasi *hyper-parameter* pada proses pelatihan *machine learning* mampu menurunkan performa model secara signifikan. Oleh karena itu, beberapa penelitian mengusulkan penggunaan teknik optimasi dalam penentuan *hyper-parameter* saat proses pelatihan model *machine learning*. Penggunaan teknik optimasi ini menggunakan fungsi *objective* dalam menentukan parameter-parameter terbaik yang dapat diaplikasikan kedalam model yang dioptimalkan (Kusuma, Pantiawati and Handayani, 2022).


Salah satu penelitian yang memanfaatkan optimasi *hyper-parameter* adalah Liu dkk (Liu et al., 2024). Pada penelitian tersebut dilakukan prediksi risiko berpindahnya pelanggan yang memiliki potensi keuntungan yang besar. Proses prediksi memanfaatkan model XGB dengan tambahan

optimisasi *hyper-parameter* menggunakan pendekatan *Bayesian Optimization* (BO). Dari hasil eksperimen diketahui bahwa BO mampu mengurangi beban komputasi secara signifikan dibandingkan dengan *Grid Optimization* (GO). Penggunaan BO juga diimplementasikan oleh Elshewey dkk (Elshewey et al., 2023). Pada penelitian tersebut BO dikombinasikan dengan *Support Vector Machine* (SVM) untuk mengklasifikasikan status pasien dari penyakit *Parkinson*. BO digunakan untuk mengoptimalkan *hyper-parameter* dari beberapa model seperti SVM, RF, DT, *Naïve Bayes* (NB), *Logistic Regression* (LR), dan *Ridge Classifier* (RC). Dari hasil evaluasi performa masing-masing model, dapat diketahui bahwa model SVM dengan optimalisasi BO mampu mengungguli model lainnya dengan skor akurasi sebesar 92,3%.

Berdasarkan referensi diatas, penelitian ini ingin mengusulkan penggunaan metode *Bayesian Optimization* (BO) dalam mengoptimasi metode *machine learning* untuk memprediksi tingkat risiko pada ibu hamil. Metode *machine learning* yang diusulkan dalam penelitian ini didasari dari hasil penelitian sebelumnya, dimana metode *Decision Tree* (DT) dan *Extreme Gradient Boosting* (XGB) mampu memprediksi tingkat risiko kehamilan pada ibu hamil dengan baik. Sehingga, dalam penelitian ini akan dilakukan optimasi *hyper-parameter* dari kedua metode tersebut guna memberikan gambaran terkait dampak implementasi metode *Bayesian Optimization* (BO).

2. METODE PENELITIAN

Pada penelitian ini, detail informasi mengenai alur penelitian sebagai gambaran terkait dengan skenario pelaksanaan penelitian dapat dilihat pada Gambar 1.



Gambar 1. Alur metode yang diusulkan

Gambar 1 menunjukkan alur dari tahapan penelitian yang diusulkan. Komposisi utama dalam tahapan penelitian ini dimulai dari tahap akuisisi data, selanjutnya tahap *pre-processing* dengan mentransformasikan representasi data menggunakan

teknik normalisasi data. Setelah data hasil normalisasi didapatkan, tahap selanjutnya dilakukan pembagian data menjadi data latih (*training set*) dan data uji (*testing set*) dengan rasio 7:3. Pembagian ini menggunakan *teknik stratified random sampling*, yang memastikan distribusi kelas target tetap seimbang antara data latih dan data uji. Setelah data latih dan uji didapatkan, maka selanjutnya dilakukan tahap pelatihan model *Decision Tree* (DT) dan *Extreme Gradient Boosting* (XGB) dengan *Bayesian Optimization*, dan diakhiri dengan tahap pengujian dan evaluasi untuk mengetahui performa dari model yang diusulkan. Detail informasi mengenai rangkaian tahapan diatas akan dijelaskan pada bagian berikut.

2.1. Dataset

Pada penelitian ini akan digunakan *dataset* publik mengenai tingkat risiko kehamilan yang bersumber dari <https://archive.ics.uci.edu/dataset/863/maternal+health+risk> (Ahmed, 2020). Dataset tersebut terdiri dari 1014 item data dan memiliki 6 variabel *independent* yaitu *Age*, *Systolic Blood Pressure* sebagai *SystolicBP*, *Diastolic BP* sebagai *DiastolicBP*, *Blood Sugar* sebagai *BS*, *Body Temperature* sebagai *BodyTemp*, *HeartRate* dan *RiskLevel*. Kemudian terdapat variabel *Risk Level* sebagai variabel dependen dalam penelitian ini. Variabel *Risk Level* memiliki 3 (tiga) variasi nilai yaitu *High Risk* (risiko tinggi), *Mid Risk* (risiko sedang), dan *Low Risk* (risiko rendah). Data dikumpulkan dari berbagai rumah sakit, klinik komunitas, layanan kesehatan ibu dari daerah pedesaan Bangladesh melalui sistem pemantauan risiko berbasis IoT (Ahmed et al., 2020).

Tabel 1. Spesifikasi Variabel-Variabel pada Dataset Tingkat Risiko Kehamilan

Nama Variabel	Tipe Data	Deskripsi Variabel
Age (usia)	Integer	Usia dalam tahun ketika seorang wanita hamil.
SystolicBP	Integer	Nilai Tekanan Darah tertinggi dalam mmHg.
DiastolicBP	Integer	Nilai Tekanan Darah yang lebih rendah dalam mmHg
BS	Integer	Kadar glukosa darah dinyatakan dalam konsentrasi molar
BodyTemp	Integer	Temperatur tubuh saat pengukuran/pemeriksaan
HeartRate	Integer	Denyut jantung istirahat normal
RiskLevel	Categorical	Prediksi Tingkat Intensitas Risiko selama kehamilan dengan mempertimbangkan atribut sebelumnya.

Pada Tabel 1 ditunjukkan detail informasi masing-masing variabel yang akan digunakan dalam penelitian ini. Keseluruhan variabel *independent* memiliki tipe data *integer*, sementara variabel *dependent* memiliki tipe data kategorik.

2.2. Tahap Preprocessing

Penelitian ini menggunakan skema *pre-processing* sebagai bagian awal perlakuan terhadap data *maternal risk level*, di mana data tersebut ditransformasikan menggunakan teknik *standard scaler*. Penggunaan teknik ini mampu memusatkan dan menyetarakan skala data, sehingga model *machine learning* dapat memaksimalkan kontribusi pada masing-masing atribut atau variabel secara proposional (Ahsan et al., 2021; Izonin et al., 2022). Diharapkan dengan kontribusi yang setara antara variabel dapat membantu peningkatan performa dari model *machine learning*.

Proses transformasi menggunakan teknik *standard scaler* memanfaatkan perhitungan *z-score* yang bisa dilihat pada persamaan dibawah ini (Mahmud Sujon et al., 2024):

$$z = \frac{x - \mu}{\sigma} \quad (1)$$

Dari persamaan (1), diketahui bahwa z merupakan nilai *z-score*, kemudian x adalah individual data *point*. Sementara itu nilai μ menunjukkan nilai rerata dari dataset yang digunakan. Lalu nilai σ merupakan nilai standar deviasi dari dataset yang dapat dihitung dengan persamaan berikut:

$$\sigma = \sqrt{\frac{\sum_{i=1}^N (x_i - \mu)^2}{N}} \quad (2)$$

Pada persamaan (2) dapat diketahui bahwa komponen x_i merepresentasikan nilai data ke i secara individu. Kemudian N merupakan total keseluruhan data dalam dataset.

2.3. Decision Tree (DT)

Decision Tree atau pohon keputusan merupakan salah satu metode *machine learning* yang umum digunakan untuk menangani kasus regresi atau klasifikasi. Secara umum, DT memiliki dua komponen utama dalam model yang terbentuk, yaitu komponen cabang dan *node*. Cabang merupakan komponen yang menunjukkan arah Keputusan. Sementara itu, *node* pada DT dapat dibagi lagi menjadi *node* akar (*root node*), *node* keputusan (*decision node*), dan *node* daun (*leaf node*). *Node* akar merupakan *node* awal dalam DT. Kemudian *node* keputusan merupakan *node* yang mewakili keputusan berdasarkan nilai dari variabel yang disematkan. Selanjutnya *node* daun merupakan *node* akhir disetiap cabang yang menjadi cabang terakhir atau hasil akhir dari keputusan. *Node* daun berisi label atau kelas (klasifikasi) atau nilai prediksi (regresi). Tahapan dalam proses pembangunan model DT dapat dilihat pada penjelasan berikut.

Menyiapkan data: tahapan ini bertujuan untuk memastikan data dalam kondisi terstruktur dan tidak mengandung *missing value* atau *outlier*.

Menentukan kriteria berhenti: tahap ini berguna untuk menghentikan proses rekursif dari

tahap sebelumnya. Kondisi pemberhentian proses rekursif dapat ditentukan dengan menggunakan kriteria batas jumlah fitur yang digunakan, tingkat kedalaman model (*depth*), atau jumlah minimum *sample* dan *sample split* pada masing-masing *leaf node*. Kriteria tersebut merupakan *hyper-parameter* yang berpengaruh terhadap hasil pelatihan *decision tree*.

Memilih atribut: memilih atribut sebagai kriteria pemisahan untuk setiap *node*. Kriteria pemilihan atribut dalam tahap ini dapat menggunakan beberapa metode, seperti *information gain*, *gini impurity*, dan *gain ratio*.

Membangun model: model *decision tree* akan dibangun secara rekursif berdasarkan atribut terbaik pada masing-masing *node*. Dataset akan dibagi berdasarkan *value* dari atribut tersebut untuk membentuk pola cabang pada model *decision tree*.

2.4. Extreme Gradient Boosting (XGB)

Extreme Gradient Boosting (XGB) merupakan salah satu pengembangan model dengan pendekatan *gradient boosting* (Zhao et al., 2020). Model XGB dikembangkan dengan memanfaatkan *decision tree* sebagai dasar dari *classifier* nya. Model XGB sering digunakan dalam pengembangan *machine learning* oleh karena kemampuannya yang cepat, efisien, dan skalabilitasnya dalam menghasilkan performa yang baik (Zhang, Jia and Shang, 2022).

Tahapan atau alur yang dilakukan dalam proses pembentukan model XGB dapat dilihat sebagai berikut:

Persiapan Data: menyiapkan dataset yang akan digunakan dengan memastikan bahwa dataset tersebut sudah dalam keadaan bersih tanpa adanya *missing value* dan *outlier*. Pecah komponen dataset menjadi komponen fitur (*independent variabel*) dan target (*dependent variabel*).

Tabel 2. Spesifikasi *Hyper-parameter* yang digunakan dalam model XGB

Nama <i>Hyper-parameter</i>	Deskripsi <i>Hyper-parameter</i>
<i>n-estimator</i>	Jumlah model pohon (<i>tree</i>) yang digunakan dalam model XGB
<i>Max-depth</i>	Batas kedalaman maksimum yang dicapai oleh model pohon (<i>tree</i>)
<i>Learning rate</i>	Ukuran Langkah penyusutan dalam proses pelatihan model (<i>model updating</i>)
<i>Sub-sample</i>	Rasio data latih yang digunakan dalam proses pelatihan model XGB
<i>Colsample by tree</i>	Rasio jumlah kolom/variabel/fitur yang digunakan dalam proses pelatihan model XGB
<i>Gamma</i>	Nilai minimum dari pengurangan fungsi <i>loss</i> sebagai prasyarat dalam proses partisi berikutnya

Penentuan *Hyper-parameter*: Menentukan *hyper-parameter* yang nantinya digunakan dalam proses pelatihan model XGB. Beberapa komponen *hyper-parameter* yang ada pada pelatihan model XGB diantaranya jumlah pohon (*number of estimator*), kedalaman maksimum (*maximum depth*),

learning rate, *sub-sample*, *colsample by tree*, dan *gamma*. Detail informasi mengenai masing-masing *hyper-parameter* dapat dilihat pada Tabel 2.

Pelatihan Model: setelah *hyper-parameter* yang diperlukan dalam proses persiapan model diperoleh, selanjutnya model akan dilatih dengan menggunakan dataset yang telah disiapkan. Dari hasil pelatihan ini, model XGB akan terbentuk dengan karakteristik yang sesuai dengan pola dataset yang digunakan.

2.5. Bayesian Optimization

Bayesian optimization atau optimasi Bayesian merupakan salah satu metode optimisasi berbasis probabilitas statistik. Sama seperti metode optimisasi lainnya, optimasi *Bayesian* digunakan untuk meningkatkan efisiensi proses komputasi, konsumsi waktu, dan sumber daya dalam mengevaluasi suatu fungsi objektif. Metode ini memungkinkan untuk mencari nilai optimum dari fungsi objektif dari dalam ruang pencarian. Optimisasi *Bayesian* mempertimbangkan dua komponen eksplorasi dan eksploitasi, dimana eksplorasi berfokus pada pencarian pada daerah yang belum dieksplorasi dengan baik. Kemudian eksploitasi berfokus pada penentuan langkah berikutnya berdasarkan informasi yang telah ditemukan sebelumnya.

Secara umum proses optimisasi *Bayesian* dapat dijabarkan sebagai berikut:

Inisialisasi: memulai dengan menetapkan dan mengevaluasi fungsi objektif untuk mendapatkan data awal.

Modelling: menggunakan data yang diperoleh pada proses inisialisasi untuk membangun model probabilistik yang umumnya memanfaatkan pendekatan *Gaussian* untuk memperkirakan fungsi objektif. Proses *Gaussian* dinilai dapat memberikan estimasi yang lebih baik terkait keberadaan nilai optimum pada ruang pencarian.

Akuisisi: fungsi akuisisi merupakan fungsi yang berguna untuk menentukan titik pencarian atau evaluasi berikutnya. Pada proses ini akan dilakukan perhitungan selisih antara eksplorasi dan eksploitasi. Beberapa fungsi akuisisi yang dapat digunakan adalah *expected improvement* (EI), *lower confidence bound* (LCB), dan *probability of improvement* (PI). Masing-masing fungsi akuisisi diatas memiliki kelebihan dan kelemahan, namun jika menggabungkan ketiganya menjadi sebuah fungsi baru dengan teknik *ensemble* maka akan diperoleh fungsi akuisisi yang dapat meningkatkan performa dalam menangani permasalahan optimisasi secara luas. Kombinasi ketiga fungsi akuisisi tersebut diberi nama “*gp_hedge*”.

Evaluasi: dilakukan tahap evaluasi terhadap fungsi objektif berdasarkan titik terpilih dari fungsi akuisisi.

Pembaruan Model: Perbarui model probabilistic dengan memanfaatkan data baru yang didapatkan pada proses evaluasi fungsi objektif.

Proses diatas akan diulang secara iteratif hingga *stop criterion* tercapai. *Stop criterion* yang biasa digunakan seperti jumlah iterasi maksimum atau konvergensi nilai optimal yang ingin dicapai.

Pada penelitian ini, optimasi *Bayesian* akan digunakan untuk mencari konfigurasi *hyper-parameter* yang optimal dari model *decision tree* dan XGB.

2.6. Evaluasi Performa

Evaluasi performa dilakukan dengan mengidentifikasi nilai parameter yang digunakan sebagai indikator capaian performa yaitu tingkat akurasi, presisi, *recall*, dan *F1-score*.

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \times 100\% \quad (3)$$

$$Presisi = \frac{TP}{TP + FP} \times 100\% \quad (4)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (5)$$

$$F1 = 2 \times \frac{Presisi \times Recall}{Presisi + Recall} \quad (6)$$

Akurasi (Persamaan (3)) digunakan sebagai indikator kemampuan model dalam memprediksi dengan benar seluruh kelas dari target yang ditetapkan. Kemudian nilai presisi (Persamaan (4)) menunjukkan persentase kasus yang diprediksi model sebagai positif yang benar-benar positif. Lalu nilai *recall* (Persamaan (5)) mengukur persentase kasus positif yang diprediksi oleh model dengan benar. Sementara nilai *F1-score* (Persamaan (6)) merupakan indikator pengukuran yang didapat dari gabungan nilai presisi dan *recall*, sehingga memberikan gambaran keseimbangan persentase diantara kedua indikator tersebut.

Pada penelitian ini, hasil evaluasi model dengan intervensi optimasi akan dibandingkan dengan hasil evaluasi pada model standar untuk mengetahui perbedaan dan dampak dari optimasi yang diterapkan. Selain itu, pada indikator presisi, *recall*, dan *F1-score* akan ditampilkan nilai untuk masing-masing kategori atau kelas pada variabel target (*dependent variabel*).

3. HASIL DAN PEMBAHASAN

Optimasi metode pembelajaran mesin (*decision tree* dan *extreme gradient boosting* (XGB)) dengan menggunakan pendekatan optimasi *Bayesian* telah dilakukan dengan data risiko kehamilan.

Sample data original dari dataset risiko kehamilan dapat dilihat pada Tabel 3. Data yang digunakan terdiri dari 1014 data dan jumlah kolom sebesar 7 variabel dengan rincian 6 kolom sebagai *independent variabel* dan 1 kolom sebagai *dependent variabel*.

Tabel 3. *Sample data* risiko kehamilan dengan 6 variabel *independent* dan 1 variabel *dependent*

No.	Ages	Systolic BP	Diastolic BP	Blood Sugar	Body Temperature	Heart Rate	Risk Level
1	25	130	80	15	98	86	high risk
2	35	140	90	13	98	70	high risk
3	29	90	70	8	100	80	high risk
4	30	140	85	7	98	70	high risk
5	35	120	60	6.1	98	76	low risk
...	...	...	...	...	...	...	...
1010	22	120	60	15	98	80	high risk
1011	55	120	90	18	98	60	high risk
1012	35	85	60	19	98	86	high risk
1013	43	120	90	18	98	70	high risk
1014	32	120	65	6	101	76	mid risk

Tabel 4. *Sample data* risiko kehamilan yang telah mengalami transformasi dengan pendekatan *standard scaler* (z-score)

No.	Ages	Systolic BP	Diastolic BP	Blood Sugar	Body Temperature	Heart Rate	Risk Level
1	-0.3617	0.9134	0.2550	1.9059	-0.4852	1.4470	high risk
2	0.3808	1.4570	0.9755	1.2983	-0.4852	-0.5321	high risk
3	-0.0647	-1.2611	-0.4655	-0.2205	0.9739	0.7048	high risk
4	0.0095	1.4570	0.6153	-0.5243	-0.4852	-0.5321	high risk
5	0.3808	0.3698	-1.1860	-0.7977	-0.4852	0.2101	low risk
...	...	...	...	...	...	...	...
1010	-0.5845	0.3698	-1.1860	1.9059	-0.4852	0.7048	high risk
1011	1.8658	0.3698	0.9755	2.8172	-0.4852	-1.7690	high risk
1012	0.3808	-1.5329	-1.1860	3.1210	-0.4852	1.4470	high risk
1013	0.9748	0.3698	0.9755	2.8172	-0.4852	-0.5321	high risk
1014	0.1580	0.3698	-0.8258	-0.8281	1.7034	0.2101	mid risk

Independent variabel yang digunakan yaitu *Age*, *Systolic Blood Pressure* sebagai *SystolicBP*, *Diastolic BP* sebagai *DiastolicBP*, *Blood Sugar* sebagai *BS*, *Body Temperature* sebagai *BodyTemp*, dan *HeartRate*. Sementara *dependent* variabelnya adalah *RiskLevel* yang terbagi menjadi 3 tingkat risiko yaitu *High Risk* (risiko tinggi), *Mid Risk* (risiko sedang), dan *Low Risk* (risiko rendah).

Pada tahap awal, dataset risiko kehamilan ditransformasikan dengan menggunakan pendekatan *standard scaler*. *Sample* hasil transformasi dataset risiko kehamilan dapat dilihat pada Tabel 4. Dari data hasil transformasi, kemudian dilakukan pembagian data dengan menggunakan teknik *split data* berbasis pendekatan *stratified* untuk menghasilkan data latih dan data uji. Pendekatan *stratified* merupakan teknik yang digunakan untuk proses pemecahan data dimana dalam prosesnya, pendekatan ini mampu mempertahankan distribusi tiap kelas pada data latih dan data uji yang setara dengan distribusi pada dataset secara utuh (Huo et al., 2023). Penggunaan teknik ini bertujuan untuk mencegah terjadinya *overfitting* atau generalisasi model yang lemah yang berpotensi muncul pada saat distribusi kelas pada data latih dan data uji berbeda secara signifikan (Farias, Ludermitr and Bastos-Filho, 2020; Merrillees and Du, 2021). Dari hasil *split data* diperoleh jumlah data latih sebesar 709 *item* data dan data uji sebesar 305 *item* data.

Selanjutnya, himpunan data latih digunakan dalam tahap pelatihan model, sementara data uji digunakan dalam proses evaluasi atau pengujian performa model hasil pelatihan. Pada penelitian ini diimplementasikan metode optimasi *Bayesian* yang diterapkan pada metode *decision tree* (BODT) dan *extreme gradient boosting* (BOXGB) untuk mengoptimasi komponen *hyper-parameter*. Komponen *hyper-paramter* dari kedua metode tersebut dapat diketahui pada Tabel 5 dan Tabel 6.

Tabel 5. *Hyper-parameter* model *decision tree*

Decision Tree (DT)	
Hyper-parameter	Domain
Criterion	[Gini, Entropy]
Max_depth	[1, 100]
Min sample split	[2, 20]
Min sample leaf	[1, 10]
Max features	[1, 4]

Tabel 6. *Hyper-parameter* model XGB

Extreme Gradient Boosting (XGB)	
Hyper-parameter	Domain
Learning rate	[0.01, 1.0, log-uniform]
Max_depth	[1, 10]
Number of estimators	[50, 200]
Sub sample	[0.1, 1.0, log-uniform]
Colsample by tree	[0.1, 1.0, log-uniform]
Gamma	[1e-9, 0.5, log-uniform]

Tabel 7. Hasil evaluasi performa model yang diusulkan

Iterasi	Metode	Akurasi	Presisi			Recall			F1 Score		
			High Risk	Mid Risk	Low Risk	High Risk	Mid Risk	Low Risk	High Risk	Mid Risk	Low Risk
10 kali	BODT	72%	85%	71%	62%	85%	75%	57%	85%	73%	60%
50 kali	BODT	83%	97%	83%	72%	84%	85%	78%	90%	84%	75%
10 kali	BOXGB	87%	95%	89%	80%	90%	86%	86%	92%	88%	83%
50 kali	BOXGB	85%	95%	88%	75%	89%	81%	85%	92%	84%	80%

Pada Tabel 5 dan Tabel 6, masing-masing terdapat 5 *hyper-parameter* untuk model *decision tree* dan 6 *hyper-parameter* pada model XGB yang selanjutnya dioptimasi dengan menggunakan optimisasi *Bayesian*.

Pada kolom *domain* dijabarkan rentang nilai batas bawah dan batas atas area pencarian. Pada Tabel 6, bagian *domain* memiliki tambahan berupa *log-uniform* yang berarti pencarian nilai optimum pada area yang luas didasari pada distribusi area logaritmik. Hal ini bertujuan untuk mencakup area yang luas dari rentang area pencarian secara efisien khususnya ketika nilai *hyper-parameter* memiliki jumlah variasi eksponensial.

Dari daftar *hyper-parameter* yang disebutkan pada Tabel 5 dan Tabel 6, selanjutnya dilakukan optimasi dengan menggunakan teknik *Bayesian optimization*. Pada tahap ini, BO akan dikonfigurasi dengan spesifikasi jumlah iterasi sebanyak 10 kali dan 50 kali untuk optimasi pada metode XGB dan DT. lalu, parameter *cross-validation* (CV) diatur dengan nilai 5 dan nilai *random-state* adalah 42. Perbedaan jumlah iterasi pada *Bayesian Optimization* dilakukan untuk meninjau dampak dari perbedaan jumlah iterasi yang diaplikasikan.

Dari hasil evaluasi performa, didapatkan nilai akurasi, presisi, *recall*, dan *F1-score* sebagai Tabel 7. Pada Tabel 7 diperlihatkan hasil evaluasi metode DT dan XGB yang dioptimalisasi *hyper-parameter*-nya dengan menggunakan pendekatan *Bayesian*. Dari hasil tersebut terlihat bahwa metode BOXGB mampu memberikan performa terbaik dibandingkan dengan metode BODT. Perubahan jumlah iterasi pada proses optimisasi *Bayesian* memberikan dampak pada perolehan parameter performa masing-masing metode. Hal ini mengindikasikan bahwa perubahan jumlah iterasi mampu mempengaruhi kemampuan dari metode *Bayesian* dalam mencapai nilai optimal. Pengaruh nilai iterasi dapat dilihat pada usulan model BOXGB dimana penggunaan jumlah iterasi yang berlebihan (50 kali) mengakibatkan penurunan nilai performa model dibandingkan dengan ketika menggunakan iterasi sebanyak 10 kali. Lain halnya dengan model BODT dimana penggunaan 50 kali iterasi mampu memberikan peningkatan performa secara keseluruhan dibanding dengan hanya menggunakan 10 kali iterasi. Seperti yang diketahui bahwa jumlah iterasi mempengaruhi proses eksplorasi dan eksploitasi dari algoritma *Bayesian*

Optimization (Galuzzi et al., 2020). Pada iterasi awal, proses difokuskan pada eksplorasi yang bertujuan untuk menemukan rentang parameter. Sementara iterasi berikutnya ditekankan proses eksploitasi guna menyaring ruang pencarian pada area yang potensial. Terlalu sedikit nilai iterasi mengakibatkan terbatasnya ruang gerak model dalam menemukan *global optima*, namun terlalu banyak nilai iterasi berdampak pada hasil yang terdegradasi dan sumber daya komputasi yang terbuang percuma (Garnett, 2023).

Hasil optimasi *hyper-parameter* dari kedua model yang diusulkan (BODT dan BOXGB) dapat dilihat pada Tabel 8 dan Tabel 9 sebagai berikut:

Tabel 8. Hasil optimasi *hyper-parameter* model *decision tree*
Decision Tree (DT)

<i>Hyper-parameter</i>	<i>Domain</i>
<i>Criterion</i>	<i>Gini</i>
<i>Max_depth</i>	100
<i>Min sample split</i>	2
<i>Min sample leaf</i>	1
<i>Max features</i>	4


Tabel 9. Hasil optimasi *hyper-parameter* model XGB
Extreme Gradient Boosting (XGB)

<i>Hyper-parameter</i>	<i>Domain</i>
<i>Learning rate</i>	0.11304216699488043
<i>Max_depth</i>	7
<i>Number of estimators</i>	186
<i>Sub sample</i>	0.7453280360438532
<i>Colsample by tree</i>	0.8195980974464558
<i>Gamma</i>	6.462532703922274e-06

Pada Tabel 8 ditunjukkan nilai *hyper-parameter* model *Decision Tree* (DT) dari hasil optimasi *Bayesian* dengan 50 kali iterasi. Sementara pada tabel 9, diperlihatkan nilai *hyper-parameter* model XGB dari hasil optimasi *Bayesian* dengan 10 kali iterasi.

Pada Gambar 2, ditunjukkan hasil perbandingan model teroptimasi yang diusulkan dengan model pada penelitian terdahulu (MUTLU et al., 2023; Hossain et al., 2024). Dari gambar tersebut dapat dipahami bahwa model XGB yang dioptimasi dengan *Bayesian Optimization* mampu memberikan performa terbaik dibandingkan dengan model penelitian sebelumnya. Pada evaluasi parameter presisi menunjukkan, model BOXGB mampu memprediksi sesuai dengan kelas

pada seluruh kelas tingkat risiko dengan rata-rata keakuratan sebesar 88%.



Gambar 2. Perbandingan performa model yang diusulkan dengan penelitian sebelumnya

Hasil tersebut mampu mengungguli performa akurasi dari penelitian terdahulu yaitu sebesar 84% (MUTLU et al., 2023) dan 85% (Hossain et al., 2024). Sedangkan nilai *recall* mengindikasikan bahwa model BOXGB mampu memprediksi dengan tepat kelas tingkat risiko kehamilan dengan persentase sebesar 87%. Kemudian nilai *F1-score* memberikan informasi bahwa model yang diusulkan memiliki persentase tingkat keseimbangan terbaik dibandingkan dengan metode lain yakni sebesar 88%. Secara keseluruhan, implementasi teknik optimasi *Bayesian* pada model XGB mampu meningkatkan performa akurasi sebesar 87%.

Keberhasilan BOXGB dalam mengungguli hasil penelitian sebelumnya menunjukkan pentingnya penggunaan metode optimasi yang tepat dalam menentukan *hyper-parameter* pada model *machine learning*. Penelitian ini memberikan gambaran efektifitas dari metode *Bayesian Optimization* dalam meningkatkan kinerja model XGB khususnya dalam konteks prediksi tingkat risiko kehamilan yang memiliki kebutuhan nilai akurasi tinggi. Metode *Bayesian* yang memanfaatkan pendekatan berbasis probabilistik secara efisien mampu menangani fungsi objektif yang tidak eksplisit serta mampu mencari *hyper-parameter* dari data *noise*. Sehingga implementasi metode *Bayesian Optimization* dalam menentukan *hyper-parameter* dari model XGB menjadi salah satu alternatif dalam menangani kasus risiko kehamilan. Secara keseluruhan, hasil penelitian ini memperkaya pendekatan berbasis data dalam ilmu komputer dan memperkuat keterkaitan antara teknologi komputasi dengan aplikasi nyata khususnya dalam bidang kesehatan.

4. KESIMPULAN

Implementasi algoritma *Bayesian optimization* (BO) pada *hyper-parameter* model pembelajaran mesin (*machine learning*) dalam upaya penentuan tingkat risiko kehamilan pada ibu hamil telah dilakukan. Tahapan akuisisi data dan *preprocessing* dengan menggunakan teknik normalisasi mampu menghasilkan kelompok data yang terdiri dari data

latih dan data uji. Implementasi BO dilakukan pada *hyper-parameter* model *Decision Tree* (DT) dan *Extreme Gradient Boosting* (XGB). Hasil evaluasi menunjukkan adanya pengaruh nilai iterasi yang diterapkan pada *Bayesian Optimization*. Selain itu, performa XGB setelah mengalami proses *tuning* pada *hyper-parameter*-nya oleh teknik *Bayesian Optimization* mengalami peningkatan dibandingkan dengan model dari penelitian sebelumnya. Capaian nilai akurasi pada model BOXGB yaitu 87% diikuti dengan nilai rata-rata presisi, *recall*, dan *F1-score* masing-masing sebesar 88%, 87%, dan 88%. Secara keseluruhan implementasi *Bayesian Optimization* mampu memberikan setelan *hyper-parameter* yang dapat meningkatkan kemampuan model *machine learning* khususnya dalam memprediksi tingkat risiko kehamilan pada ibu hamil berdasarkan data pengukuran klinis. Meskipun dalam penelitian ini telah diimplementasikan teknik optimasi *hyper-parameter*, tidak menutup kemungkinan untuk menjelajah ruang *hyper-parameter* lain yang lebih luas. Penggunaan teknik optimasi yang lebih efisien juga dapat menjadi potensi pengembangan untuk kedepannya.

DAFTAR PUSTAKA

- AHMED, M., 2020. Maternal Health Risk [Dataset]. *UCI Machine Learning Repository*. [online] <https://doi.org/https://doi.org/10.24432/C5DP5D>.
- AHMED, M., KASHEM, M.A., RAHMAN, M. AND KHATUN, S., 2020. Review and Analysis of Risk Factor of Maternal Health in Remote Area Using the Internet of Things (IoT). [online] pp.357–365. https://doi.org/10.1007/978-981-15-2317-5_30.
- AHSAN, M., MAHMUD, M., SAHA, P., GUPTA, K. AND SIDDIQUE, Z., 2021. Effect of Data Scaling Methods on Machine Learning Algorithms and Model Performance. *Technologies*, [online] 9(3), p.52. <https://doi.org/10.3390/technologies9030052>.
- ALLAAM, F., PRASETIO, B.H. AND MAULANA, R., 2023. Sistem Deteksi Dini Penyakit Preeklampsia Melalui Perubahan Warna Urine Berdasarkan Protein dengan Menggunakan Metode Naive Bayes Classifier. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 10(4), pp.807–814. <https://doi.org/10.25126/jtiik.20241046908>.
- BACH, P., SCHACHT, O., CHERNOZHUKOV, V., KLAASSEN, S. AND SPINDLER, M., 2024. Hyperparameter Tuning for Causal Inference with Double Machine Learning: A Simulation Study. [online] (2018), pp.1–53. Available at: <<http://arxiv.org/abs/2402.04674>>.
- BUNGA, F.R., FLORA, S. AND TARIGAN, N., 2023. Analisis Faktor Risiko Kejadian Hipertensi Pada Ibu Hamil di Puskesmas Telaga

- Kabupaten Gorontalo. *Health Information : Jurnal Penelitian*, [online] 15(2), pp.1–6. Available at: <<https://myjurnal.poltekkes-kdi.ac.id/index.php/hijp/article/view/1048>>.
- ELSHWEY, A.M., SHAMS, M.Y., EL-RASHIDY, N., ELHADY, A.M., SHOHIEB, S.M. & TAREK, Z., 2023. Bayesian Optimization with Support Vector Machine Model for Parkinson Disease Classification. *Sensors*, 23(4), pp.1–21. <https://doi.org/10.3390/s23042085>.
- FARIAS, F., LUDERMIR, T. & BASTOS-FILHO, C., 2020. Similarity based stratified splitting: an approach to train better classifiers. *arXiv preprint arXiv:2010.06099*.
- GALUZZI, B.G., GIORDANI, I., CANDELIERI, A., PEREGO, R. & ARCHETTI, F., 2020. Bayesian Optimization for Recommender System. [online] pp.751–760. https://doi.org/10.1007/978-3-030-21803-4_75.
- GARNETT, R., 2023. *Bayesian Optimization*. [online] Cambridge University Press. <https://doi.org/10.1017/9781108348973>.
- HOSSAIN, M.M., KASHEM, M.A., NAYAN, N.M. & CHOWDHURY, M.A., 2024. A Medical Cyber-physical system for predicting maternal health in developing countries using machine learning. *Healthcare Analytics*, [online] 5(October 2023), p.100285. <https://doi.org/10.1016/j.health.2023.100285>.
- HUO, T., GLUECK, D.H., SHENKMAN, E.A. & MULLER, K.E., 2023. Stratified split sampling of electronic health records. *BMC Medical Research Methodology*, [online] 23(1), p.128. <https://doi.org/10.1186/s12874-023-01938-0>.
- ISYTI'AROH, I., SUGIHARTO, S., ROFIQOH, S. & WIDYASTUTI, W., 2023. Studi Awal Resiko Gestasional Diabetik Melitus di Wilayah Kerja Puskesmas Bojong I Kabupaten Pekalongan. *Jurnal Ilmiah Kesehatan Keperawatan*, [online] 19(1), p.50. <https://doi.org/10.26753/jikk.v19i1.1088>.
- IZONIN, I., TKACHENKO, R., SHAKHOVSKA, N., ILCHYSHYN, B. & SINGH, K.K., 2022. A Two-Step Data Normalization Approach for Improving Classification Accuracy in the Medical Diagnosis Domain. *Mathematics*, [online] 10(11), p.1942. <https://doi.org/10.3390/math10111942>.
- KUSUMA, E.J., NURMANDHANI, R. & HANDAYANI, S., 2022. Evaluasi Identifikasi Kanker Serviks Berdasarkan Data Risiko Perilaku dengan Data Mining. *JPKM: Jurnal Profesi Kesehatan Masyarakat*, [online] 3(1), pp.9–19. <https://doi.org/10.47575/jpkm.v3i1.266>.
- KUSUMA, E.J., PANTIAWATI, I. & HANDAYANI, S., 2022. Melanoma Classification based on Simulated Annealing Optimization in Neural Network. *Knowledge Engineering and Data Science*, [online] 4(2), p.97. <https://doi.org/10.17977/um018v4i22021p97-104>.
- LIU, Z., JIANG, P., DE BOCK, K.W., WANG, J., ZHANG, L. & NIU, X., 2024. Extreme gradient boosting trees with efficient Bayesian optimization for profit-driven customer churn prediction. *Technological Forecasting and Social Change*, [online] 198, p.122945. <https://doi.org/10.1016/j.techfore.2023.122945>.
- LU, H.Y., DING, X., HIRST, J.E., YANG, Y., YANG, J., MACKILLOP, L. & CLIFTON, D., 2023. Digital Health and Machine Learning Technologies for Blood Glucose Monitoring and Management of Gestational Diabetes. *IEEE Reviews in Biomedical Engineering*, [online] pp.1–19. <https://doi.org/10.1109/RBME.2023.3242261>.
- MAHMUD SUJON, K., BINTI HASSAN, R., TUSNIA TOWSHI, Z., OTHMAN, M.A., ABDUS SAMAD, M. & CHOI, K., 2024. When to Use Standardization and Normalization: Empirical Evidence From Machine Learning Models and XAI. *IEEE Access*, [online] 12, pp.135300–135314. <https://doi.org/10.1109/ACCESS.2024.3462434>.
- MERRILLEES, M. & DU, L., 2021. Stratified sampling for extreme multi-label data. In: *Pacific-Asia Conference on Knowledge Discovery and Data Mining*. pp.334–345. <https://doi.org/https://doi.org/10.48550/arXiv.2103.03494>.
- MUTLU, H.B., DURMAZ, F., YÜCEL, N., CENGİL, E. & YILDIRIM, M., 2023. Prediction of Maternal Health Risk with Traditional Machine Learning Methods. *NATURENGS MTU Journal of Engineering and Natural Sciences Malatya Turgut Ozal University*, 4(1), pp.16–23. <https://doi.org/10.46572/naturengs.1293185>.
- PINANDITO, A., WICAKSONO, S.A. & WIJOYO, S.H., 2023. Implementasi Machine Learning dalam Deteksi Risiko Tinggi Diabetes Melitus pada Kehamilan. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 10(4), pp.739–746. <https://doi.org/10.25126/jtiik.20241047005>.
- PIRMANSYAH, E. & BERAWI, K.N., 2023. Faktor-Faktor Yang Berhubungan Dengan Kejadian Preeklampsia Pada Ibu Hamil: Tinjauan Pustaka. *Medical Profession Journal of Lampung*, 13(4), pp.575–577. <https://doi.org/https://doi.org/10.53089/medula.v13i4.757>.
- WU, J., CHEN, X.Y., ZHANG, H., XIONG, L.D., LEI, H. & DENG, S.H., 2019. Hyperparameter

- optimization for machine learning models based on Bayesian optimization. *Journal of Electronic Science and Technology*, [online] 17(1), pp.26–40. <https://doi.org/10.11989/JEST.1674-862X.80904120>.
- ZHANG, P., JIA, Y. & SHANG, Y., 2022. Research and application of XGBoost in imbalanced data. *International Journal of Distributed Sensor Networks*, [online] 18(6), p.155013292211069. <https://doi.org/10.1177/15501329221106935>.
- ZHAO, W., LI, J., ZHAO, J., ZHAO, D., LU, J. & WANG, X., 2020. XGB model: Research on evaporation duct height prediction based on XGBoost algorithm. *Radioengineering*, 29(1), pp.81–93. <https://doi.org/10.13164/re.2020.0081>.