

Perbandingan Performa Data Penyakit Jantung Menggunakan Pendekatan Klasifikasi *Boosting Methods*

Mega Devia In Baliani ¹⁾, Roy Rudolf Huizen ²⁾, Gede Angga Pradipta ³⁾

Program Studi Magister Sistem Informasi
Institut Teknologi dan Bisnis STIKOM Bali
Denpasar, Indonesia

e-mail: 222012034@stikom-bali.ac.id¹, roy@stikom-bali.ac.id²,
angga_pradipta@stikom-bali.ac.id³

Abstrak

Penyakit jantung merupakan penyebab utama kematian di seluruh dunia, termasuk di Indonesia. Deteksi dini dan prediksi penyakit ini menjadi penting dalam upaya pencegahan dan penanganannya. Pendekatan *Machine Learning* (ML) telah digunakan dalam prediksi penyakit jantung, dengan hasil penelitian menunjukkan potensi besar dalam mendukung identifikasi dini. Beberapa studi sebelumnya telah berhasil meningkatkan akurasi prediksi hingga 85,21% dengan menggunakan berbagai metode *ensemble* dan *hybrid model*. Penelitian juga menyoroti efektivitas algoritma *Boosting*, dengan algoritma *Gradient Boosting* mampu mencapai akurasi hingga 89,5%. Namun, masih diperlukan penelitian lebih lanjut untuk membandingkan metode *Boosting* yang lebih unggul. Hasil penelitian menekankan pentingnya pengembangan lebih lanjut dalam hal algoritma, optimasi parameter, dan penggunaan dataset yang lebih besar. Eksplorasi lebih lanjut diharapkan dapat meningkatkan validitas dan generalisasi hasil penelitian di masa mendatang.

Kata kunci: *Adaboost, Gradient Boosting, Heart Disease, Machine Learning, Boosting Methods.*

1. Pendahuluan

Penyakit jantung menjadi salah satu penyebab utama kematian baik di Indonesia maupun di dunia. Gejala penyakit dan gangguan fungsi jantung sering kali tidak dirasakan atau diketahui oleh penderita karena kelalaian atau kurang memperhatikan kesehatan jantungnya. Menurut Organisasi Kesehatan dunia WHO (*World Health Organization*) pada tahun 2019 melaporkan kematian yang diakibatkan oleh penyakit jantung adalah sekitar 31% dari kematian di seluruh dunia [1]. Oleh karena itu, penelitian terkait prediksi, deteksi, dan pengelolaan penyakit jantung khususnya *heart disease* menjadi sangat penting dalam upaya pencegahan dan penanganannya. Adapun tindakan pencegahan ini dapat dilakukan dengan mengembangkan inovasi teknologi canggih dan beragam metode pendidikan kesehatan [2].

Pendekatan *Machine Learning* (ML) memiliki potensi besar untuk mengatasi masalah-masalah dalam *domain biomedis* komputasi, seperti prediksi penyakit jantung [3]. Dalam konteks ini, penggunaan teknologi dan metode analisis data, khususnya dalam bidang *Machine Learning*, telah menunjukkan potensi yang besar dalam mendukung pengidentifikasian dini dan prediksi penyakit jantung.

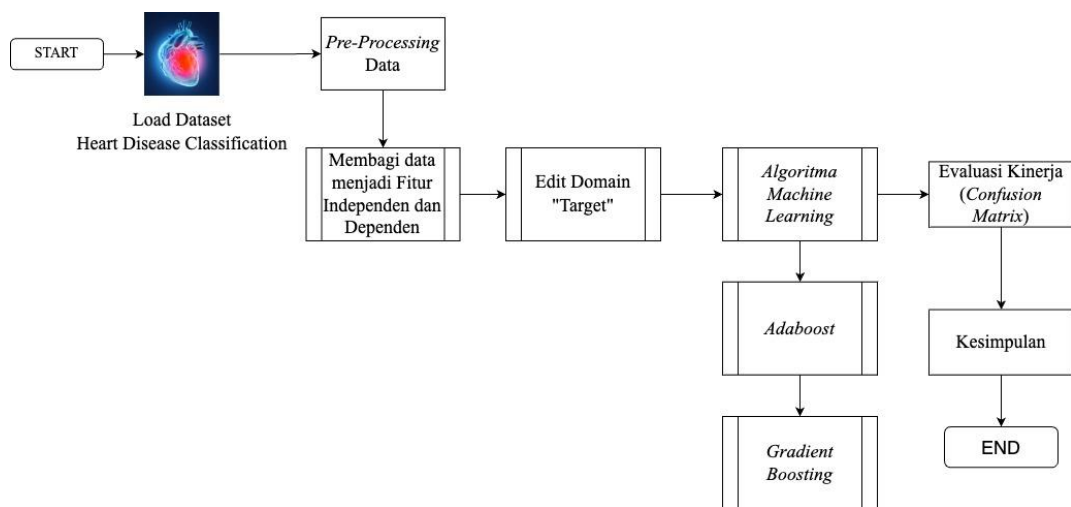
Penelitian terkait tentang deteksi penyakit jantung menggunakan *machine learning* sudah pernah dilakukan. Penelitian Apriyanto dkk (2019) tentang Prediksi Penyakit Jantung Menggunakan Metode-Metode *Machine Learning* Berbasis *Ensemble – Weighted Vote*. Mereka berhasil meningkatkan akurasi hingga 85,21% dengan menggunakan metode *Weighted Vote*, melebihi beberapa metode *machine learning* lainnya [3]. Kemudian ada penelitian Silmi dkk (2022) dimana pada penelitian berjudul “*Hybrid Machine Learning Model Untuk Memprediksi Penyakit Jantung Dengan Metode Logistic Regression Dan Random Forest*”. Penelitian ini bertujuan untuk memprediksi penyakit jantung dengan menggabungkan metode *Logistic Regression* Dan *Random Forest* untuk meningkatkan prediksi menjadi 84,48% [4]. Selain itu ada Sabrina dkk (2023) dengan penelitian berjudul “*Klasifikasi Penyakit Jantung Menggunakan Decision Tree dan Random Forest*,” menghasilkan kesimpulan bahwa klasifikasi penyakit jantung dengan *random forest* lebih baik dibandingkan dengan metode *decision tree*. Pada klasifikasi dengan metode *random forest* menghasilkan nilai akurasi 81.82% [5]. Kaushalya dkk dengan judul penelitian *Two-level Boosting Classifier Ensemble Based on Feature Selection for Heart Disease Prediction*, yang tidak kalah menariknya. Hal tersebut dikarenakan mereka melakukan eliminasi fitur *rekursif* dari 3 buah dataset menggunakan SVM dan kemudian menggunakan 5 algoritma yang digabungkan ke dalam *ensemble model* untuk mencapai kinerja terbaik. Menghasilkan *accuracy* 93.44%, 83.33%, dan 79.75% dalam melakukan prediksi terhadap penyakit jantung. Adapun ke-lima algoritma tersebut adalah *Gradient Boosting, Adaboost, XGBoost, CatBoost, dan LightGBM* [6]. Selain pendeteksian mengenai penyakit jantung, ada

beberapa penelitian lainnya tentang biomedis menggunakan *machine learning* diantaranya penelitian karya Moataz dkk dengan judul *Classification of Chronic Kidney Disease Based on Machine Learning Techniques*, dimana penelitian ini menggunakan 9 algoritma *machine learning* untuk memprediksi potensi infeksi *Chronic Kidney Disease* (CKD). Dimana algoritma *adaboost* memberikan nilai *accuracy* tertinggi yakni 99.17% dari 8 algoritma lainnya [7].

Dari penelataran tersebut, model *algoritma Boosting* dapat dikatakan terbukti mampu melakukan klasifikasi dengan baik dan akurat. Namun masih dapat dibuat sebuah penelitian untuk melakukan perbandingan metode *boosting* mana yang lebih unggul. Maka pada penelitian ini akan dibuat sebuah perbandingan antara 2 metode *boosting* yakni *Adaboost* dan *Gradient Boosting* pada sebuah dataset *Heart Disease Classification by Kaggle*.

2. Metode Penelitian

Pada metode penelitian ini terdapat sebuah Gambar 1 untuk memperlihatkan bagaimana rencana alur penelitian yang akan dilakukan.



Gambar 1. Alur Penelitian

Secara garis besar, alur penelitian yang terlihat pada Gambar 1 terdiri atas beberapa proses diantaranya dataset *Heart Disease Classification* akan diinputkan pada aplikasi Orange 3 versi 3.34.0. Kemudian dataset ini masuk ke proses *preprocessing* diantaranya adalah membaginya menjadi dua fitur yakni fitur *independen* dan *dependen* untuk menentukan *class* atau target. Setelah itu proses dilanjutkan dengan mengubah domain pada target agar penamaan hasil nantinya akan lebih mudah. Proses edit domain ini merubah yang awalnya target diinisialisasikan dengan 0 dan 1 kemudian diubah menjadi 0=no disease dan 1= disease (tidak menderita penyakit jantung dan menderita penyakit jantung).

2.1 Gradient Boosting

Gradient Boosting termasuk pada *supervised learning* berbasis *decision tree* yang dapat digunakan untuk klasifikasi. Algoritma ini bekerja secara *sekuensial* untuk menambahkan prediktor sebelumnya yang dimana prediktor tersebut kurang cocok dengan prediksi ke ensemble, memastikan adanya kesalahan yang dibuat sebelum diperbaiki (1).

$$-\log L1 = - \sum_{i=1}^N y_i \log(odds) + \log(1 + e^{\log(odds)}) \dots\dots\dots(1)$$

Penggambaran sederhana mengenai konsep *ensemble* ialah keputusan-keputusan dari berbagai mesin pembelajaran yang digabungkan, kemudian untuk kelas yang menerima suara terbanyak atau mayoritas adalah kelas yang menghasilkan pohon klasifikasi awal dan terus menyesuaikan pohon baru melalui minimalisasi fungsi kerugian [6],[8].

2.2 Adaboost

Merupakan algoritma yang ide dasarnya adalah untuk melakukan pemilihan dan penggabungan sekelompok pengklasifikasi lemah untuk membentuk klasifikasi yang kuat. Parameter yang dipelajari tersebut akan digunakan sebagai penelitian untuk mendapatkan peningkatan akurasi pengklasifikasian dasar C4.5 melalui iterasi yang tepat [7],[9]. Teknik pembobotan algoritma Adaboost, sebagai berikut: Rumus-rumus yang terlibat dalam algoritma Adaboost adalah sebagai berikut:

1. Inisialisasi bobot sampel:

$$w_i^{(1)} = \frac{1}{N} \dots\dots\dots(2)$$

2. Pembobotan Galat:

$$e_t = \frac{\sum_{i=1}^N w_i^{(t)} \cdot 1(y_i \neq \hat{y}_i^{(t)})}{\sum_{i=1}^N w_i^{(t)}} \dots\dots\dots(3)$$

3. Pembobotan Model:

$$\alpha_t = \frac{1}{2} \ln \left(\frac{1-e_t}{e_t} \right) \dots\dots\dots(4)$$

4. Pembaruan Bobot Sampel:

$$w_i^{(t+1)} = \frac{w_i^{(t)} \cdot \exp \left(-\alpha_t \cdot y_i \cdot \hat{y}_i^{(t)} \right)}{Z_t} \dots\dots\dots(5)$$

5. Prediksi Ensemble Model:

$$H(x) = \text{sign} \left(\sum_{t=1}^T \alpha_t \cdot h_t(x) \right) \dots\dots\dots(6)$$

2.3 Confusion Matrix

Confusion Matrix adalah tabel yang digunakan untuk melihat akurasi serta seberapa baik suatu algoritma yang dihasilkan dari klasifikasi yang telah dibuat untuk mengklasifikasi dan melakukan prediksi atribut dari data testing. Metode ini dikembangkan sebagai penilaian algoritma *machine learning* yang diterapkan dalam menyelesaikan masalah klasifikasi. Dalam *confusion matrix* terdapat *False Negative* (FN), *False Positive* (FP), *True Negative* (TN), dan *True Positive* (TP). Berikut merupakan tabel dari *confusion matrix* [10].

Tabel 1. Asumsi *Confusion Matrix*

Kelas Prediksi	Kelas Aktual	
	Positive	Negative
Positive	TP	FP
Negative	FN	TN

TP adalah kondisi dimana baik prediksi maupun nilai aktualnya benar; kemudian FN adalah kasus dimana nilai prediksi tidak benar tetapi nilai aktualnya benar; sedangkan FP merupakan kasus dimana nilai pada prediksi benar namun pada nilai aktualnya tidak benar. Dalam mengevaluasi kinerja model, ada berbagai macam peforma diantaranya akurasi, *recall*, dan presisi. Dimana ketiga nilai tersebut diperoleh dengan menggunakan persamaan pada Tabel 2.2 di bawah ini.

Tabel 2. Rumus Evaluasi Peforma Metode

Performance Metrics	Rumus	
Akurasi	$\frac{TP+TN}{TP+TN+FP+FN}$	x100
Recall	$\frac{TP}{TP + FN}$	x100
Presisi	$\frac{TP}{TP+FP}$	x100

Akurasi merupakan rasio prediksi benar dengan keseluruhan data. Kemudian *recall* adalah rasio prediksi benar positif dibandingkan dengan keseluruhan data aktual positif. Sedangkan presisi merupakan rasio prediksi benar positif dibandingkan dengan seluruh data yang diprediksi positif.

3. Hasil dan Pembahasan

Pada bagian hasil dan pembahasan, akan diinformasikan terkait proses-proses yang telah dilakukan untuk membandingkan kedua algoritma boosting secara terperinci. Adapun proses yang dilakukan, diantaranya:

3.1 Data Pre-Processing

Tahap awal data *pre-processing* dapat dilakukan dengan menginputkan dataset sekunder dengan judul *Heart Disease Classification by Kaggle* (<https://www.kaggle.com/datasets/sumaiyatasmeeem/heart-disease-classification-dataset>) pada aplikasi Orange 3 versi 3.34.0. Pada tahap awal ini dataset dibuka terlebih dahulu untuk melihat jumlah dari fitur maupun data, dimana jumlah keseluruhan data ialah 303 dan jumlah fitur 14 yakni *age, sex, cp, trestbps, chol, fbs, restecg, thalach, exang, oldpeak, slope, ca, thal*, dan *target*. Dari proses pengecekan tidak ditemukan adanya *missing value* sehingga proses yang dilakukan hanyalah pembagian antara data independen (*variabel prediktor* atau *variabel input*) dan dependen (*variabel target* atau *variabel respons*) setelah itu dilakukan juga proses *Edit Domain* pada class atau target agar lebih mudah terbaca maka inisial angka dari 0 dan 1 diubah menjadi 0 = *no disease* dan 1 = *disease*.

3.2 Evaluasi

Pada tahap evaluasi dataset yang telah diinputkan memasuki proses klasifikasi *boosting methods* menggunakan *algoritma adaboost* dan *gradient boosting*. Pada prosesnya sendiri, dataset yang digunakan diproses pada kedua klasifikasi ini dengan merubah *number of estimator* dari 10 sampai dengan 100 (kelipatan 10) dan menggunakan 2 *learning rate* yakni 0.1 dan 0.01. Secara garis besar hasil evaluasi dapat terlihat pada tabel 3 dan 4.

Tabel 3 Hasil Evaluasi 1

Algoritma	Number of Estimator									
	10	20	30	40	50	60	70	80	90	100
Gradient Boosting	87.7	89.3	89.5	89.2	89.0	88.7	88.8	88.6	88.3	88.1
Adaboost	73.4	73.4	73.4	73.4	73.4	73.4	73.4	73.4	73.4	73.4

Pada evaluasi pertama menggunakan *learning rate* 0.1 dapat terlihat pada tabel 3.1 bahwa akurasi terbaik didapatkan oleh *algoritma gradient boosting* pada *number of estimator* 30 yakni 89.5%.

Tabel 4 Hasil Evaluasi 2

Algoritma	Number of Estimator									
	10	20	30	40	50	60	70	80	90	100
Gradient Boosting	82.9	84.2	85.2	85.4	86.2	86.8	87.2	87.6	87.8	88.1
Adaboost	73.4	73.4	73.4	73.4	73.4	73.4	73.4	73.4	73.4	73.4

Pada evaluasi kedua menggunakan *learning rate* 0.01 dapat terlihat pada tabel 3.1 bahwa akurasi terbaik didapatkan oleh *algoritma gradient boosting* pada *number of estimator* 100 yakni 88.1%.

3.3 Perhitungan Confusion Matrix

Kinerja model dievaluasi berdasarkan efisiensi dan kesalahan yang terjadi menggunakan *matrix* evaluasi seperti *accuracy, precision, recall, f1-score*, dan *specificity*. *Matrix* evaluasi inipun dapat dihitung dengan menggunakan *confusion matrix*. *Confusion Matrix* merangkum hasil dari prediksi pada masalah klasifikasi dari dataset *Heart Disease Classification*, seperti yang ditunjukkan pada gambar 2 dan 3 untuk *confusion matrix* dengan pengaturan *number of estimator* 30 dan *learning rate* yang digunakan 0.1. Kemudian pada gambar 4 dan 5 untuk *confusion matrix* dengan pengaturan *number of estimator* 100 dan *learning rate* yang digunakan 0.01.

		Predicted		Σ
		No Disease	Disease	
Actual	No Disease	98	40	138
	Disease	40	125	165
Σ		138	165	303

Gambar 2 *Confusion Matrix* pada hasil prediksi *Algoritma Adaboost* Evaluasi 1

		Predicted		Σ
		No Disease	Disease	
Actual	No Disease	101	37	138
	Disease	21	144	165
Σ		122	181	303

Gambar 3 *Confusion Matrix* pada hasil prediksi *Algoritma Gradient Boosting* Evaluasi 1

Kedua hasil perhitungan *confusion matrix* pada *algoritma adaboost* dan *gradient boosting* menghasilkan masing-masing 4 nilai yang diisikan pada tabel berwarna ungu dan merah. Warna ungu menyatakan bahwa secara aktual dan prediksi jumlah penderita dan tidak menderita penyakit jantung nilainya sesuai antara aktual dan prediksi *machine learning*. Sedangkan warna merah adanya ketidaksesuaian antara keadaan aktual dengan prediksi yang dihasilkan. Hasil evaluasi kedua menggunakan perhitungan *Confusion Matrix* dapat terlihat pada gambar 3.3 dan 3.4.

		Predicted		Σ
		No Disease	Disease	
Actual	No Disease	98	40	138
	Disease	40	125	165
Σ		138	165	303

Gambar 4 *Confusion Matrix* pada hasil prediksi *Algoritma Adaboost* Evaluasi 2

		Predicted		Σ
		No Disease	Disease	
Actual	No Disease	97	41	138
	Disease	17	148	165
Σ		114	189	303

Gambar 5 *Confusion Matrix* pada hasil prediksi *Algoritma Adaboost* Evaluasi 2

4. Kesimpulan

Pada konteks perbandingan evaluasi klasifikasi boosting methods antara *adaboost* dan *gradient boosting* pada dataset *Heart Disease Classification* menunjukkan performa terbaik didapatkan oleh *algoritma gradient boosting* pada number of estimator 30 dan learning rate yang digunakan adalah 0.1 menghasilkan nilai accuracy sebesar 89.5%. Secara garis besar, temuan ini menegaskan pentingnya sebuah pengembangan lebih lanjut lagi pada setiap aspek penelitian khususnya jenis *algoritma* yang digunakan, serta modifikasi *learning rate* yang digunakan. Namun, hasil penelitian ini juga memiliki keterbatasan, terutama dalam hal penggunaan model *machine learning*, teknik optimasi yang digunakan, serta jumlah dataset serta fitur yang hendaknya bisa lebih banyak. Oleh karena itu, penelitian selanjutnya diharapkan dapat melakukan eksplorasi lebih lanjut untuk meningkatkan validitas dan generalisasi hasil dari penelitian.

Daftar Pustaka

- [1] World Health Organization. "Cardiovascular Diseases (CVD) Fact Sheet." WHO. [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)). 11 Juni 2021. (Diakses pada 23 Pebruari 2024).
- [2] Saputro Indro, H. T. dan J. T. M. (2018). Peningkatan Upaya Promotif Preventif dalam Efektivitas Pembiayaan Penyakit Kardiovaskuler: Systematic Review. *Jurnal Ilmiah Kesehatan*, 17. <https://journals.stikim.ac.id/index.php/jikes/article/view/144/134>
- [3] Apriyanto A, Azminuddin I.S, Budy S, Sunarto, Prediksi Penyakit Jantung Menggunakan Metode-Metode *Machine Learning* Berbasis *Ensemble – Weighted Vote*, 2019
- [4] Silmi Ath Thahirah Al Azhima, D. D. , N. F. A. H. , I. K. , M. A. Q. , N. S. S. (2022). Hybrid Machine Learning Model untuk Memprediksi Penyakit Jantung dengan Metode Logistic Regression dan Random Forest. *Jurnal Teknologi Terpadu*, 8, 40–46. <https://journal.nurulfikri.ac.id/index.php/jtt>
- [5] Adnin Kamila, S., Sri Sulistijowati, R., Susanto, I., & Matematika dan Ilmu Pengetahuan Alam, F. (2023). Klasifikasi Penyakit Jantung Menggunakan Decision Tree dan Random Forest. In *Universitas Nusantara PGRI Kediri. Kediri (Vol. 2)*.
- [6] Dissanayake, K., & Johar, M. G. M. (2023). Two-level boosting classifiers ensemble based on feature selection for heart disease prediction. *Indonesian Journal of Electrical Engineering and Computer Science*, 32(1), 381–391. <https://doi.org/10.11591/ijeecs.v32.i1.pp381-391>
- [7] Sherbiny, M. M. el, Abdelhalim, E., El-Din Mostafa, H., & El-Seddik, M. M. (2023). Classification of chronic kidney disease based on machine learning techniques. *Indonesian Journal of Electrical Engineering and Computer Science*, 32(2), 945–955. <https://doi.org/10.11591/ijeecs.v32.i2.pp945-955>
- [8] Elsa Suryana, S., & Warsito, B. (n.d.). Penerapan Gradient Boosting dengan Hyperopt untuk Memprediksi Keberhasilan Telemarketing Bank. 10, 617–623. <https://ejournal3.undip.ac.id/index.php/gaussian/>
- [9] Ilmiah, J., & Akuntansi, K. (2019). Optimasi Klasifikasi Status Gizi Balita Berdasarkan Indeks Antropometri Menggunakan Algoritma C4.5 Adaboost Classification. 12(2), 45–51. <http://jurnal.stekom.ac.id/index.php/kompak/page45>
- [10] Junifer Pangaribuan, J., & Tanjung, H. (2021). Mendeteksi Penyakit Jantung Menggunakan Machine Learning dengan Algoritma Logistic Regression.
- [11] Amelia, Y. (2023). Perbandingan Metode Machine Learning untuk Mendeteksi Penyakit Jantung. In *Idealis: Indonesia Journal Information System (Vol. 6, Issue 2)*. <http://jom.fti.budiluhur.ac.id/index.php/IDEALIS/index>