

# PERBANDINGAN ALGORITMA *LOGISTIC REGRESSION* DAN *ADAPTIVE BOOSTING (ADABOOST)* DALAM KLASIFIKASI PENYAKIT GAGAL JANTUNG

Anita Desiani<sup>1\*</sup>, Ali Amran<sup>b,2</sup>, Yuli Andriani<sup>c,3</sup>, Tri Wahyuni<sup>d,4</sup>, Fatur Rizki<sup>e,5</sup>

<sup>a,b,c,d,e</sup> Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Sriwijaya, Jl. Raya Palembang - Prabumulih No.KM. 32, Indralaya Indah, Kec. Indralaya, Kabupaten Ogan Ilir, Sumatera Selatan 30862

<sup>1</sup>[anita\\_desiani@unsri.ac.id](mailto:anita_desiani@unsri.ac.id)\*; <sup>2</sup>[ali\\_amran@mipa.unsri.ac.id](mailto:ali_amran@mipa.unsri.ac.id); <sup>3</sup>[yuliandriani@unsri.ac.id](mailto:yuliandriani@unsri.ac.id); <sup>4</sup>[triiwahyuni1609@gmail.com](mailto:triiwahyuni1609@gmail.com); <sup>5</sup>[faturrizky666@gmail.com](mailto:faturrizky666@gmail.com)

\* corresponding author

## ARTICLE INFO

## ABSTRACT

### Keywords

Heart Failure, Logistic Regression, Adaboost

The heart is a vital organ in the human body, responsible for pumping blood throughout the body via the circulatory system. The heart is responsible for the delivery of oxygen and nutrients to tissues, as well as the removal of carbon dioxide and other waste products. Any disruption to the heart's functioning has the potential to be fatal to human survival. One such disruption is heart failure disease, also known as congestive heart failure (CHF). It is of the utmost importance to detect heart failure at an early stage. The early detection of heart failure disease can be achieved through the utilisation of machine learning, which can mitigate the low probability of this disease. This research employs a machine learning system based on artificial intelligence, utilising logistic regression and adaptive boosting (adaboost) algorithms. The research findings indicate that the classification of heart failure can be accurately determined using a range of parameters. The highest accuracy results, derived from this study, are 90% accuracy, 84% precision, 88% recall, and 88% F1-score. These results are exclusively attributable to the adaboost algorithm. In comparison to the logistic regression algorithm, the resulting accuracy is still below that of the adaboost algorithm, with the results being 86% accuracy, 76% precision, 79% recall, and 88% F1-score. It can therefore be concluded that the adaboost algorithm is more effective than the logistic regression algorithm in classifying heart failure disease. This is particularly the case when the selected data set exhibits an unbalanced number of labels.

## 1 Pendahuluan

Jantung sebagai organ vital makhluk hidup pada manusia yang memiliki peran untuk memompa darah ke seluruh tubuh melalui sistem peredaran darah[1]. Jantung mengantarkan oksigen dan nutrisi ke jaringan serta membuang karbon dioksida dan limbah lainnya[2]. Gangguan sedikit saja pada jantung dapat berakibat fatal terhadap kelangsungan hidup manusia, salah satu gangguan yang dapat terjadi pada jantung adalah penyakit gagal jantung yang juga dikenal sebagai *congestive heart failure* (CHF)[2]. Gagal jantung merupakan penyakit yang disebabkan adanya gangguan pada jantung atau penyakit kardiovaskular yang tidak menular dan dapat menyebabkan kematian[3]. Penyakit gagal jantung yang perlu dilakukan penanganan lebih cepat sehingga dibutuhkan deteksi dini pada penyakit jantung[4].

Deteksi untuk penyakit gagal jantung dapat dilakukan dengan menggunakan machine learning

<https://doi.org/10.47111/JTI>

Available online at <https://e-journal.upr.ac.id/index.php/JTI>

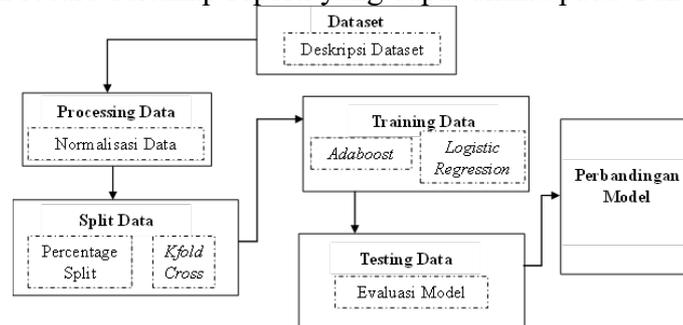
untuk mengatasi terjadi peluang kecil pada penyakit gagal jantung[5]. *Machine learning* merupakan metode yang dalam bidang kecerdasan buatan yang digunakan untuk meniru peran dari manusia yang bertujuan untuk memecahkan suatu masalah[6]. Salah satu algoritma yang sering digunakan dalam *machine learning* adalah logistik regresi atau *regression logistic*[7]. Logistik regresi adalah metode dalam *machine learning* yang sering dipakai dalam perlebalan biner yang digunakan untuk menganalisis kumpulan data di mana satu atau lebih variabel independen menentukan hasil yang bersifat biner 0 dan 1[8]. Metode regresi logistik banyak digunakan di berbagai bidang seperti kedokteran, ilmu sosial, dan pembelajaran mesin untuk tugas-tugas seperti klasifikasi biner, di mana variabel hasil memiliki dua nilai yang mungkin[8]. Metode regresi logistik memiliki kelebihan adadalam bentuk deviasi dan metode ini sangat banyak digunakan karena mudah dipahami, akan tetapi metode regresi logistik ini juga memiliki kekurangan hanya bisa digunakan dalam bentuk biner 0 dan 1 kemudian jika digunakan pada dataset yang banyak akan mengalami terjadinya underfitting pada data sehingga terjadi ketidakseimbangan akurasi[9]. Sebelumnya sudah ada penelitian yang menggunakan regresi logistik seperti jurnal jefri junifer pangaribuan, henry tanjaya dan kenichi mengenai mendekteksi penyakit jantung machine learning dengan menggunakan algoritma *logistic regression*[8]. Sayangnya hasil dari penelitian tersebut memiliki akurasi yang kurang baik, tepatnya pada nilai 83,47%, dikarena terdapat beberapa kelemahan pada metode regresi logistik. Kelemahan dari algoritma logistik regresi yaitu memiliki kinerja yang buruk dengan data set yang tidak seimbang, sering kali membuat prediksi menjadi bias ke arah kelas mayoritas yang sangat berpengaruh terhadap hasil prediksi[8]. Ada penelitian lain yang terdapat pada jurnal yang berjudul “Analisis Perbandingan Klasifikasi Penyakit Jantung Menggunakan Algoritma Naïve Bayes dan Algoritma *Logistic Regression*” oleh Annisa Aulia Lestari, Lucy Chania Agatha, dalam jurnal menggunakan data pada penyakit pada jantung dengan menggunakan metode *logistic regression*, akan tetapi metode yang digunakan hanya memiliki nilai akurasi hanya 84%[10]. Perbandingan pada penelitian lain yaitu pada jurnal yang berjudul “Analisis Perbandingan Kinerja Algoritma Klasifikasi dalam Mendeteksi Penyakit Jantung” oleh Abram Setyo Prabo dan Felix Kurniadi yang nyatakan pada penelitian tersebut bahwa hasil yang menggunakan metode *logistic regression* yaitu memiliki akurasi hanya sebesar 80%[11]. Terdapat banyak kekurangan pada penelitian sebelumnya yang menggunakan metode *logistic regression*, maka untuk mengatasi kekurangan tersebut dilakukan perbandingan dengan menambahkan algoritma lain yaitu *adaptive boosting*.

*Adaptive Boosting* pada umumnya dikenal sebagai metode *adaboost* merupakan teknik pembelajaran ensemble yang digunakan secara luas yang dirancang untuk meningkatkan kinerja pengklasifikasian yang lemah dengan menggabungkannya ke dalam pengklasifikasian yang kuat[12]. *Adaboost* sangat efektif untuk masalah klasifikasi biner, tetapi juga dapat diperluas ke masalah multi-kelas. *Adaboost* dapat mengatasi masalah yang dimiliki oleh metode logistik regresi saat mengolah data yang tidak seimbang sehingga bisa mengoptimalkan hasil[13]. Dalam penelitian pada jurnal sistem dan teknologi informasi yang berjudul “Optimasi Prediksi Kematian pada Gagal Jantung: Analisis Perbandingan Algoritma Pembelajaran *Ensemble* dan Teknik Penyeimbangan Data pada Dataset” oleh Andhar Siraj Munir dan Retno Waluyo menggunakan metode *adaboost* yang mengukur berdasarkan parameter[14]. Kemudian penelitian pada jurnal gaussian yang berjudul “Penerapan Tuling Hyperparameter Randomsearchcv Pada *Adaptive Boosting* Untuk Prediksi Kelangsungan Hidup Pasien Gagal Jantung” oleh Tita Aulia, Tatik Widiharih dan Rukun Santoso yang menggunakan algoritma *adaboost* pada penyakit jantung yang mengukur berdasarkan proposisi data yang digunakan[15].

Pada penelitian ini menggunakan perbandingan antara algoritma *adaboost* sebagai perbandingan akurasi untuk lebih baik. Proses yang dilakukan dengan *percentage split* dan *k-fold*. Pada pengujian *k-fold* dengan menggunakan nilai *k* sebesar 10 dengan uji sebanyak 10 kali. Penelitian ini dilakukan dengan menentukan berdasarkan akurasi, presisi dan recall pada dataset gagal jantung dan diharapkan dapat terjadi penurunan korban penyakit gagal jantung dengan cara deteksi dini, serta penelitian ini dapat dijadikan referensi untuk penelitian-penelitian lainnya.

### Metode Penelitian

Penelitian ini terdiri dari 5 langkah. Langkah-langkah dalam penelitian ini tersusun dari runtutan tahapan yang dikerjakan secara bertahap seperti yang dapat dilihat pada Gambar 1.



**Gambar 1.** Langkah Metode Penelitian

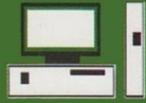
Langkah pertama dimulai dengan pengumpulan data, kemudian dilakukan *processing* data, dilanjutkan dengan *split data*, hasil proses *split data* kemudian dapat digunakan pada proses *training* dan *testing* data, dilanjutkan dengan melatih model yang akan dipakai (evaluasi model), lalu pada langkah terakhir dilakukan perbandingan model.

#### 2.1 Deskripsi Data

Penelitian ini menggunakan dataset yang diambil pada website kaggle, dataset yang diambil mengenai *heart failure clinical* data atau data gagal jantung dengan format data yaitu cvs excel[16]. Dataset yang digunakan berisikan 299 baris data dengan 13 atribut. Atribut yang terdapat pada data tersebut tersusun dari 12 variabel independen dan 1 variabel dependen. Variabel independen pada data tersebut terdiri dari data yang berbentuk kategorik dan numerik, atribut-atribut tersebut merepresentasikan kondisi pada pasien yang dianggap berpengaruh dalam diagnosa penyakit gagal jantung. Variable dependen pada data tersebut berupa atribut target yaitu *death\_event*, variable ini merepresentasikan kondisi dari pasien berupa keterangan hidup atau meninggal dunia. Rincian atribut pada penelitian ini dapat dilihat pada Tabel 1.

Tabel 1. Informasi dari Atribut Dataset Gagal Jantung

Artibut	Keterangan	Skala Pengukuran
<i>Age</i>	Usia/ Umur	[40-95]
<i>Anemia</i>	Anemia	0=No, 1= Yes
<i>Creatine Phosphokinase</i>	Kreatin fosforkinase	[23-7861]
<i>Diabetes</i>	Diabetes	0=No, 1=Yes
<i>Ejection Fraction</i>	Fraksi pengeluaran	[14-80]
<i>High Blood Pressure</i>	Tekanan Darah Tinggi	0=No, 1=Yes
<i>Platelets</i>	Trombosit	[25100-48000]
<i>Serum Creatinine</i>	Kreatinin Serum	[0,5-9,4]
<i>Serum Sodium</i>	Natrinum Serum	[113-148]



Sex	Jenis Kelamin	0=Famale, 1=Male
Smoking	Merokok	0=No, 1=Yes
Time	Waktu	[4-285]
Death event	Kejadian Kematian	0=No, 1=Yes

## 2.2 Processing Data

### 2.2.1 Percentage Split

*Percentage Split* atau juga disebut persentase split adalah proses pemisahan data menjadi 2 bagian atau lebih dimana bagian pertama menjadi data uji (*training set*) dan bagian data lainnya digunakan untuk melatih model (*testing set*). Dengan menggunakan *percentage split*, hasil klasifikasi yang didapatkan mewakili besaran data yang diambil. Pada penelitian ini data akan dibagi menjadi dua bagian dengan 70% dari data dijadikan data training dan 30% dari data menjadi data *testing*.

### 2.2 Evaluasi Model

Tahapan dalam menghitung jumlah pengujian yang akan diprediksi dengan benar dan tidak benar saat mengevaluasi model mengevaluasi model klasifikasi. Tabel *confusion matrix* yang bertujuan untuk mrrmbandingkan hasil klasifikasi seperti *positive true* (TP), *false positive* (FP), *true negative* (TN) dan *false negative* (FN). Pada Tabel 2 akan digambarkan *confusion matrix* untuk dua kelas.

Tabel 2. *Confusion Matrix*

Kelas		Nilai Aktual	
		Positif	Negatif
Nilai Prediksi	Positif	TP	FN
	Negatif	FP	TN

Ada beberapa kemungkinan yang diukur dengan menggunakan metode yang digunakan dari hasil *confusion matrix* dengan menggunakan nilai akurasi, presisi, dan *recall*. Nilai akurasi adalah jumlah prediksi benar atau salah yang dibuat oleh model berdasarkan kumpulan data atau disebut sebagai tingkat akurasi. Untuk menghitung nilai akurasi digunakan Persamaan (10). Presisi merupakan rasio prediksi benar positif terhadap keseluruhan hasil yang diprediksi benar positif. Untuk menghitung nilai presisi digunakan Persamaan (11). *Recall* merupakan rasio prediksi benar positif yang dibandingkan dengan keseluruhan data yang benar positif. Persamaan (12) digunakan untuk menghitung nilai *recall*.

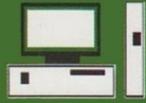
$$Akurasi = \frac{TP + TN}{TP + TN + FN + FP} \tag{10}$$

$$Presisi = \frac{TP}{TP + FP} \tag{11}$$

$$Presisi = \frac{TP}{TP + FP} \tag{12}$$

### 3 Hasil dan Pembahasan

Hasil klasifikasi algoritma logistik regresi pada penyakit gagal jantung diperoleh menggunakan teknik pengujian *K-fold*. Tingkat keberhasilan model yang diperoleh dari diprediksi menggunakan *confusion matrix*, seperti yang ditunjukkan pada Tabel 3.



Tabel 3. *Confusion Matrix* Algoritma *Logistic Regression*

Kelas	YES (Positif Jantung)	Gagal	NO (Negatif Jantung)	Gagal
YES (Positif Jantung)	21		3	
NO (Negatif Jantung)	1		4	

Berdasarkan hasil *confusion matrix* bahwa Setelah mendapatkan hasil dari *confusion matrix* dalam keadaan positif yaitu terdapat 21 prediksi positif gagal jantung dan 3 data prediksi negatif gagal jantung sedangkan dalam keadan negatif terdapat 1 prediksi data yang positif gagal jantung dan 4 prediksi negatif gagal jantung. Dengan menggunakan algoritma regresi logistik maka dilakukan untuk mencari nilai presisi, *recall* dan *f1-score* serta akurasi data *training* serta data *testing* yaitu dapat dilihat pada Tabel 4.

Tabel 4. Nilai Presisi, *Recall*, dan *F1-Score* Algoritma Logistik Regresi

Kelas	Presisi (%)	<i>Recall</i> (%)	<i>F1-score</i> (%)
0	95	88	91
1	57	80	67

Berdasarkan Tabel 4, nilai *recall* algoritma logistik regresi pada kelas 1 menghasilkan angka yang cukup kecil. Dalam konteks pada dataset yang digunakan dalam penelitian ini terdapat lebih banyak kelas nol daripada nilai satu, hal ini menunjukkan lemahnya performa algoritma logistik regresi pada data yang tidak seimbang dengan akurasi pada data *testing* dengan data *training*, maka dilanjutkan dengan metode *adaboost* untuk melakukan hasil akurasi yang lebih baik. Dalam perhitungan didapatkan akurasi data *training* yaitu sebesar 84,81% dengan akurasi data *testing* sebesar 86,21%.

### 3.2 Algoritma AdaBoost

Hasil klasifikasi *adaboost* pada penyakit gagal jantung juga diperoleh menggunakan teknik pengujian *K-fold*, dimana tingkat keberhasilan model yang diperoleh akan digunakan sebagai prediksi dengan *confusion matrix* yang dapat dilihat pada Tabel 5.

Tabel 5. *Confusion Matrix* Algoritma *AdaBoost*

Kelas	YES (Positif Jantung)	Gagal	NO (Negatif Jantung)	Gagal
YES (Positif Jantung)	23		1	
NO (Negatif Jantung)	1		4	

Berdasarkan Tabel 5, pada teknik pengujian *percentage split* terdapat 23 data positif yang diprediksi dengan benar dan 1 data positif yang diprediksi negatif. Pada kondisi negatif, 1 data diprediksi dengan benar dan 4 data negatif yang seharusnya diprediksi negatif tetapi diprediksi negatif. Dari *confusion matrix* menggunakan *percentage split* tersebut, dapat diketahui nilai presisi, *recall*, dan akurasi dari masing-masing kondisi yang disajikan pada Tabel 6.

Tabel 6. Nilai Presisi, *Recall* dan Akurasi Algoritma *AdaBoost*

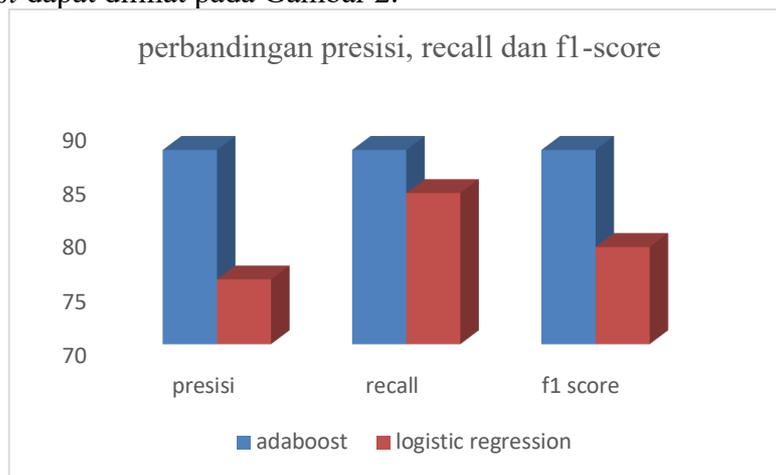
Kelas	Presisi (%)	<i>Recall</i> (%)	<i>F1-score</i> (%)
0	96	96	96

1	80	80	80
---	----	----	----

Berdasarkan Tabel 6, nilai presisi, recall, dan akurasi menggunakan metode adaboost menghasilkan nilai yang sudah sangat baik walaupun data yang digunakan tidak seimbang. Pada algoritma *adaboost* memberikan dampak kelebihan terhadap algoritma sebelumnya yaitu algoritma logistik regresi. Didapatkan hasil akurasi pada data *training* sebesar 100% dengan akurasi data *testing* sebesar 93,1%.

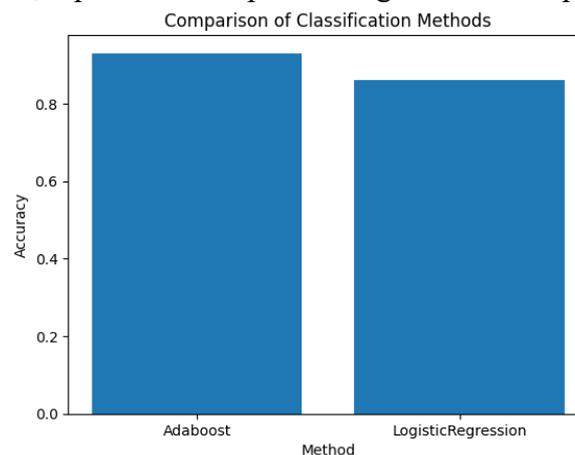
### 3.3 Perbandingan Hasil Kedua Algoritma

Pada pembahasan sebelumnya, hasil dari kedua algoritma yang digunakan menunjukkan hasil yang cukup signifikan. Perbandingan nilai rata-rata presisi, *recall*, dan *F1-score* dari metode logistik regresi dan *AdaBoost* dapat dilihat pada Gambar 2.



Gambar 2. Perbandingan Nilai Rata-Rata Presisi, *Recall* dan *F1-Score*

Dapat dilihat pada gambar metode *adaboost* menunjukkan hasil yang lebih baik daripada metode regresi logistik. Rata-rata pada presisi dengan menggunakan *adaboost* sebesar 88% sedangkan menggunakan metode regresi logistik adalah sebesar 76%. Nilai *recall* yang didapat dengan menggunakan *adaboost* sebesar 88% sedangkan dengan menggunakan logistik regresi yaitu sebesar 84% dan jika nilai *f1-score* yaitu sebesar 88% dengan menggunakan metode *adaboost* sedangkan menggunakan metode logistik regresi yaitu sebesar 79%. Telah dilakukan Perbandingan nilai rata-rata presisi, *recall*, dan *F1-score*. Setelah itu dilakukan perbandingan lanjutan secara langsung antara akurasi kedua metode tersebut, diperoleh hasil perbandingan akurasi dapat dilihat pada Gambar 3.



Gambar 3. Perbandingan Hasil Akurasi Kedua Algoritma

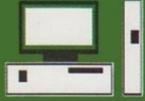
Berdasarkan Gambar 3, algoritma *adaboost* menunjukkan hasil akurasi keseluruhan yang lebih baik yaitu 93% terhadap prediksi data set gagal jantung dibandingkan dengan algoritma gosistik regresi yang hanya menunjukkan akurasi keseluruhan sebesar 86%.

#### 4 Kesimpulan dan Saran

Berdasarkan metode *adaboost* dan regresi logistik, hasil pengujian menggunakan algoritma logistik regresi menunjukkan akurasi terbaik yang diperoleh sebesar 86%. Sementara itu, pada algoritma *adaboost* diperoleh tingkat akurasi yang sama lebih tinggi yaitu diatas 92% yaitu 93%. Algoritma yang dilakukan dengan baik algoritma *adaboost* dapat bekerja lebih baik dibandingkan algoritma regresi logistik. Berdasarkan perbandingan hasil akurasi, serta nilai rata-rata presisi dan *recall*, dapat disimpulkan bahwa algoritma *adaboost* lebih unggul dalam melakukan klasifikasi Penyakit gagal jantung dibandingkan dengan algoritma regresi logistik. Saran untuk penelitian selanjutnya adalah untuk mempertimbangkan karakteristik data dan tujuan analisis sebelum memilih metode. Jika data yang dipilih memiliki jumlah label yang tidak seimbang lebih disarankan untuk menghindari pemilihan algoritma regresi logistik. Pada kasus seperti itu algoritma *adaboost* dapat menjadi pilihan yang lebih baik.

#### Daftar Pustaka

- [1] U. Basuki, “Merunut Konstitusionalisme Hak Atas Pelayanan Kesehatan Sebagai Hak Asasi Manusia,” *J. Huk. Caraka Justitia*, vol. 1, no. 1, pp. 21–41, 2020, [Online]. Available: <https://ejournal.up45.ac.id/index.php/JHCJ/article/view/699>
- [2] M. Hutasuhut, T. Tugiono, and A. H. Nasyuha, “Analisis Aritmia (Gangguan Irama Jantung) Menerapkan Metode Certainty Factor,” *J. Media Inform. Budidarma*, vol. 5, no. 4, p. 1386, 2021, doi: 10.30865/mib.v5i4.3289.
- [3] E. Tasia, R. Zaid, I. Zariar, S. Kenia, and P. Loka, “Klasifikasi Penyakit Gagal Jantung Menggunakan Supervised Learning,” *Sentimas*, pp. 1–7, 2023, [Online]. Available: <https://journal.irpi.or.id/index.php/sentimas/article/view/535>
- [4] Eva Miranda Marwali, Yoel Purnama, and Poppy Surwianti Roebiono, “Modalitas Deteksi Dini Penyakit Jantung Bawaan di Pelayanan Kesehatan Primer,” *J. Indones. Med. Assoc.*, vol. 71, no. 2, pp. 100–109, 2021, doi: 10.47830/jinma-vol.71.2-2021-241.
- [5] J. J. Pangaribuan, H. Tanjung, and K. Kenichi, “Mendeteksi Penyakit Jantung Menggunakan Machine Learning Dengan Algoritma Logistic Regression,” *J. Inf. Syst. Dev.*, vol. 06, no. 02, pp. 1–10, 2021.
- [6] W. Lestari and S. Sumarlinda, “Studi Komparatif Model Klasifikasi Kerentanan Penyakit Jantung Menggunakan Algoritma Machine Learning,” *SATIN - Sains dan Teknol. Inf.*, vol. 9, no. 1, pp. 107–115, 2023, doi: 10.33372/stn.v9i1.918.
- [7] Q. R. Cahyani *et al.*, “Prediksi Risiko Penyakit Diabetes menggunakan Algoritma Regresi Logistik Diabetes Risk Prediction using Logistic Regression Algorithm Article Info ABSTRAK,” *JOMLAI J. Mach. Learn. Artif. Intell.*, vol. 1, no. 2, pp. 2828–9099, 2022, doi: 10.55123/jomlai.v1i2.598.
- [8] L. Anisa and N. A. K. Rifai, “Analisis Regresi Logistik Biner dengan Metode Penalized Maximum Likelihood pada Penyakit Covid-19 di RSUD Pringsewu,” *J. Ris. Stat.*, vol. 2, no. 2, pp. 129–136, 2022, doi: 10.29313/jrs.v2i2.1425.
- [9] D. Y. Wulandari, Ismaraidha, and O. Amelia, “Analisis Model Regresi Logistik Biner Dalam



- Menentukan Faktor-Faktor yang Mempengaruhi Masa Studi Mahasiswa,” *J. Math. Educ. Sci.*, vol. 8, no. 1, pp. 127–134, 2022.
- [10] A. A. Lestari, L. C. Agatha, A. Desiani, F. Matematika, and P. Alam, “Analisis Perbandingan Klasifikasi Penyakit Jantung Menggunakan Algoritma Naïve Bayes dan Algoritma Logistic Regression,” vol. 5, no. 2, pp. 82–90.
- [11] A. S. Prabowo and F. I. Kurniadi, “Analisis Perbandingan Kinerja Algoritma Klasifikasi dalam Mendeteksi Penyakit Jantung,” *J. SISKOM-KB (Sistem Komput. dan Kecerdasan Buatan)*, vol. 7, no. 1, pp. 56–61, 2023, doi: 10.47970/siskom-kb.v7i1.468.
- [12] A. M. Majid and M. N. Dwi Miharja, “Penerapan Metode Discretization Dan Adaboost Untuk Meningkatkan Akurasi Algoritma Klasifikasi Dalam Memprediksi Penyakit Jantung,” *Indones. J. Bus. Intell.*, vol. 5, no. 2, p. 70, 2022, doi: 10.21927/ijubi.v5i2.2689.
- [13] Y. Crismayella, N. Satyahadewi, and H. Perdana, “Algoritma Adaboost pada Metode Decision Tree untuk Klasifikasi Kelulusan Mahasiswa,” *Jambura J. Math.*, vol. 5, no. 2, pp. 278–288, 2023, doi: 10.34312/jjom.v5i2.18790.
- [14] A. Siraj, R. Waluyo, J. Letjend, P. Soemarto, K. P. Utara, and K. Banyumas, “Optimasi Prediksi Kematian pada Gagal Jantung : Analisis Perbandingan Algoritma Pembelajaran Ensemble dan Teknik Penyeimbangan Data pada Dataset Optimizing Heart Failure Mortality Prediction : Comparative Analysis of Ensemble Learning Algorithms and Data ,” vol. 12, no. 2, pp. 365–372, 2024, doi: 10.26418/justin.v12i2.75158.
- [15] T. A. E. Putri, T. Widiharih, and R. Santoso, “Penerapan Tuning Hyperparameter Randomsearchcv Pada Adaptive Boosting Untuk Prediksi Kelangsungan Hidup Pasien Gagal Jantung,” *J. Gaussian*, vol. 11, no. 3, pp. 397–406, 2023, doi: 10.14710/j.gauss.11.3.397-406.
- [16] Larxel, “Heart Failure Prediction.” [Online]. Available: <https://www.kaggle.com/andrewmvd/heart-failure-clinical-data%0A%0A>
- [17] Wiwid Wahyudi, “Implementasi Data Mining Untuk Klasifikasi Penyakit Liver Dengan C4.5 Adaboost,” *J. Ilm. Tek. Inform. dan Komun.*, vol. 1, no. 3, pp. 71–76, 2021, doi: 10.55606/juitik.v1i3.120.