

Meta-Algorithms untuk Meningkatkan Kinerja Klasifikasi dalam Keberhasilan Telemarketing Perbankan

Meta-Algorithms for Improving Classification Performance in the Success of Banking Telemarketing

Muhammad Eka Purbaya¹, Anggit Ferdita Nugraha², Sapriani Gustina³, M. Khusaini Azis⁴

¹Program Studi Sistem Informasi, Institut Teknologi Telkom Purwokerto

²Program Studi Teknik Komputer, Universitas AMIKOM Yogyakarta

^{3,4}Program Studi Teknologi Informasi, Universitas Proklamasi 45 Yogyakarta

E-mail: ¹m.eka @ittelkom-pwt.ac.id, ² anggitferdita@amikom.ac.id, ³sa.gustina@up45.ac.id, ⁴mkazis4215@gmail.com

Abstrak

Banyak bank dan perusahaan asuransi berinteraksi dengan pelanggan mereka menggunakan jasa telemarketing agar dapat lebih meningkatkan pendapatan bank dan mencapai target. Kompetisi yang ketat di industri perbankan membuat tenaga penjualan bank mengejar target terutama menjelang akhir tahun. Pelaku telemarketing atau biasa disebut telemarketer pada perbankan bertugas menghubungi nasabah potensial yang dilakukan secara berkala melalui sambungan telepon. Namun tidak semua nasabah mendapatkan respons yang positif, sering kali telemarketing menemui antipati dari nasabah sebelum proses komunikasi dilakukan. Pendekatan yang diusulkan untuk menemukan nasabah potensial adalah dengan cara klasifikasi data nasabah menggunakan pembelajaran mesin (*machine learning*). Penggunaan algoritme pembelajaran yang dilakukan secara tunggal memungkinkan untuk dikembangkan menggunakan *meta-algorithms* sehingga akan memaksimalkan kinerja klasifikasi dalam memprediksi target pelanggan atau nasabah yang sesuai dengan kebutuhan perusahaan agar tujuan pemasaran tercapai. Berdasarkan hasil penelitian yang diperoleh, tindakan pra-pemrosesan dan penggunaan *meta-algorithms* seperti *bagging* memberikan kontribusi yang baik untuk proses pembelajaran model *decision tree* pada data telemarketing dengan hasil akurasi terbaik 98,7%.

Kata kunci: telemarketing, meta-algoritms, decision tree, bagging

Abstract

Many banks and insurance companies interact with their customers using telemarketing services in order to further increase bank revenue and achieve targets. Tight competition in the banking industry makes the bank's sales force pursue the target especially towards the end of the year. The perpetrators of telemarketing or commonly called telemarketers in banking are tasked with contacting potential customers which are done regularly through telephone lines. However, not all customers get positive responses, often telemarketing meets antipathy from customers before the communication process is carried out. The proposed approach for finding potential customers is by way of classifying customer data using machine learning. The use of a single learning algorithm allows to be developed using meta-algorithms so that it will maximize the performance of classifications in predicting target customers or customers in accordance with company needs so that marketing objectives are achieved. Based on the research results obtained, pre-processing actions and the use of meta-algorithms such as bagging make a good contribution to the learning process of the decision tree model on telemarketing data with the best accuracy results of 98.7%.

Keywords: telemarketing, meta-algoritms, decision tree, bagging

1. PENDAHULUAN

Kemajuan sebuah teknologi saat ini berkembang pesat pada berbagai aspek kehidupan masyarakat yang salah satunya adalah kegiatan pemasaran. Untuk lebih banyak mendapatkan pelanggan potensial, kegiatan pemasaran atau marketing dituntut untuk lebih spesifik menjangkau target tertentu sehingga banyak perusahaan yang menghindari promosi massal karena dinilai kurang efektif [1]. Salah satu strategi pemasaran yang digunakan oleh banyak bank dan perusahaan asuransi adalah telemarketing [2]. Telemarketing dapat diartikan sebagai aktivitas memasarkan produk atau jasa melalui saluran komunikasi jarak jauh. Strategi ini sering digunakan oleh perusahaan karena memiliki beberapa kelebihan [3] yaitu: membangun hubungan timbal balik dengan calon pelanggan sehingga dengan cepat menemukan kebutuhan yang sesuai dan diinginkan oleh calon pelanggan. Umpan balik penjualan yang bisa diukur sehingga atasan mampu menilai berapa jumlah penjualan pada hari tersebut dan bisa menjadi bahan evaluasi bagi perusahaan untuk pengambilan keputusan. Waktu pemasaran yang fleksibel dengan melihat waktu optimal dari calon pelanggan. Mempercepat siklus penjualan merupakan salah satu media yang efektif bila dibandingkan media pemasaran lain seperti e-mail, brosur, flyer dan *billboard*.

Banyak bank dan perusahaan asuransi berinteraksi dengan pelanggan mereka menggunakan jasa telemarketing agar dapat lebih meningkatkan pendapatan bank dan mencapai target [4]. Kompetisi yang ketat di industri perbankan membuat tenaga penjualan bank mengejar target terutama menjelang akhir tahun. Istilah *cross-selling* diterapkan perbankan untuk meningkatkan pemasukan bank dengan cara memantau aktivitas transaksi nasabah atau pelanggan, kemudian akan disarankan untuk mengambil program perbankan yang lainnya. Contohnya terdapat nasabah pengguna kartu kredit dengan predikat baik karena membayar tagihan selalu tepat waktu dan tidak pernah menunggak. Kemungkinan besar pihak bank akan menghubungi nasabah ini untuk menawarkan program lain misalkan deposito jangka panjang. Contoh lainnya adalah nasabah kartu debit yang aktif melakukan setor tunai setiap bulan yang pada waktu tertentu akan dihubungi pihak bank untuk menawarkan pembuatan dan aktivasi kartu kredit.

Pelaku telemarketing atau biasa disebut telemarketer pada perbankan bertugas menghubungi nasabah potensial yang dilakukan secara berkala melalui sambungan telepon. Mereka menawarkan produk atau jasa dan memberikan informasi se jelas mungkin pada nasabah agar tertarik membeli. Namun tidak semua nasabah mendapatkan respons yang positif, sering kali telemarketing menemui antipati dari nasabah sebelum proses komunikasi dilakukan. Hal tersebut dikarenakan perbankan sering menghubungi nasabah yang kurang sesuai dengan target pemasaran. Faktor yang mempengaruhi salah satunya adalah kuantitas data nasabah perbankan yang memerlukan waktu lama untuk proses menemukan nasabah potensial yang sesuai dengan target perusahaan [5].

Pendekatan yang diusulkan untuk menemukan nasabah potensial adalah dengan cara klasifikasi data nasabah menggunakan pembelajaran mesin (*machine learning*). *Machine learning* dikenal oleh peneliti sebagai salah satu cabang dari kecerdasan buatan yang menggunakan metode statistika untuk menjadikan komputer dapat mempelajari pola pada data. Beberapa penelitian yang berhasil mengklasifikasi nasabah potensial menggunakan teknik *machine learning* dengan beberapa model percobaan. Model *machine learning* yang pernah diteliti untuk kasus serupa antara lain menggunakan *logistic regression* (LR), *decision tree* (DT), *support vector machine* (SVM) dan *neural networks* (NN).

Moro dkk [6] memprediksi keberhasilan panggilan telemarketing bank untuk menjual deposito jangka panjang. Hasil yang diperoleh Moro dkk adalah bahwa NN merepresentasikan hasil klasifikasi terbaik dengan pengukuran $AUC = 0,8$ dan $ALIFT = 0,7$. VenkateshYadav dkk [7] menggunakan model *Decision Tree*, *Random Forest*, *NaïveBaye's* dan *Random Tree* dengan hasil bahwa *Random Tree* memiliki performa terbaik dengan nilai *root mean squared error* (RMSE) dengan nilai 0. Elzhan dkk [4] juga membandingkan beberapa model klasifikasi untuk memprediksi telemarketing perbankan dengan hasil *Random Forest* memiliki nilai akurasi terbaik (90,9) daripada model KNN, LR, NN, *NaïveBaye's* dan SVM.

Perlu diketahui bahwa *random forest* menggunakan *decision tree* untuk melakukan proses seleksi sehingga bisa juga disebut *decision tree ensemble* [4]. Penggunaan metode seperti *decision tree* [4], [8], [9] turut menghasilkan prediksi yang cukup akurat dalam menentukan nasabah potensial. Dari beragam metode *machine learning* yang telah digunakan, penggunaan *classifier* secara langsung dalam menentukan potensi target pelanggan dilakukan oleh beberapa peneliti. Padahal diperlukan adanya seleksi fitur dalam proses pembelajaran untuk mengetahui potensi dari fitur-fitur dari *dataset* agar meningkatkan kinerja *machine learning* dalam melakukan klasifikasi. Penggunaan algoritme pembelajaran yang dilakukan secara tunggal memungkinkan untuk dikembangkan menggunakan *meta-algorithms* sehingga akan memaksimalkan kinerja klasifikasi dalam memprediksi target pelanggan atau nasabah yang sesuai dengan kebutuhan perusahaan agar tujuan pemasaran tercapai.

Hal yang membedakan penelitian ini dengan penelitian sebelumnya adalah bahwa pada penelitian [8] tidak dilakukan pra-pemrosesan untuk menguji algoritme *decision tree* yang diusulkan. Padahal *preprocessing* berperan penting untuk meningkatkan ekstraksi fitur lebih optimal. Sedangkan pada penelitian ini akan dibandingkan hasil akurasi dari pelatihan tanpa *preprocessing* dan yang sudah dilakukan *preprocessing*. Selain itu penelitian ini berusaha meningkatkan *decision tree* agar bisa berkompetisi secara seimbang dengan *classifier* lainnya melalui penggunaan *meta-algorithms* yang tidak digunakan pada penelitian klasifikasi pada data bank [2], [4], [8]–[11]. Hal baru yang dapat diambil melalui penelitian ini adalah kalayak dapat mengetahui peran *pre-processing* dan *meta-algorithms* dalam meningkatkan performa metode algoritme klasifikasi. Sedangkan tujuan dari penelitian ini yaitu mengembangkan model *machine learning* berdasarkan pendekatan *meta-algorithms* untuk meningkatkan keberhasilan proses telemarketing di sektor perbankan. Manfaat yang diperoleh dari penelitian ini adalah hasil penelitian dapat digunakan untuk pengembangan beragam sistem dengan tujuan mendukung pengambilan keputusan dalam mengklasifikasi nasabah atau pelanggan potensial sehingga tujuan telemarketing tercapai. Penelitian ini juga bisa menjadi referensi bagi peneliti yang lain dalam pengembangan model *machine learning*.

2. METODE PENELITIAN

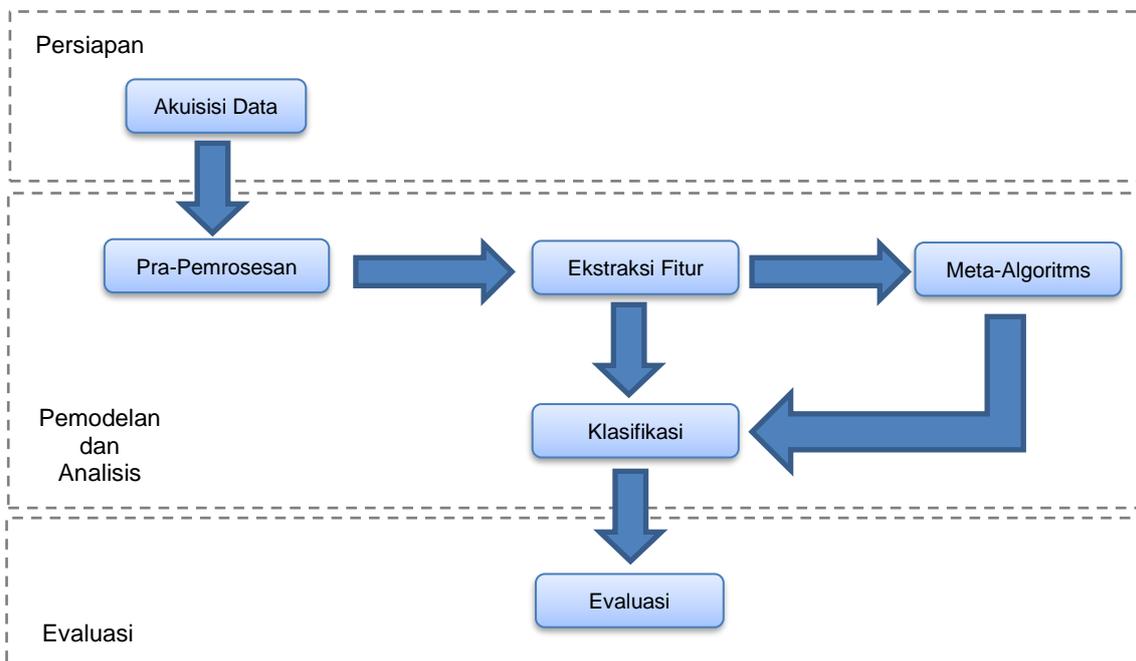
2.1 Metode Pengembangan Sistem

Proses penelitian dilakukan dengan menggunakan tahapan umum seperti yang ditampilkan pada Gambar 1 yang diawali tahap persiapan, pemodelan dan analisis lalu diakhiri dengan tahap evaluasi. Tahap persiapan ini adalah akuisisi data atau mengenai cara mendapatkan dataset. Dataset utama yang digunakan untuk mengembangkan model *machine learning* ini diunduh melalui situs *UCI Machine Learning Repository*. Dataset tersebut berasal dari Lembaga Perbankan di Portugis dari tahun 2008-2013 yang memiliki 16 atribut dengan label keluaran klasifikasi apakah nasabah tersebut mengambil program deposito jangka panjang atau tidak. Informasi lebih detail mengenai *dataset* ini akan dijelaskan secara rinci pada sub bab *Dataset*.

Tahap yang kedua adalah Pemodelan dan Analisis yang menjadi fokus utama dan menjadi ciri khas dari penelitian ini. Setelah *dataset* diperoleh, dilakukan pra-pemrosesan karena tidak semua data memiliki kondisi ideal untuk bisa digunakan sebagai analisis atau pemodelan lebih lanjut. Contoh kondisi yang membuat data dikatakan tidak ideal adalah adanya berbagai masalah yang mengganggu hasil seperti diantaranya adalah *missing value*, *redundant data*, *outliers* maupun bisa jadi format dari data tersebut tidak *compatible*. Pada kasus ini, pra-pemrosesan yang dilakukan adalah menghilangkan masalah *missing values* karena terdapat nilai pada kolom berisi kata “*unknown*”. Pada *WEKA tools machine learning*, kata “*unknown*” tidak dapat diproses untuk klasifikasi sehingga perlu diubah menjadi “*NULL*” pada kolom yang tidak dapat diketahui nilainya. Selain itu diperlukan proses *discretization* untuk mengubah bentuk nomina ke bentuk numerik seperti yang ada pada fitur *age*, *balance* dan *duration*. Hasil dari proses *discretization* ini

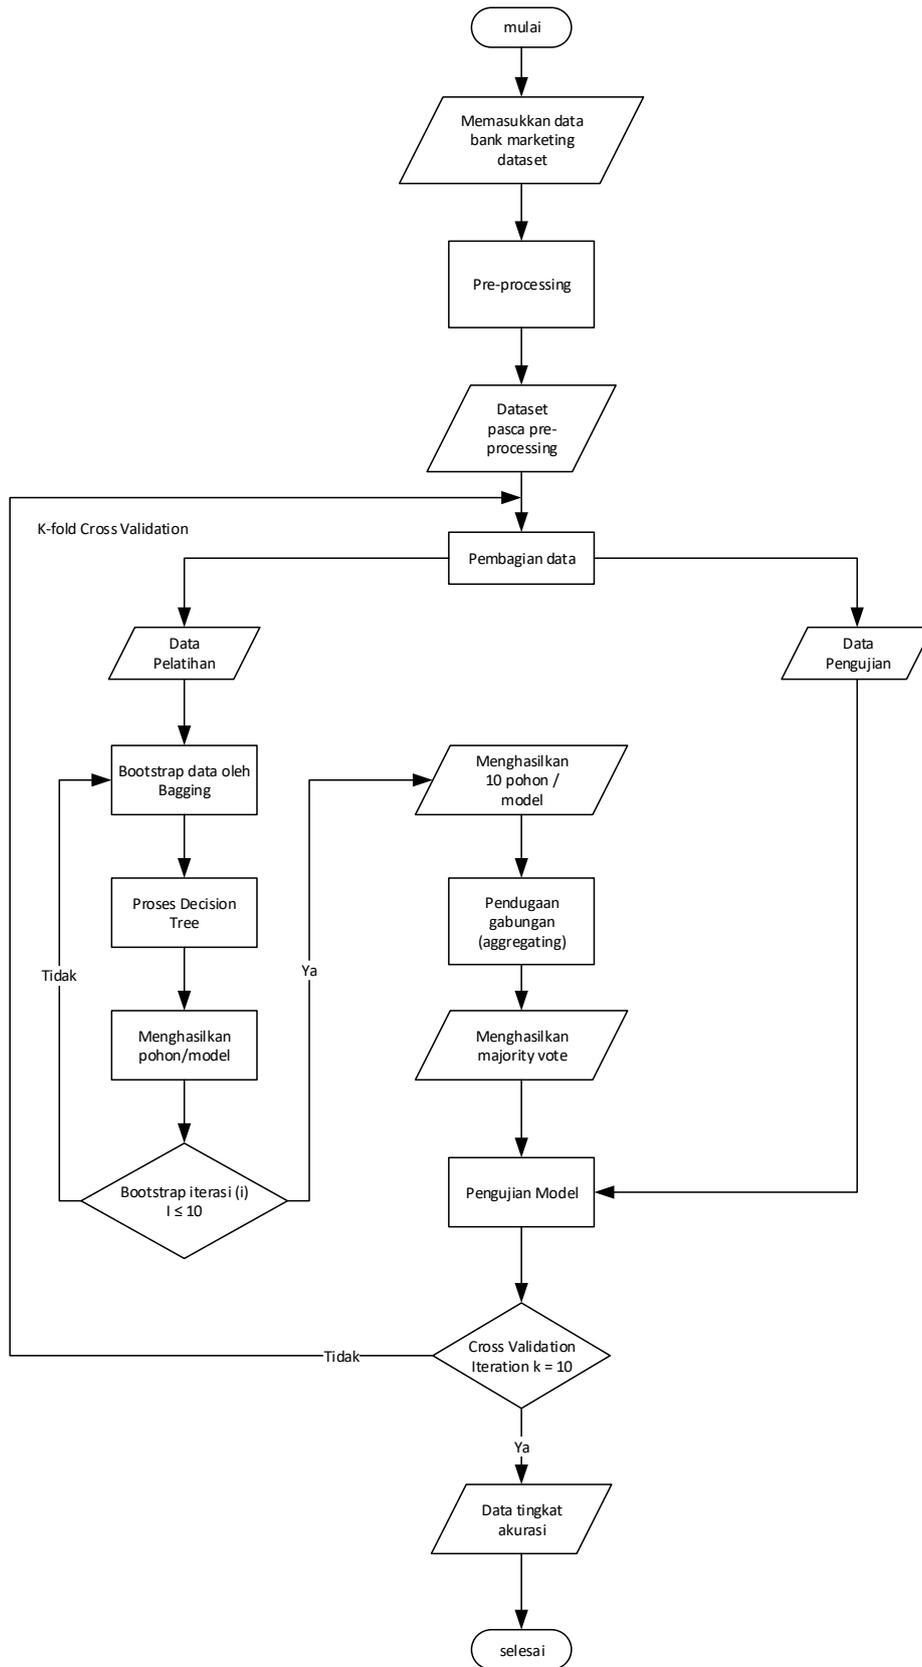
adalah dilakukan klusterisasi menggunakan *k-means* dengan nilai $k = 2$ untuk menemukan pendekatan nilai data yang hilang sehingga bisa memiliki karakteristik serupa.

Data yang telah normal selanjutnya masuk ke tahap ekstraksi fitur. Proses ini dapat dikatakan sebagai tahapan mengekstrak ciri atau informasi dari objek agar bisa dikenali dari objek lainnya. Tahap selanjutnya adalah masuk ke proses model pembelajaran untuk menentukan kinerja klasifikasi yang dihasilkan. Model pembelajaran yang diterapkan untuk dilatih ada empat skenario. Skenario pertama adalah *dataset* tidak dilakukan pra-pemrosesan dulu dan langsung dilakukan ekstraksi ciri kemudian dilakukan pembelajaran terhadap model *decision tree*. Skenario kedua adalah penggunaan *meta-algorithms* pada hasil pelatihan data bank marketing menggunakan model *decision tree* tanpa adanya *pre-processing*. Skenario yang ketiga adalah *dataset* dilakukan pra-pemrosesan, lalu dilakukan ekstraksi fitur kemudian dilakukan pembelajaran menggunakan *decision tree*. Sedangkan skenario yang keempat terdapat penggabungan metode model *decision tree* dengan salah satu *meta-algorithms*.



Gambar 1 Alur Pengembangan Sistem

Setelah proses pembelajaran selesai, akan masuk ke tahap validasi menggunakan *10-fold cross validation* sehingga nanti akan diperoleh nilai akurasi. Pada tahap terakhir atau evaluasi, hasil akurasi dari masing-masing skenario yang diusulkan akan dibandingkan sehingga dapat diambil metode yang paling baik untuk digunakan sebagai model klasifikasi nasabah potensial. Untuk memahami skenario keempat maka disajikan flowchart mengenai preprocessing *dataset*, pembelajaran menggunakan *decision tree* yang digabungkan dengan metode *meta-algorithms* yaitu *bagging*, *boosting* dan *stacking*. Untuk ilustrasi penggabungan *decision tree* dengan *bagging* seperti yang disajikan pada Gambar 2.



Gambar 2 Flowchart Penggabungan *Decision Tree* dengan *Bagging*

2.2 Dataset

Dataset yang digunakan untuk penelitian ini adalah *Bank Marketing Dataset* yang berasal dari Lembaga Perbankan di Portugis dari tahun 2008-2013. Dataset dapat diunduh melalui situs *UCI Machine Learning*. Secara umum *Bank Marketing Dataset* memiliki 16 atribut dengan label keluaran klasifikasi apakah nasabah tersebut mengambil program deposito jangka panjang atau tidak. Pada situs tersebut disediakan 2 jenis dokumen unduhan. Yang pertama adalah “bank.zip” yang memiliki 16 fitur dan yang kedua adalah “bank-additional.zip” yang memiliki 21 fitur. Perbedaan dokumen tersebut adalah “bank-additional.zip” memiliki 5 fitur tambahan mengenai fitur sosial dan ekonomi pada nasabah dengan tipe data numerik yang tidak digunakan untuk pemodelan klasifikasi pada penelitian ini. Informasi mengenai fitur yang ada pada dokumen “bank.zip” ditampilkan pada Tabel 1.

Tabel 1 Fitur-fitur *Bank Marketing Dataset*

No	Nama Atribut	Tipe Data	Deskripsi	Nilai
1	age	numerik	Fitur yang berisi data usia dari nasabah.	19 s/d 87
2	job	kategorik	Fitur yang berisi data informasi pekerjaan nasabah.	'admin.', 'blue-collar', 'entrepreneur', 'housemaid', 'management', 'retired', 'self-employed', 'services', 'student', 'technician', 'unemployed' dan 'unknown'
3	marital	kategorik	Fitur yang mencatat status perkawinan	'divorced', 'married', 'single', 'unknown'
4	education	kategorik	Fitur yang mencatat informasi pendidikan dari nasabah	primary, secondary, tertiary, dan unknown
5	default	kategorik	Fitur yang mencatat informasi apakah nasabah memiliki kepemilikan kredit atau tidak	yes/no
6	balance	numerik	Fitur yang mencatat data jumlah saldo yang dimiliki oleh nasabah	-3.313 s/d 71.188
7	housing	kategorik	Fitur yang mencatat informasi apakah pelanggan memiliki kredit perumahan	yes/no
8	loan	kategorik	Fitur yang mencatat informasi apakah pelanggan memiliki pinjaman pribadi	yes/no
9	contact	kategorik	Fitur yang berisi data jenis komunikasi dengan nasabah	cellular, telephone, unknown
10	day	numerik	Berisi informasi tanggal ketika nasabah dihubungi	1 s/d 31
11	month	kategorik	Berisi informasi nama bulan ketika nasabah dihubungi (Jan-Dec)	Jan., Feb., Mar., ..., Nov., Dec.
12	duration	numerik	Fitur yang mencatat durasi panggilan Ketika nasabah dihubungi	4 s/d 3.025
13	campaign	numerik	Fitur yang mencatat jumlah nasabah pernah dihubungi berapa kali dalam menawarkan produk melalui telemarketing	1 s/d 50
14	pdays	numerik	Fitur yang mencatat jeda waktu untuk promosi berdasarkan pada hari terakhir dihubungi	-1 s/d 871

15	previous	numerik	Fitur yang berisi intensitas kontak dengan nasabah sebelum penawaran dibuat	0 s/d 25
16	poutcome	kategorik	Fitur yang berisi tanggapan dari penawaran telemarketing sebelumnya	failure, success, other dan unknown

2.3 Decision Tree

Decision tree merupakan sebuah algoritme yang menggunakan struktur pohon sebagai model prediksi yang umumnya digunakan untuk pengambilan keputusan. Sesuai dengan struktur pohon, setiap pohon memiliki cabang yang mewakili atribut yang harus dipenuhi untuk menuju ke cabang berikutnya sampai berakhir di daun. Dalam mengolah data, decision tree akan menentukan atribut dari akar keputusan dengan menggunakan perhitungan gainratio yang dapat dilihat pada rumus 1. Perhitungan tersebut menunjukkan bahwa gain mengacu pada seberapa banyak informasi yang diperoleh dengan mengetahui nilai atribut, sedangkan split information akan dilakukan untuk atribut yang memiliki lebih dari dua variasi. Aturan yang digunakan pada model decision tree ini ditetapkan menggunakan konjungsi 'IF'

$$Gainratio (S, A) = \frac{Gain (S,A)}{Split Information (S,A)} \quad (1)$$

Selain sebagai model klasifikasi dan prediksi yang umum digunakan, kelebihan dari decision tree adalah model ini cocok digunakan untuk pemodelan data numerik dan data kategori karena menghasilkan kinerja yang baik. Beberapa penelitian yang telah berhasil dilakukan oleh peneliti untuk memecahkan masalah dalam domain telemarketing dijabarkan pada Tabel 2.

Tabel 2 Penelitian Decision Tree Sebelumnya

No	Penulis	Metode	Deskripsi
1	Sergio Moro dkk., 2014 [6]	<ul style="list-style-type: none"> Logistic Regression Decision Tree Support Vector Machine Neural Network 	Penelitian ini memiliki fokus dalam memprediksi keberhasilan panggilan telemarketing bank menjual deposito jangka panjang. Dengan membandingkan 4 model untuk klasifikasi, didapatkan hasil bahwa Neural Network merupakan model terbaik dengan nilai AUC = 0,8 dan ALIFT = 0,7.
2	Shamala Palaniappan dkk., 2017 [12]	<ul style="list-style-type: none"> Naïve Bayes Decision Tree Random Forest 	Penelitian ini memiliki fokus dalam prediksi pelanggan untuk menerima penjualan atau penawaran berdasarkan karakteristik pribadi. Algoritma yang dipilih dalam pendekatan klasifikasi yang diusulkan menghasilkan decision tree sebagai model dengan akurasi tertinggi yaitu 90,68 %.
3	Grzonka Daniel dkk, 2016 [11]	<ul style="list-style-type: none"> Decision Trees Bagging Boosting Random Forests 	Penelitian ini memiliki fokus dalam menyelesaikan permasalahan klasifikasi nasabah bank dalam mengambil keputusan membuka deposito. Untuk menyelesaikan masalah, peneliti melakukan pendekatan dengan metode ensemble untuk decision tree yaitu bagging dan boosting. Hasil yang diperoleh dari perbandingan metode ini dengan menggunakan pengukuran confusion matrix yang menyatakan bahwa random forest memberikan performa nilai klasifikasi error terendah yaitu 0,106. Namun decision tree menghasilkan persentase terbesar dari klasifikasi true positif.
4	J. Asare-Frempong & M. Jayabalan, 2017 [8]	<ul style="list-style-type: none"> Multilayer Perceptron Neural Network (MLPNN) Decision Tree Logistic Regression Random Forest 	Penelitian ini memiliki fokus dalam membangun model prediksi apakah nasabah potensial untuk membuka deposito atau tidak. Dengan membandingkan 4 model untuk melatih data, hasil pengukuran nilai akurasi yang terbaik ditunjukkan oleh performa dari random forest dengan nilai 86,8%.
5	Rahman dkk, 2017 [13]	<ul style="list-style-type: none"> Feature Selection Technique Metalearning Model Technique 	Penelitian ini memiliki fokus dalam membangun dan meningkatkan model prediksi melalui seleksi fitur dalam meningkatkan kinerja akademik. Penelitian ini membuktikan bahwa penggunaan seleksi fitur dan model meta-algorithm dapat meningkatkan kinerja klasifikasi pada siswa data prestasi.

2.4 Meta-Algorithms

Meta-algorithms merupakan algoritme yang menggunakan atau menggabungkan algoritme lain dengan tujuan untuk memperbaiki algoritme yang performanya ingin ditingkatkan. Sub-algoritme yang digunakan biasanya sebagai peubah dan parameter yang dapat diganti. Contoh *meta-algorithms* yang populer adalah *boosting*, *bagging*, *stacking*, *simulated annealing*, *AdaBoost*, dan *random-restart hill climbing*. *Meta-algorithms* pada dasarnya lebih dikenal di kalangan peneliti dengan istilah metode atau teknik *ensemble* dikarenakan terdapat penggabungan metode untuk meningkatkan performa sebuah algoritme. *Meta-algorithms* atau metode *ensemble* yang digunakan pada penelitian ini adalah *bagging*, *boosting* dan *stacking* sebagai bahan uji untuk membandingkan dengan 2 skenario pengujian lainnya. Pemilihan *bagging*, *boosting* dan *stacking* ini didasari rekomendasi dari penelitian [14] dalam meningkatkan performa model prediksi.

2.4.1 Bagging

Bagging merupakan akronim dari *Bootstrap Aggregating* yang pertama kali dipublikasikan oleh [15] untuk meningkatkan kinerja *machine learning* terutama dalam hal klasifikasi dan regresi. *Bagging* melakukan proses secara dua tahap. Tahap pertama adalah *bootstrap* yang bekerja berdasarkan konsep pengambilan sampel di seluruh populasi data sebanyak N kali kembali untuk membuat kumpulan data pelatihan. Hasil yang diperoleh berdasarkan susunan data *training* kemudian diproses pada tahap kedua, yaitu agregasi atau menentukan suara terbanyak untuk menentukan nilai prediksi yang dihasilkan. Sampel *bootstrap* diperoleh dengan melakukan *resampling* dengan penggantian dari *dataset* asli sehingga menghasilkan jumlah elemen yang sama dari *dataset* asli.

Sampel *bootstrap* baru akan bertindak sebagai set data independen lain yang diambil dari distribusi yang sebenarnya. Kemudian, *weak learner* dimasukan untuk masing-masing sampel sehingga terkumpul dan mendapatkan rata-rata nilai keluaran berupa model *ensemble* dengan varian yang lebih sedikit dari komponen-komponennya. Diasumsikan kita memiliki sampel *bootstrap* yang dilambangkan dengan L dan ukuran yang dilambangkan dengan B . Untuk setiap $n = 1$ s/d L sampel dari *bootstrap* akan masuk ke persamaan 2 seperti berikut:

$$\{z_1^1, z_2^1, \dots, z_B^1\}, \{z_1^2, z_2^2, \dots, z_B^2\}, \dots, \{z_1^L, z_2^L, \dots, z_B^L\} \quad (2)$$

Ukuran sampel untuk setiap *bootstrap* memiliki jumlah yang sama seperti data pelatihan yang digunakan sebelum proses *bootstrap* dilakukan. Setiap *bootstrap* yang telah terbentuk kemudian akan dilatih menggunakan model pembelajaran untuk mengetahui nilai dari *weak-learner* (w).

$$w_1, w_2, \dots, w_L(\cdot) \quad (3)$$

Pada persamaan 3, nilai-nilai *weak-learner* yang diketahui kemudian diolah menggunakan model agregasi untuk mendapatkan model yang kuat (S) yang menggunakan persamaan nilai statistik seperti persamaan 4 berikut :

$$S_L = \arg \max [(l | w_L)] \quad (4)$$

Untuk masalah klasifikasi kelas yang dikeluarkan oleh masing-masing model dapat dilihat sebagai *voting* dan kelas yang menerima mayoritas suara dikembalikan oleh model *ensemble*. Probabilitas setiap kelas yang dikembalikan oleh semua model tentunya dipertimbangkan sehingga menjaga kelas dengan probabilitas rata-rata tertinggi. Rata-rata atau *voting* dapat menjadi sederhana atau tertimbang jika bobot yang relevan dapat digunakan.

2.4.2 Boosting

Boosting merupakan bentuk *meta-algorithms* yang dikembangkan untuk meningkatkan prediksi model masing-masing algoritma pembelajaran. Istilah *boosting* mengacu pada koleksi algoritma yang menggunakan pendekatan iteratif untuk mengkonversi *weak learner* menjadi *strong learner*. Proses pelatihan *weak learner* dilakukan secara berurutan untuk mendapatkan tingkat kesalahan klasifikasi yang lebih kecil. *Adaptive Boosting* atau sering dikenal dengan istilah *AdaBoost* merupakan salah satu model *boosting* yang paling banyak digunakan untuk tugas klasifikasi kelas biner. Berdasarkan penelitian [16], persamaan *AdaBoost* disajikan sebagai berikut:

$$F(x) = \text{sign}(\sum_{m=1}^M \alpha_m f_m(x)) \quad (5)$$

Keterangan:

1. $f_m(x)$ merupakan nilai dari *weak learner*
2. α_m merupakan bobot yang sesuai untuk setiap kombinasi dari M *weak learner*

2.4.3 Stacking

Stacking merupakan *meta-algorithm* yang memiliki pendekatan dalam mengelola *weak learner* didasarkan pada kombinasi dari beberapa model pembelajaran [17], [18]. Model *stacking* dapat dilakukan secara bertahap. Pada susunan pertama model pembelajaran dilakukan menggunakan data latih, berikutnya proses pelatihan dilakukan dengan menggunakan hasil dari model yang diperoleh pada tahap sebelumnya. Model *stacking* yang digunakan pada penelitian ini menggunakan kombinasi dari *decision tree* dengan *bagging* dan *boosting*.

2.5 Evaluasi Kinerja Model

Evaluasi diperlukan untuk meninjau hasil penggunaan model pada empat skenario yang diusulkan dalam penelitian ini. Metode evaluasi kinerja model yang akan digunakan penelitian ini adalah menggunakan *confusion matrix*. *Confusion matrix* berisi informasi yang membandingkan hasil prediksi berdasarkan model dengan hasil aktual yang menjadi nilai kebenaran/*ground truth*. Tabel 3 merupakan tabel *confusion matrix* yang digunakan untuk membantu menilai akurasi dari model menggunakan empat kategori berikut:

- True Positive (TP) : Menunjukkan jumlah data yang diklasifikasikan positif oleh sistem terhadap data aktual yang juga positif.
- False Positive (FP) : Menunjukkan jumlah data yang diklasifikasikan positif oleh sistem tetapi memiliki nilai negatif pada data aktual.
- False Negative (FN) : Menunjukkan jumlah data yang diklasifikasikan negatif oleh sistem terhadap aktual data yang positif
- True Negative (TN) : Menunjukkan jumlah data yang diklasifikasikan negatif terhadap data aktual yang juga negatif

Tabel 3 *Confusion Matrix*

Actual Classification	Prediction Classification	
	Positive	Negative
Positive	True Positive (TP)	False Negative (FN)
Negative	False Positive (FP)	True negative (TN)

Dari hasil empat kategori dalam *confusion matrix* (TP, FP, FN dan TN), pengukuran kinerja klasifikasi dapat dihitung berdasarkan akurasi, presisi, *recall*, dan metrik *F1-Measure*. Namun, penelitian ini hanya digunakan metrik untuk mengukur nilai akurasi untuk menggambarkan seberapa akurat model yang dihasilkan dalam mengklasifikasikan nasabah potensial yang tepat. Untuk menilai akurasi diberikan perhitungan (6), bahwa akurasi didapat dari proporsi total yang diklasifikasikan dengan benar dibanding dengan semua hasil klasifikasi oleh sistem.

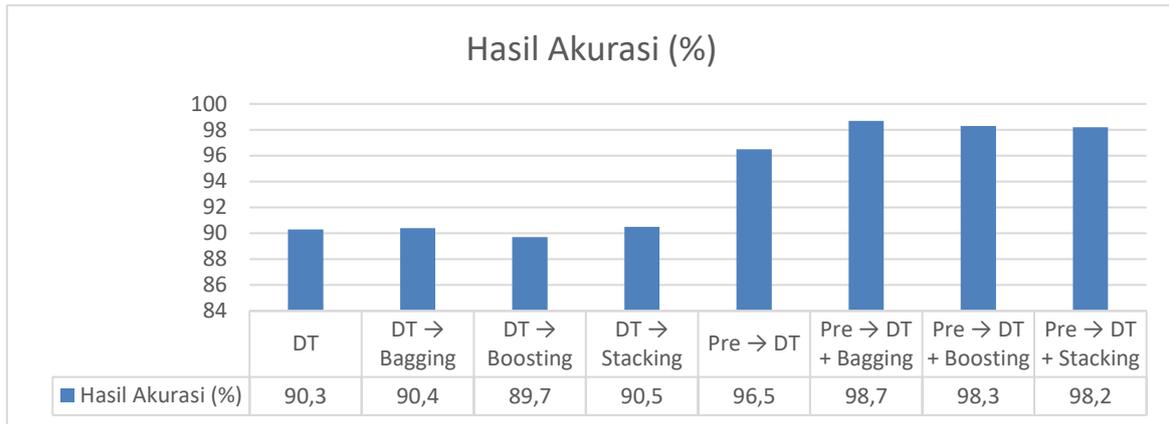
$$Akurasi = \frac{TP}{TP+TN+FP+FN} \quad (6)$$

3. HASIL DAN PEMBAHASAN

Dengan menggunakan bantuan perangkat lunak Weka, 3 skenario model yang diusulkan dilatih, divalidasi dan dievaluasi sehingga memberikan nilai hasil akurasi. *K-fold cross validation* digunakan untuk membantu evaluasi kinerja model dalam melakukan prediksi model dan memperkirakan seberapa akurat sebuah model prediktif ketika dijalankan dalam pengujian. Nilai *K* yang digunakan adalah 10, artinya data dipisahkan menjadi dua subset yaitu data pelatihan dan data validasi/pengujian. *Cross validation* akan menggunakan 9 *fold* untuk subset pelatihan dan 1 *fold* untuk subset pengujian. *Cross validation* juga digunakan untuk memilih model yang sesuai dengan membandingkan *mean squared error* dari *cross validation* (MSECV). Algoritme terbaik dipilih jika memiliki nilai MSECV terendah dibandingkan yang lain.

Nilai akurasi menjadi tolak ukur untuk membandingkan hasil kinerja klasifikasi masing-masing metode. Pada Gambar 3 ditampilkan bagan hasil akurasi dari empat skenario. Arti dari DT adalah akronim dari *decision tree*, artinya pada skenario ini, dataset langsung di proses menggunakan *classifier decision tree* seperti pada mayoritas penelitian lainnya. Proses pada skenario pertama ini sering dikatakan sebagai *single process classification*. Pada skenario pertama ini menghasilkan nilai akurasi sebesar 90,3 %. Selanjutnya pada skenario ke-2 merupakan skenario yang mengaplikasikan *meta-algorithms* dengan *classifier decision tree*, namun pada skenario ini dataset langsung diproses tanpa adanya *preprocessing*. Pada skenario ke-2 akan terdiri dari tiga bagian, yaitu bagian pertama adalah DT + Bagging artinya skenario model yang mengaplikasikan *meta-algorithms* berupa *bagging* dengan *classifier decision tree* yang menghasilkan nilai akurasi sebesar 90,4 %. Bagian ke-2 skenario ke-2 yaitu DT + Boost, artinya skenario model yang mengaplikasikan *meta-algorithms* berupa *boosting* dengan *classifier decision tree* yang menghasilkan nilai akurasi sebesar 89,7 %. Pada bagian ke-3 skenario ke-2 adalah DT + Stacking, artinya skenario model yang menambahkan *meta-algorithms* berupa *stacking* antara *bagging* dengan *boosting* untuk *classifier decision tree* yang menghasilkan nilai akurasi sebesar 90,5%. Ketiga proses dalam skenario ke-2 masuk dalam skenario pertama karena *meta-algorithms* diimplementasikan secara langsung untuk melihat adanya perubahan kinerja klasifikasi, namun dari hasil yang diperoleh, terdapat peningkatan pada DT+Bagging dan DT+Stacking serta penurunan nilai akurasi pada DT+Boost namun dengan jumlah yang sangat kecil.

Selanjutnya pada skenario yang ke-3 adalah dengan memanfaatkan *preprocessing* data yang menggunakan mekanisme *discretize and clusterize*. Dengan adanya *preprocessing* (Pre+DT) kinerja klasifikasi menunjukkan adanya peningkatan nilai hingga 96,5% jika dibandingkan dengan pemrosesan tunggal yang hanya menghasilkan kinerja klasifikasi sebesar 90,13 %. Dengan adanya peningkatan hasil tersebut, penggunaan *meta-algorithms* juga diuji coba pada skenario selanjutnya yaitu skenario ke-4 yang terdiri dari tiga bagian dengan mengimplementasi masing-masing *meta-algorithms*. Penggunaan *bagging* (Pre+ DT +Bagging) mendekati angka akurasi sebesar 98,7%. Sedangkan penggunaan *boosting* (Pre+ DT +Boosting) menunjukkan nilai akurasi yang semakin meningkat hingga 98.3 %. dan *stacking* (Pre+ DT +Stack) yang memanfaatkan *bagging* dan *boosting* menunjukkan kinerja klasifikasi sebesar 98.2%.



Gambar 3 Hasil Akurasi 3 Skenario yang Diusulkan

Skenario pertama menunjukkan bahwa klasifikasi tunggal sebenarnya memberikan nilai yang baik karena masih dalam kisaran di atas 90 %. Namun pra-pemrosesan *dataset* ternyata memberikan efek yang lebih baik lagi karena bisa mendongkrak nilai akurasi dari klasifikasi tunggal *decision tree* dengan selisih 6,2%. Hal ini membuktikan bahwa pra-pemrosesan yang digunakan seperti eliminasi *missing values* dan *discretization* cukup berpengaruh terhadap hasil klasifikasi. Diskritisasi atribut bertujuan untuk menyederhanakan permasalahan dan memperbaiki kualitas data sehingga bisa meningkatkan akurasi dalam proses pembelajaran. Sehingga apabila *dataset* sudah memiliki kriteria yang lengkap maka hasil klasifikasi juga akan turut meningkat. Sedangkan untuk metode *ensemble* yaitu penggunaan *meta-algorithms* dengan menggunakan *bagging* untuk melatih *dataset* yang telah dilakukan pra-pemrosesan mendapatkan hasil tertinggi yaitu 98,7%. *Bagging* mampu meningkatkan kinerja model *decision tree* dikarenakan bisa mengurangi adanya *variance* dan *overfitting* pada model [19]. Selain itu, *bagging* merupakan metode yang cocok untuk *decision tree* sebagai model yang berubah jika data pelatihannya ikut berubah.

4. KESIMPULAN DAN SARAN

Tujuan dari penelitian ini adalah untuk mengetahui peningkatan kinerja klasifikasi berdasarkan penambahan pra-pemrosesan dan model *meta-algorithms* dalam data telemarketing. Berdasarkan hasil penelitian yang diperoleh, tindakan pra-pemrosesan dan penggunaan *meta-algorithms* seperti *bagging* memberikan kontribusi yang baik untuk proses pembelajaran model *decision tree* pada data telemarketing dengan hasil akurasi terbaik 98,7% daripada tiga skenario lainnya. Semakin tinggi nilai akurasi yang dihasilkan dari proses klasifikasi, tingkat keberhasilan proses telemarketing juga akan meningkat. Dengan adanya hasil peningkatan nilai akurasi ini, maka diharapkan menjadi acuan dalam menyempurnakan dan meningkatkan keberhasilan proses telemarketing.

DAFTAR PUSTAKA

- [1] C. S. T. Koumetio, W. Cherif, and S. Hassan, "Optimizing the prediction of telemarketing target calls by a classification technique," *Proc. - 2018 Int. Conf. Wirel. Networks Mob. Commun. WINCOM 2018*, no. October, 2019, doi: 10.1109/WINCOM.2018.8629675.
- [2] E. M. A. Elsalamony A. Hany, "Bank Direct Marketing Based on Neural Network," *Adv. Energy Mater.*, vol. 8, no. 25, pp. 1–9, 2018, doi: 10.1002/aenm.201800466.
- [3] K. C. Schneider, "Telemarketing as a promotional tool-its effects and side effects," *J. Consum. Mark.*, vol. 2, no. 1, p. 29, 1985, doi: 10.1108/eb038818.

- [4] E. Zeinulla, K. Bekbayeva, and A. Yazici, "Comparative study of the classification models for prediction of bank telemarketing," *IEEE 12th Int. Conf. Appl. Inf. Commun. Technol. AICT 2018 - Proc.*, pp. 1–5, 2018, doi: 10.1109/ICAICT.2018.8747086.
- [5] R. Vaidehi, "Predictive Modeling to Improve Success Rate of Bank Direct Marketing Campaign," *Int. J. Manag. Bus. Stud.*, vol. 6, no. 1, pp. 22–24, 2016.
- [6] S. Moro, P. Cortez, and P. Rita, "A data-driven approach to predict the success of bank telemarketing," *Decis. Support Syst.*, vol. 62, pp. 22–31, 2014, doi: 10.1016/j.dss.2014.03.001.
- [7] V. Yadav, M. Sreelatha, and T. V. Rajinikanth, "Classification of telemarketing data using different classifier algorithms," *Int. J. Innov. Technol. Explor. Eng.*, vol. 8, no. 12, pp. 1300–1306, 2019, doi: 10.35940/ijitee.L3917.1081219.
- [8] J. Asare-Frempong and M. Jayabalan, "Predicting customer response to bank direct telemarketing campaign," *2017 Int. Conf. Eng. Technol. Technopreneurship, ICE2T 2017*, vol. 2017-Janua, pp. 1–4, 2017, doi: 10.1109/ICE2T.2017.8215961.
- [9] K. H. Kim, C. S. Lee, S. M. Jo, and S. B. Cho, "Predicting the success of bank telemarketing using deep convolutional neural network," *Proc. 2015 7th Int. Conf. Soft Comput. Pattern Recognition, SoCPaR 2015*, pp. 314–317, 2016, doi: 10.1109/SOCPAR.2015.7492828.
- [10] W. Jin and Y. He, "Three data mining models to predict bank telemarketing," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 490, no. 6, 2019, doi: 10.1088/1757-899X/490/6/062075.
- [11] D. Grzonka, G. Suchacka, and B. Borowik, "Application of Selected Supervised Classification Methods to Bank Marketing Campaign," *Inf. Syst. Manag.*, vol. 5, no. 1, pp. 36–48, 2016.
- [12] S. Palaniappan, A. Mustapha, C. F. Mohd Foozy, and R. Atan, "Customer Profiling using Classification Approach for Bank Telemarketing," *JOIV Int. J. Informatics Vis.*, vol. 1, no. 4–2, p. 214, 2017, doi: 10.30630/joiv.1.4-2.68.
- [13] L. Rahman, N. A. Setiawan, and A. E. Permanasari, "Feature selection methods in improving accuracy of classifying students' academic performance," in *2017 2nd International conferences on Information Technology, Information Systems and Electrical Engineering (ICITISEE)*, Nov. 2017, no. 1, pp. 267–271, doi: 10.1109/ICITISEE.2017.8285509.
- [14] A. Saifudin and R. S. Wahono, "Penerapan Teknik Ensemble untuk Menangani Ketidakseimbangan Kelas pada Prediksi Cacat Software," *J. Softw. Eng.*, vol. 1, no. 1, pp. 28–37, 2015.
- [15] L. Breiman, "Bagging predictors," *Mach. Learn.*, vol. 24, no. 2, pp. 123–140, 1996, doi: 10.1007/bf00058655.
- [16] Y. Freund and R. E. Schapire, "A Short Introduction to Boosting," *J. Japanese Soc. Artif. Intell.*, vol. 14, no. 5, pp. 771–780, 1999, [Online]. Available: <http://arxiv.org/abs/1508.01136>.
- [17] V. Estivill-Castro, M. Lombardi, and A. Marani, "Improving binary classification of web pages using an ensemble of feature selection algorithms," in *Proceedings of the Australasian Computer Science Week Multiconference on - ACSW '18*, 2018, pp. 1–10, doi: 10.1145/3167918.3167963.
- [18] R. Sikora and O. Al-Laymoun, "A Modified Stacking Ensemble Machine Learning Algorithm Using Genetic Algorithms," in *Artificial Intelligence*, IGI Global, pp. 395–405.
- [19] M. Mirqotussa'adah, M. A. Muslim, E. Sugiharti, B. Prasetyo, and S. Alimah, "Penerapan Dizcretization dan Teknik Bagging Untuk Meningkatkan Akurasi Klasifikasi Berbasis Ensemble pada Algoritma C4.5 dalam Mendiagnosa Diabetes," *Lontar Komput. J. Ilm. Teknol. Inf.*, vol. 8, no. 2, p. 135, 2017, doi: 10.24843/lkjiti.2017.v08.i02.p07.