

DECISION TREE DENGAN BINARY BAT ALGORITHM OPTIMIZATION PADA HEART CATHETERIZATION PREDICTION

Natasya Yosevin Nababan¹, Kharisma Grace Tambunan², Indah Sonia Sinaga³, Junita Amalia^{4*}
^{1), 2), 3), 4)}Sistem Informasi, Fakultas Informatika dan Teknik Elektro, Institut Teknologi Del
¹tasyanababan150299@gmail.com, ²kharismagrace0710@gmail.com,
³indahsoniasinaga@gmail.com, ^{4*}junita.amalia@del.ac.id

ABSTRACT

Risk of heart catheterization is huge, to ensure the patient will perform right heart catheterization optimally, it is necessary to predict whether the patient needs it or not. In this study, the classification is using K-Nearest Neighbor, Decision Tree C4.5, and Decision Tree C4.5 optimized with Bat Binary Algorithm. Prior to classification, data preprocessing is carried out which aims to produce good data for processing and obtain accurate classification result. The data preprocessing carried out are data cleaning, data selection and data normalization. The combination of the best parameter value for Binary Bat Algorithm as the feature generator selected is $q = 2$, $a = 0.2$, $r = 0.4$, $n = 30$, $M_i = 10$ and the comparison of training and testing data are 90% and 10%. Based on experiment result, the classification accuracy of Decision Tree optimized with Bat Binary Algorithm is the highest, which is 0.725. Meanwhile the accuracy of K-Nearest Neighbor is 0.600 and accuracy of decision Tree is 0.588.

Keywords: *Bat Binary Algorithm, Decision Tree, K-Nearest Neighbor.*

ABSTRAK

Risiko kateterisasi jantung kanan sangat besar, untuk menentukan seorang pasien akan melakukan kateterisasi jantung kanan secara optimal maka dibutuhkan prediksi apakah seorang pasien membutuhkan atau tidak. Pada penelitian ini, pengklasifikasian apakah pasien membutuhkan kateterisasi jantung kanan dengan algoritma *K-Nearest Neighbor*, *Decision Tree C4.5*, dan *Decision Tree C4.5* yang dioptimasi dengan *Bat Binary Algorithm*. Sebelum dilakukan klasifikasi terlebih dahulu dilakukan *preprocessing* data yang memiliki tujuan untuk menghasilkan data yang baik untuk diproses dan didapatkan hasil klasifikasi yang akurat. Data *preprocessing* yang dilakukan adalah data *cleaning*, data *selection* dan data *normalization*. Kombinasi nilai parameter terbaik *Binary Bat Algorithm* sebagai pembangkit *feature* yang dipilih adalah $q = 2$, $a = 0,2$, $r = 0,4$, $n = 30$, $M_i = 10$ dan perbandingan data training dan testing 90% dan 10%. Dari hasil eksperimen, nilai akurasi klasifikasi *Decision Tree C4.5* dengan *Bat Binary Algoritma* paling tinggi, yaitu 0,725. Sementara itu, nilai akurasi menggunakan K-Nearest Neighbor sebesar 0,600 dan nilai akurasi menggunakan Decision Tree C4.5 saja sebesar 0,588.

Kata Kunci: *Bat Binary Algorithm, Decision Tree, K-Nearest Neighbor.*

PENDAHULUAN

Pemeriksaan kondisi jantung harus dilakukan dengan teliti dan tepat agar tidak terjadi kesalahan diagnosa yang dapat menyebabkan ketidaksesuaian penanganan serta dalam penanganan tersebut membutuhkan biaya besar yang dapat merugikan pasien. Tindakan kateterisasi yang dilakukan sesuai kaidah dapat menolong nyawa dan memperbaiki kualitas hidup seseorang yang memiliki penyakit jantung dan pembuluh darah, tetapi tindakan kateterisasi jantung dan pembuluh darah juga memiliki risiko serius bahkan dapat menyebabkan kematian [1]. Karena risiko kateterisasi jantung kanan sangat besar, untuk menentukan seorang

pasien melakukan kateterisasi jantung kanan secara optimal maka dibutuhkan prediksi apakah seorang pasien membutuhkan kateterisasi jantung kanan atau tidak.

Teknik penambangan data yang dilakukan sangat penting dalam menentukan seorang pasien membutuhkan prosedur kateterisasi jantung kanan. Pada penelitian mengenai deteksi penyakit jantung menggunakan teknik klasifikasi data mining oleh Abdul Aziz dan Aziz Ur Rehman menerapkan metode klasifikasi algoritma Decision Tree untuk memprediksi penyakit jantung [2]. Pada penelitian tersebut mengatakan bahwa algoritma Decision Tree memiliki hasil terbaik dalam melakukan



prediksi sebesar 79.9% dengan menggunakan delapan atribut.

Selain itu penelitian [3] melakukan perbandingan metode Bat algorithm (BA) dengan Firefly Algorithm (FA), Gravitational Search Algorithm (GSA), dan Harmony Search (HS). Akurasi yang didapat yaitu BA = 96 dengan fitur optimal sebanyak 3, FA = 92 dengan fitur optimal sebanyak 4, GSA = 92 dengan fitur optimal sebanyak 4, dan HS = 64 dengan fitur optimal sebanyak 6. Berdasarkan penelitian tersebut dapat disimpulkan bahwa Bat Algorithm, sebagai algoritma metaheuristik, mampu melakukan eksplorasi dan eksploitasi pada ruang pencarian, sehingga akan menghasilkan solusi yang optimal.

Penelitian mengenai prediksi diabetes melitus menggunakan beberapa algoritma machine learning antara lain Support Vector Machine (SVM), Naive Bayes (NB), K-Nearest Neighbor (KNN) and Decision Tree C4.5. Pada penelitian tersebut didapat akurasi yang tertinggi yaitu Decision Tree C4.5 sebesar 73,5% dan urutan yang ke-2 yaitu K-Nearest Neighbor (KNN) sebesar 70%, urutan ketiga SVM dan yang terendah adalah Naive Bayes. [4].

Berdasarkan uraian diatas, peneliti akan melakukan penelitian tentang klasifikasi kateterisasi jantung kanan dengan metode K-Nearest Neighbor, Decision Tree C4.5, Decision Tree C4.5 dengan Binary Bat Algorithm sebagai feature selection.

TINJAUAN PUSTAKA

Knowledge Discovery in Databases (KDD) adalah sebuah teknik yang digunakan oleh data analyst untuk menemukan informasi yang sebelumnya tidak diketahui dan berpotensi yang akan berguna bagi mereka, serta melihat pola-pola yang ada dalam data. Salah satu tahapan dalam keseluruhan proses KDD adalah data mining. Data mining merupakan salah satu proses yang terkandung dalam keseluruhan proses KDD yang berfungsi untuk memperoleh informasi serta menemukan pola yang menarik dari data. Proses KDD adalah urutan yang berulang dari beberapa tahapan yaitu *data cleaning*, *data integration*, *data selection*, *data reduction* dan *data transformation*, *data mining*, *pattern evaluation*, dan *knowledge presentation*.

Data cleaning merupakan suatu proses untuk membersihkan data yang tidak lengkap, noisy, dan tidak konsisten. Data cleaning dilakukan secara rutin untuk mengisi nilai-nilai yang hilang, menghaluskan noise data, mengidentifikasi outlier, dan memperbaiki ketidakkonsistenan dalam data. Data integration merupakan suatu proses penggabungan data dari dua atau lebih sumber

menjadi satu ke dalam database yang baru. Dengan dilakukannya integrasi data dapat mengurangi dan menghindari redundansi dan dataset yang tidak konsisten. Data selection merupakan suatu proses pemilihan data yang akan digunakan pada proses data mining. Data reduction adalah proses untuk mendapatkan representasi kumpulan data yang bervolume kecil dan mempertahankan integritas data aslinya. Data transformation merupakan suatu proses mengubah format data yang sesuai sehingga proses penambangan data dilakukan lebih efisien dan dapat menemukan pola yang mudah dipahami. Terdapat metode-metode yang digunakan untuk data transformation yaitu *smoothing*, *aggregation*, *normalization*, *attribute/feature construction*, *discretization*, *concept hierarchy climbing*.

KNN melakukan klasifikasi pada sebuah instance dengan menemukan tetangga terdekat dan memilih kelas yang paling populer dari semua tetangga. KNN adalah metode inferensi induktif yang sangat efektif untuk noisy data dan fungsi target yang kompleks [5]. Fungsi target untuk seluruh ruang dapat digambarkan sebagai kombinasi dari pendekatan lokal yang kurang kompleks. Dalam KNN, pembelajaran sangat sederhana dan klasifikasi cukup memakan waktu. Langkah-langkah pada algoritma K-Nearest Neighbor untuk mengklasifikasikan data yaitu: 1). Mendefinisikan nilai K, 2). Melakukan perhitungan nilai jarak antara data latih dengan data uji, 3). Mengelompokkan data berdasarkan perhitungan jarak, 4). Mengelompokkan data berdasarkan nilai tetangga terdekat, 5). Memilih nilai yang sering muncul dari tetangga terdekat sebagai prediksi data selanjutnya.

Algoritma Decision Tree (algoritma C4.5) merupakan algoritma yang memiliki input berupa training samples dan samples [6]. Training samples merupakan data contoh yang digunakan membangun sebuah tree yang telah diuji kebenarannya. Sedangkan samples adalah *field* – *field* data yang kemudian digunakan sebagai parameter ketika melakukan klasifikasi. Algoritma *Decision Tree* dikembangkan untuk mengatasi masalah dalam melakukan data mining seperti mengatasi *missing value*, mengatasi *continue data*, dan *pruning*. *Tree Pruning* dilakukan untuk menyederhanakan tree sehingga akurasi dapat bertambah. *Pruning* ada dua pendekatan, yaitu: 1) *Pre-pruning*, yaitu menghentikan pembangunan suatu subtree lebih awal (yaitu dengan memutuskan untuk tidak lebih jauh mempartisi data *training*). Saat seketika berhenti, maka node berubah menjadi *leaf* (*node* akhir). *Node* akhir ini menjadi kelas yang paling sering muncul di antara subset sampel. 2) *Post pruning*, yaitu menyederhanakan tree dengan cara membuang beberapa cabang subtree setelah



tree selesai dibangun. *Node* yang jarang dipotong akan menjadi *leaf* (*node* akhir) dengan kelas yang paling sering muncul.

Secara umum algoritma C4.5 adalah untuk membangun pohon keputusan sebagai berikut : 1). Pilih atribut sebagai akar, 2). Buat cabang untuk masing – masing nilai, 3). Bagi kasus dalam cabang, 4). Ulangi proses untuk masing – masing cabang sampai semua kasus pada cabang memiliki kelas yang sama.

Binary Bat Algorithm (BBA) merupakan salah satu jenis dari Bat Algorithm (BA), namun fokus Binary Bat Algorithm digunakan untuk menyelesaikan masalah yang bersifat diskrit. Pada bidang ilmu *machine learning*, *feature selection* merupakan sebuah hal yang paling mendasar yang memiliki kemampuan mengurangi jumlah fitur untuk meningkatkan kinerja klasifikasi. Terdapat banyak dataset tidak berkontribusi untuk menghasilkan hasil yang baik. Oleh karena itu, fitur yang tidak relevan dan tidak penting bukan hanya meningkatkan kompleksitas namun juga memperlama waktu pemrosesan. Binary Algorithm dianggap sebagai salah satu solusi yang dapat menyelesaikan masalah data mining seperti *feature selection* [7].

METODE PENELITIAN

Pada penelitian ini, pengklasifikasian apakah pasien membutuhkan kateterisasi jantung kanan dengan algoritma *K-Nearest Neighbor*, *Decision Tree*, dan *Decision Tree* yang dioptimasi dengan *Bat Binary Algorithm*.

3.1 Data

Data yang digunakan ialah data yang didapatkan dari website *Department of Biostatistics Vanderbilt University*. Dataset yang digunakan merupakan *record* data yang terdiri dari 5.735 penerimaan di rumah sakit dari pasien yang sakit kritis, 2.184 di antaranya menerima kateterisasi jantung kanan (RHC). Dataset memiliki 5735 rows dan 63 atribut. Dari analisis atribut terdapat sebanyak 10 atribut tidak digunakan.

Tabel 1 Atribut yang Digunakan

No.	Atribut	Tipe Data	Keterangan
1	Cat1	Nominal	Kategori penyakit primer
2	Cat2	Nominal	Kategori penyakit sekunder
3	Ca	Nominal	Apakah pasien mengidap Kanker
...			
51	Meta	Diskrit	Diagnosis metabolisme

No.	Atribut	Tipe Data	Keterangan
52	Hema	Diskrit	Diagnosis hematologic
53	Label	Binary	Apakah pasien melakukan prosedur RHC atau Tidak

3.2 Preprocessing

Tahapan *preprocessing* data yang digunakan pada penelitian ini ialah data *selection*, data *cleaning*, dan data *normalization*. Data *selection* digunakan untuk memilih data yang memiliki tipe numerik dan nominal. Data *cleaning* diperlukan untuk menangani *missing data* dan *noisy data*, dilakukan dengan cara *deletion* dan *imputation*. *Deletion* dilakukan dengan menghapus atribut-atribut yang tidak digunakan dalam penelitian. Sedangkan *imputation* dilakukan dengan menggunakan nilai median pada atribut numerik yang memiliki *missing value* yakni atribut *surv2md1*, *hrt1*, *resp1*, *meanbp1*, *wb1c1* dan menggunakan nilai konstan pada atribut kategorial yakni atribut *cat2*.

Dengan adanya rentang nilai yang bervariasi pada dataset maka dilakukan normalisasi atribut menggunakan metode *normalization by decimal scaling*. Bentuk desimal pada atribut ini tetap dapat merepresentasikan nilai sebenarnya dari atribut tersebut. Atribut yang dinormalisasi menggunakan *decimal scaling* ialah atribut bertipe data numerik.

3.3 K-Nearest Neighbor (KNN)

Berdasarkan penelitian yang dilakukan oleh Achmad Safriandono, terhadap diagnosis penyakit jantung koroner dengan menggunakan algoritma *K-Nearest Neighbor* (KNN). Dikatakan bahwa dengan menggunakan algoritma algoritma KNN berbasis *Forward Selection*, dapat meningkatkan akurasi dan mereduksi ukuran data set. Namun penelitian dengan menggunakan algoritma KNN akurasi belum terlalu tinggi. Dataset jantung koroner dengan menggunakan algoritma KNN memiliki nilai akurasi 86,79% dan nilai AUC (*Area Under Curve*) 0,963 yang tergolong dalam kategori *excellent classification*. Dalam penelitian ini juga dinyatakan bahwa pada saat dataset jantung koroner dengan menggunakan algoritma *Forward Selection* KNN memiliki nilai akurasi sebesar 91,86% dengan nilai AUC 0,777 yang tergolong dalam kategori *fair classification* [8]. Berdasarkan hal yang sudah dijelaskan algoritma ini masih memiliki kelemahan yaitu membutuhkan memori yang besar



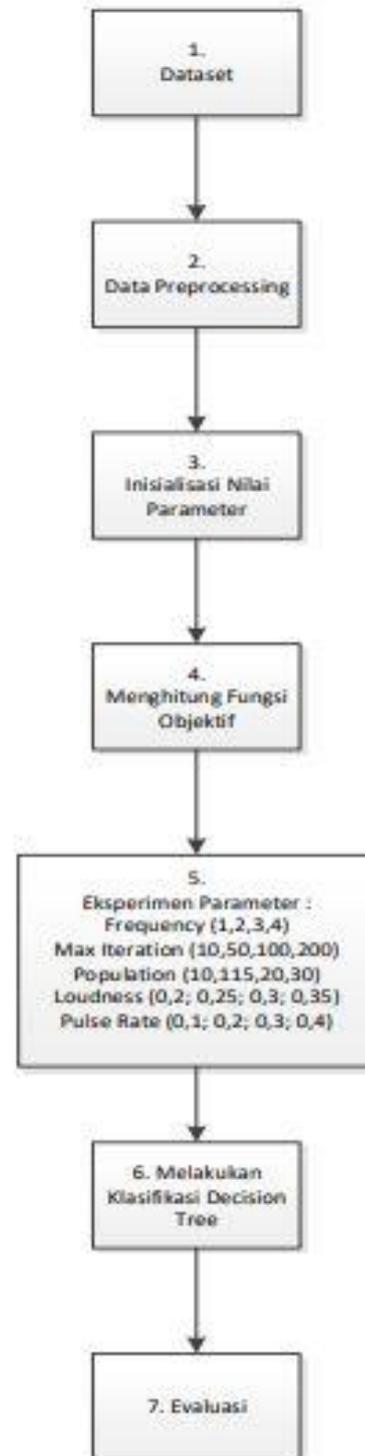
untuk menyimpan seluruh sampel yang dibutuhkan. Apabila sampel yang dibutuhkan besar maka waktu respon pada komputer yang dibutuhkan juga besar. Walaupun masalah persyaratan memori menjadi perhatian yang besar dengan menggunakan KNN dalam melakukan klasifikasi pada berbagai jenis dataset. Membagi data menjadi data training dan data set merupakan sebuah solusi untuk menghasilkan model klasifikasi pada algoritma ini. Dan yang paling penting ialah ketika membagi data dapat meningkatkan kinerja klasifikasi.

3.4 Decision Tree Dengan BBA

Beberapa keunggulan *Decision Tree* C4.5 ialah dapat menangani atribut dengan tipe data diskrit atau kontinu, mampu menangani atribut yang memiliki *missing value*, melakukan pemangkasan pohon, dan dalam pemilihan atribut dilakukan menggunakan *gain ratio*. Namun yang menjadi kelemahannya adalah hasil kualitas keputusan yang didapatkan dari metode decision tree C4.5 sangat tergantung pada bagaimana pohon tersebut didesain. Untuk itu, pada penelitian ini *Decision Tree* C4.5 akan dioptimasi dengan BBA, untuk mendapatkan hasil akurasi yang optimal.

Untuk langkah awal, dataset akan melalui tahapan data preprocessing. Setelah tahapan data preprocessing, akan dilakukan pemilihan atribut optimal dengan *Binary Bat Algorithm*. Dalam melakukan pemilihan fitur optimal, akan dilakukan eksperimen pada ke-5 parameter untuk menemukan kombinasi parameter terbaik untuk memilih fitur optimal. Parameter yang dioptimasi adalah parameter frekuensi (q), *loudness* (a), *pulse rate* (r), jumlah populasi (n), dan maksimum iterasi (M_i). Kombinasi parameter terbaik dapat ditentukan dengan memperhatikan hasil akurasi setelah mengimplementasikan ke dalam *algoritma Decision Tree*. Langkah akhir dari eksperimen pada penelitian ialah dengan membandingkan hasil analisis dari ketiga metode tersebut.

Desain klasifikasi algoritma *Decision Tree* dengan *Binary Bat Algorithm* sebagai *feature selection* dapat dilihat pada Gambar berikut.



Gambar 1 Desain Klasifikasi Algoritma Decision Tree dengan Binary Bat Algorithm



HASIL DAN PEMBAHASAN

Implementasi dilakukan pada tiga algoritma yaitu klasifikasi dengan KNN, *Decision Tree C4.5* serta *Decision Tree C4.5* dengan BBA. Berikut hasil evaluasi dari setiap algoritma yang diimplementasikan.

4.1. Klasifikasi dengan KNN

Berikut hasil eksperimen menggunakan KNN dengan pembagian data training dan testing untuk mendapatkan akurasi yang paling tinggi.

Tabel 2 Nilai Akurasi Klasifikasi dengan KNN

Jumlah Data Training	Jumlah Data Testing	Nilai Akurasi
90%	10%	0,599
80%	20%	0,600
70%	30%	0,592
60%	40%	0,595

Dari tabel diatas dapat dilihat akurasi tertinggi didapatkan dengan jumlah data training 80% dan data testing 20% dengan akurasi 0,600. Nilai akurasi ini didapatkan dengan menggunakan $K=2$.

4.2. Klasifikasi dengan *Decision Tree C4.5*

Berikut hasil eksperimen menggunakan KNN dengan pembagian data training dan testing untuk mendapatkan akurasi yang paling tinggi.

Tabel 3 Nilai Akurasi Klasifikasi dengan *Decision Tree C4.5*

Jumlah Data Training	Jumlah Data Testing	Nilai Akurasi
90%	10%	0,564
80%	20%	0,588
70%	30%	0,586
60%	40%	0,579

Dari tabel diatas dapat dilihat akurasi tertinggi didapatkan dengan jumlah data training 80% dan data testing 20% dengan akurasi 0,588.

4.3. Klasifikasi dengan *Decision Tree C4.5* dengan BBA

Untuk mendapatkan hasil klasifikasi yang paling optimal dari algoritma *decision tree* dengan BBA dilakukan experiment terhadap nilai parameter frekuensi (q), *loudness* (a), *pulse rate* (r), jumlah populasi (n), dan maksimum iterasi (M_i). Kombinasi nilai parameter frekuensi dengan nilai parameter lainnya yang digunakan untuk memperoleh atribut optimal. Atribut optimal

sebagai inputan untuk membangkitkan model klasifikasi dan nilai akurasi yang dihasilkan untuk menentukan nilai parameter q terbaik.

Kombinasi nilai parameter *loudness* dengan nilai parameter lainnya yang digunakan untuk memperoleh atribut optimal. Atribut optimal sebagai inputan untuk membangkitkan model klasifikasi dan nilai akurasi yang dihasilkan untuk menentukan nilai parameter a terbaik. Begitu juga dengan parameter *pulse rate* (r), jumlah populasi (n), dan maksimum iterasi (M_i).

Dari setiap parameter tersebut juga dilakukan *experiment* dengan jumlah data *training* dan data *testing* yang beragam yaitu 90% dan 10%, 80% dan 20%, 70% dan 30% serta 60% dan 40%. Hasil *experiment*, nilai akurasi tertinggi yaitu 0,725 didapatkan saat nilai $q = 2$, $a = 0,2$, $r = 0,4$, $n = 30$, $M_i = 10$ dengan partisi data *training* dan data *testing* 90%:10%.

4.4. Perbandingan Hasil Evaluasi KNN, *Decision Tree C4.5* dan *Decision Tree C4.5* dengan BBA

Berikut hasil evaluasi ketiga algoritma yang digunakan:

Tabel 4 Perbandingan Hasil Nilai Evaluasi KNN, *Decision Tree C4.5* dan *Decision Tree C4.5* dengan BBA

No	Algoritma	Class	Precision	Recall	F1-score	Accuracy
1	KNN	0	0,64	0,86	0,73	0,600
		1	0,38	0,15	0,21	
2	<i>Decision Tree</i>	0	0,71	0,71	0,71	0,588
		1	0,53	0,53	0,53	
3	<i>Decision Tree</i> dengan BBA	0	0,72	0,69	0,70	0,725
		1	0,56	0,59	0,57	

Dari Tabel diatas dapat disimpulkan bahwa akurasi dari *Decision Tree C4.5* dengan BBA lebih tinggi dibanding dengan algoritma *Decision Tree C4.5* dan algoritma K-Nearest Neighbor.

KESIMPULAN DAN SARAN

Berdasarkan hasil analisis dan eksperimen yang telah dilakukan menunjukkan bahwa pembagian data menjadi data train dan data set dapat mempengaruhi hasil klasifikasi dimana semakin banyak data train cenderung semakin besar performa klasifikasi, maka dapat disimpulkan bahwa klasifikasi yang dilakukan dengan KNN memiliki akurasi paling tinggi dengan

perbandingan pembagian data 80% : 20% sebesar 0,600.

Klasifikasi yang dilakukan dengan *Decision Tree C4.5* memiliki akurasi paling tinggi dengan perbandingan pembagian data 80% : 20% sebesar 0,588. Klasifikasi yang dilakukan dengan *Decision Tree C4.5* yang telah dioptimasi dengan BBA sebagai menghasilkan model klasifikasi yang optimal dengan nilai akurasi 0,725. Hal ini berkaitan dengan dilakukannya eksperimen dalam penentuan kombinasi nilai parameter terbaik pada saat pemilihan fitur sebelum dilakukannya klasifikasi. Kombinasi nilai parameter terbaik BBA pembangkit *feature* terpilih yaitu $q = 2$, $a = 0,2$, $r = 0,4$, $n = 30$, $M_i = 10$ dengan partisi data 90%:10%.

Saran untuk pengembangan penelitian selanjutnya adalah melakukan klasifikasi RHC menggunakan optimasi algoritma metaheuristic lainnya. Pemodelan ini diharapkan dapat memberikan informasi apakah kinerja algoritma tersebut tidak jauh berbeda dengan optimasi BBA. Saran lain yaitu melakukan klasifikasi RHC menggunakan algoritma K-Nearest Neighbor dengan Binary Bat Algorithm.

REFERENSI

Minimal Referensi 7 sumber. Direkomendasikan menggunakan *Tools Reference Manager* seperti MENDELEY atau lainnya dengan *APA Style Citation*. Sistematika penulisannya adalah:

- [1] Perhimpunan Dokter Spesialis Kardiovaskular Indonesia. (2018). Pedoman Laboratorium Kateterisasi Jantung Dan Pembuluh Darah. Indonesia.
- [2] Aziz, A. & Rahman, A. U. R. (2017). Detection of Cardiac Disease using Data Mining Classification Techniques. *International Journal of Advanced Computer Science and Applications (IJACSA)*, 8(7),256-259.
- [3] Ramasamy, R and Rani, S. (2018). Modified Binary Bat Algorithm for Feature Selection in Unsupervised Learning. *The International Arab Journal of Information Technology*, 15(6), 1060-1067.
- [4] Faruque, M.F, Asaduzzaman and Sarker, I. H. (2019). Performance Analysis of Machine Learning Techniques to Predict Diabetes Melitus. *International Conference on Electrical, Computer and Communication Engineering (ECCE)*.
- [5] Saxena, K., Khan, Z & Singh, S. (2014). Diagnosis of Diabetes Melitus Using K Nearest Neighbor Algorithm. *International*

Journal of Computer Science Trends and Technology (IJCST), 2(4), 36-43.

- [6] Cynthia, E. K., & Ismanto, E. (2018). Metode Decision Tree Algoritma C.45 Dalam Mengklasifikasi Data Penjualan Bisnis Gerai Makanan Cepat Saji. *Jurnal Riset Sistem Informasi dan Teknik Informatika(JURASIK)*, vol. 3, 1-13.
- [7] Alam, M. W, U. (2019). Improved Binary Bat Algorithm for Feature Selection. Abo Akademi University.
- [8] Safriandono, A. N. (2017). Algoritma K-Nearest Neighbor Berbasis Forward Selection Untuk Mendiagnosis Penyakit Jantung Koroner. *KOMPUTAKI*, 3(1), 1-16.