

BAB II LANDASAN TEORI

2.1. Tinjauan Pustaka

Beberapa penelitian terkait dengan penelitian menggunakan *machine learning* dan analisis klasifikasi data sudah ditemukan sebelumnya. Penelitian yang dilakukan oleh (Pradeep & Naveen, 2018) adalah memprediksi kelangsungan hidup pasien kanker paru-paru agar ke depannya dapat mengevaluasi pola yang merupakan faktor risiko untuk studi kanker paru-paru. Penelitian ini menggunakan 14 fitur kanker paru-paru dari *dataset* kanker paru-paru *North Central Cancer Treatment Group* (NCCTG) yang berjumlah 24 data latih dan 24 data uji dengan membandingkan kinerja dari tiga algoritma klasifikasi, yaitu *support vector machine*, C4.5, dan *naïve bayes*. Penelitian tersebut menunjukkan kinerja akurasi dan *precision* C4.5 lebih baik, yaitu sebesar 82,6 persen dalam memprediksi kanker paru-paru, sedangkan SVM memperoleh tingkat akurasi terendah sebesar 54,9 persen. Penelitian tersebut menunjukkan bahwa model algoritma yang digunakan dapat membantu dokter mendeteksi risiko kanker paru-paru secara dini.

Penelitian yang dilakukan oleh (Gerhana dkk., 2019) adalah memprediksi masa studi mahasiswa dengan membandingkan algoritma *naïve bayes classifier* dan algoritma C4.5 dengan menggunakan 109 *dataset* kelulusan mahasiswa tahun angkatan 2011 dan 2012 pada Departemen Informatika UIN Sunan Gunung Djati Bandung dan menggunakan sebanyak tujuh atribut. Dalam penelitian tersebut membandingkan akurasi prediksi masa studi mahasiswa dan kecepatan pengolahan data dari kedua algoritma tersebut. Hasil penelitian tersebut menunjukkan bahwa waktu pemrosesan pada algoritma C4.5 lebih baik, yaitu sebesar 87 persen dibandingkan dengan algoritma *naïve bayes classifier*.

Penelitian yang dilakukan oleh (Ranjan dkk., 2021) adalah mengidentifikasi siswa yang mempunyai kinerja buruk sehingga siswa tersebut mendapatkan bimbingan yang tepat pada tahap awal. Penelitian tersebut mengklasifikasikan kinerja siswa berdasarkan catatan akademik masa lalu mereka dengan melakukan perbandingan algoritma klasifikasi, yaitu *naïve bayes* dan C4.5. Data yang

digunakan dalam penelitian tersebut sebanyak 100 catatan kinerja siswa dari total data lebih dari 100 buah pada tahun 2016 dan 2017, dan menggunakan sebanyak 10 atribut. Dari analisis yang dilakukan, diperoleh hasil akurasi *naïve bayes* sebesar 70 persen dan akurasi C4.5 sebesar 86 persen.

Penelitian yang dilakukan oleh (Nanda dkk., 2021) adalah mengimplementasikan klasifikasi algoritma C4.5 dengan menggunakan *dataset* gejala pasien *covid-19* untuk menentukan tingkat risiko seseorang berdasarkan gejala yang tercatat yang didapatkan dari Kaggle pada tahun 22 Januari 2020 sampai 20 Juni 2020 dan menggunakan tujuh atribut. Hasil analisis menunjukkan bahwa algoritma C4.5 memberikan akurasi klasifikasi sebesar 75 persen.

Penelitian yang dilakukan oleh (Dardzinska-Głebocka & Zdrodowska, 2021) adalah mengklasifikasi masalah perawatan diri dengan benar untuk diagnosis anak disabilitas menggunakan 205 variabel dan 70 data di UCI Machine Learning Repository di Pusat Kesehatan di Yazd, Iran. Penelitian tersebut menggunakan lima algoritma klasifikasi, yaitu *naïve bayes classifier*, C4.5, PART, CART, dan *multilayer perceptron*. Penelitian tersebut menunjukkan bahwa model C4.5 mengklasifikasi dengan benar lebih dari 82 persen anak-anak dengan masalah perawatan diri hanya dengan menggunakan 19 fitur karakteristik.

Penelitian yang dilakukan oleh (Fadilah & Murnawan, 2021) adalah memprediksi penyakit hati dengan menggunakan perbandingan KNN dengan PSO dan C4.5 dengan PSO. Pemrosesan dan pengujian data menggunakan RapidMiner. *Dataset* yang digunakan berjumlah 2093 data penyakit hati yang mempunyai 11 atribut yang dikumpulkan dari UCI Machine Learning Repository. Dari membandingkan kedua algoritma tersebut, didapatkan hasil bahwa C4.5 dengan PSO mempunyai tingkat kinerja lebih baik, yaitu sebesar 91,26 persen dengan waktu eksekusi 25 detik, sedangkan tingkat kinerja KNN dengan PSO sebesar 89,11 persen dengan waktu eksekusi selama 94 detik. Selisih hasil AUC antara algoritma KNN dengan PSO dan C4.5 dengan PSO mendekati 1,00.

Penelitian yang dilakukan oleh (Ariyati dkk., 2020) adalah menentukan aplikasi pembayaran digital, seperti GoPay atau OVO, menggunakan pemodelan pohon keputusan C4.5 dan optimasi PSO untuk memberikan klasifikasi paling baik

dan meningkatkan nilai validasi untuk memilih pembayaran digital. Jumlah *dataset* 750 responden. Dari hasil penelitian tersebut, didapatkan 10 atribut dari 14 atribut, serta diperoleh akurasi sebesar 90 persen, *precision* sebesar 92,07 persen, dan *recall* sebesar 90,67 persen.

Penelitian yang dilakukan oleh (Kadafi & Gata, 2019) adalah melakukan klasifikasi kompetensi dan kinerja guru menggunakan algoritma C4.5 dengan pemilihan atribut PSO. *Dataset* menggunakan 133 data dan 10 atribut, dan menggunakan RapidMiner. Setelah melakukan klasifikasi dan menerapkan algoritma PSO didapatkan empat parameter yang menghasilkan akurasi sebesar 79,70 persen dan nilai kappa sebesar 0,528.

Penelitian yang dilakukan oleh (Amrin & Pahlevi, 2021) adalah mendiagnosis penyakit peradangan hati dengan membandingkan beberapa metode klasifikasi *data mining* dan optimasi dengan PSO, yaitu C4.5, KNN, C4.5 dengan PSO, dan KNN dengan PSO. Pengukuran kinerja keempat model tersebut menggunakan metode *cross validation*, *confusion matrix*, dan *ROC curve*. Dari hasil penelitian yang dilakukan, diketahui bahwa metode C4.5 dengan PSO mendapatkan akurasi terbaik, yaitu sebesar 79,51 persen. Selanjutnya, metode KNN dengan PSO mendapatkan akurasi sebesar 75,59 persen. Pada C4.5 memperoleh tingkat akurasi sebesar 70,99 persen, sedangkan KNN memperoleh tingkat akurasi sebesar 67,19 persen.

Penelitian yang dilakukan oleh (Setiawan dkk., 2019) adalah menentukan pola keterlambatan order suatu produksi dengan menggunakan metode klasifikasi C4.5 berdasarkan PSO. Data yang digunakan dalam penelitian tersebut adalah data pembuatan produk kosmetik dan produk herbal. Dari analisis yang dilakukan, diperoleh hasil bahwa optimasi algoritma C4.5 dengan PSO mempunyai tingkat akurasi sebesar 82,52 persen. Hasil tersebut lebih baik dibandingkan dengan tingkat nilai akurasi dari model algoritma C4.5, yaitu sebesar 80,17 persen. Selisih dari akurasi kedua model tersebut sebesar 0,033. Dari hasil analisis optimasi algoritma C4.5 dengan PSO, pola keterlambatan suatu produk dipengaruhi oleh status produk yang menyebabkan keterlambatan pesanan produksi, status menunggu pra produksi, dan status administratif.

Tabel 2.1 Penelitian Terkait

| No | Judul Penelitian | Studi Kasus | Metode yang Digunakan | Hasil Penelitian |
|----|--|---|------------------------------------|--|
| 1 | <i>Lung cancer survivability prediction based on performance using classification techniques of support vector machines, c4.5, and naïve bayes algorithms for healthcare analytics</i> (Pradeep & Naveen, 2018) | Prediksi tingkat kelangsungan hidup pasien kanker paru-paru menggunakan 14 fitur kanker paru-paru dengan membandingkan 3 algoritma klasifikasi. | - SVM - C4.5 - naïve bayes | Akurasi, AUC, dan <i>precision</i> C4.5 menggunakan dataset 2200 buah lebih baik dalam memprediksi kanker paru-paru yaitu 82,6%. |
| 2 | <i>Comparison of naïve bayes classifier and c4.5 algorithms in predicting student study period</i> (Gerhana dkk., 2019). | Membandingkan akurasi prediksi masa studi mahasiswa dan kecepatan pengolahan data dari algoritma yang digunakan. | - naïve bayes classifier - C4.5 | Waktu pemrosesan algoritma C4.5 lebih baik dengan memperoleh akurasi 87%. |
| 3 | <i>Student performance prediction using</i> | Mengklasifikasi kinerja siswa berdasarkan | - naïve bayes - C4.5 | C4.5 menunjukkan akurasi 86%, naïve |

| No | Judul Penelitian | Studi Kasus | Metode yang Digunakan | Hasil Penelitian |
|----|--|--|---|---|
| | <i>classification algorithms</i> (Ranjan dkk., 2021) | catatan akademik masa lalu. | | <i>bayes</i> memiliki akurasi 70%. |
| 4 | <i>Covid-19 risk assessment using the c4.5 algorithm</i> (Nanda dkk., 2021) | Menentukan tingkat risiko seseorang berdasarkan gejala pasien <i>covid-19</i> . | C4.5 | Uji klasifikasi algoritma c4.5 menghasilkan akurasi 75%. |
| 5 | <i>Analysis children with disabilities self-care problems based on selected data mining techniques</i> (Dardzinska-Glebocka & Zdrodowska, 2021) | Klasifikasi masalah perawatan diri dengan benar untuk diagnosis anak disabilitas menggunakan 205 variabel data dengan 5 algoritma klasifikasi. | - <i>naïve bayes classifier</i> - C4.5 - PART - CART - <i>multilayer perceptron</i> | Model C4.5 mengklasifikasi dengan benar lebih dari 82% anak-anak dengan masalah perawatan diri, menggunakan 19 fitur karakteristik. |
| 6 | <i>Performance comparison of k-nearest neighbor and decision tree c4.5 by utilizing</i> | Membandingkan algoritma KNN dan C4.5 pada prediksi penyakit hati, dipadukan dengan PSO | - KNN- PSO - C4.5-PSO | Akurasi C4.5 dan PSO=91,26%, Akurasi KNN dan PSO=89,11%. Selisih hasil AUC antara kedua |

| No | Judul Penelitian | Studi Kasus | Metode yang Digunakan | Hasil Penelitian |
|----|--|--|--|--|
| | <i>particle swarm optimization for prediction of liver disease</i> (Fadilah & Murnawan, 2021) | untuk meningkatkan performa akurasi. | | algoritma mendekati 1,00. |
| 7 | <i>Optimization of the decision tree algorithm used particle swarm optimization in the selection of digital payments</i> (Ariyati dkk., 2020) | Melakukan peningkatan kualitas pemodelan pohon keputusan dan akurasi memilih pembayaran digital. | - C4.5-PSO | Hasil penelitian menunjukkan tingkat akurasi meningkat sebesar 90%, <i>precision</i> 92,07%. |
| 8 | <i>Particle swarm optimization based c4.5 for teacher performance classification</i> (Kadafi & Gata, 2019) | Klasifikasi kompetensi dan kinerja guru menggunakan kombinasi 2 algoritma. | - C4.5-PSO | Hasil penelitian menunjukkan C4.5 dengan PSO menghasilkan akurasi 79,70%, nilai kappa sebesar 0,528. |
| 9 | <i>Data mining optimization based on particle swarm optimization for</i> | Menerapkan dan membandingkan metode klasifikasi <i>data mining</i> | - C4.5 - KNN - C4.5-PSO - KNN-PSO | Akurasi C4.5=70,99% dengan nilai AUC=0,950. Akurasi |

| No | Judul Penelitian | Studi Kasus | Metode yang Digunakan | Hasil Penelitian |
|----|--|--|-----------------------|--|
| | <i>diagnosis of inflammatory liver disease</i> (Amrin & Pahlevi, 2021) | dan optimasi PSO untuk mendiagnosis penyakit peradangan hati. | | KNN=67,19%, nilai AUC=0,873. Akurasi C4.5- PSO=79,51%, nilai AUC=0,950. Akurasi k-NN- PSO=75,59%, nilai AUC=0,909. |
| 10 | <i>C4.5 classification algorithm based on particle swarm optimization to determine the delay order production Pattern</i> (Setiawan dkk., 2019) | Menentukan pola keterlambatan order produksi menggunakan atribut pembobotan untuk meningkatkan akurasi klasifikasi C4.5 dalam memperoleh pola pesanan produksi yang terlambat. | - C4.5 - PSO-C4.5 | Akurasi model C4.5-PSO =82,52%. Akurasi model C4.5=80,17%. Selisih 0,033, nilai AUC=0,855 (good classification). Atribut yang memengaruhi: status produksi diikuti status menunggu pra produksi dan status administratif. |

2.2. Dasar Teori

2.2.1. Tunagrahita

Tunagrahita salah satu jenis gangguan atau keterbatasan yang dialami pada anak berkebutuhan khusus. Tunagrahita adalah disabilitas mental yang dikenal

dengan *retradasi* mental. Dalam kesehariannya, anak penyandang tunagrahita sulit dalam menulis, berhitung, dan membaca (Sakinah, 2018). Klasifikasi anak tunagrahita meliputi tunagrahita ringan, sedang, dan berat. Setiap tingkat berbeda dalam hal keterlambatan perkembangan dan kondisinya, sehingga strategi pendidikan dan pengajaran dirancang dan diprogram secara berbeda (Rochyadi, 2012).

Berdasarkan pengukuran kemampuan intelektual, tunagrahita ringan mempunyai IQ antara 50 sampai dengan 70, tunagrahita sedang mempunyai IQ antara 30 sampai dengan 50, dan tunagrahita berat mempunyai IQ di bawah 30. Selain pengelompokan IQ, ada pula tipe klinis atau kelainan jasmani pada ciri-ciri anak tunagrahita, yaitu seperti mempunyai raut wajah mirip orang Mongol yang bermata sipit dan miring, serta lidah tebal suka menjulur ke luar atau yang disebut dengan *down syndrome* (Pieter, 2017). Berikut karakteristik anak tunagrahita menurut tingkatannya (Rochyadi, 2012).

1) Tunagrahita ringan

Meski kalah bersaing dengan anak-anak normal seusianya, namun anak-anak tersebut dapat belajar menulis, membaca, dan berhitung sederhana. Laju perkembangan intelektualnya hanya setengah hingga tiga perempat dari anak normal dan berhenti pada saat usia muda. Kosakata terbatas tetapi kemahiran bahasa cukup dalam beberapa situasi. Dapat bersosialisasi dan hanya membutuhkan keterampilan semi-profesional. Di masa dewasa, kecerdasan mencapai tingkat normal anak-anak antara usia 9 dan 12 tahun.

2) Tunagrahita sedang

Anak tunagrahita sedang mengalami kesulitan dalam mempelajari pelajaran akademik. Perkembangan bahasa lebih terbatas, namun dapat mengkomunikasikan beberapa kata. Anak bisa menulis dan membaca, sambil tetap bisa mengurus dirinya sendiri. Walaupun kecerdasan saat dewasa tidak lebih dari anak normal usia 6 tahun, anak tersebut tetap dapat melakukan sesuatu di bawah pengawasan dan dapat membedakan mana yang bahaya dan tidak berbahaya.

3) Tunagrahita berat

Anak tunagrahita berat harus memerlukan pengawasan dan bantuan orang lain karena tidak mampu mengurus dirinya sendiri. Kecerdasan mencapai usia dewasa sekitar usia 4 tahun pada anak normal. Untuk menjaga kestabilan fisik dan kesehatan perlu dilakukan kegiatan yang bermanfaat, seperti memindahkan barang dan mengisi karung beras hingga penuh.

2.2.2. *Machine Learning*

Pembelajaran mesin atau *Machine Learning* (ML) merupakan subbidang kecerdasan buatan spesialisasi dalam menggunakan data untuk membuat prediksi atau mendukung pengambilan keputusan. Teori *machine learning* untuk merancang dan menganalisis beberapa algoritma yang memungkinkan komputer untuk belajar secara otomatis dan mampu dimanfaatkan untuk memprediksi data yang tidak diketahui (Urso dkk., 2019). *Machine learning* menyatukan semua teknik yang memungkinkan untuk belajar dan membuat prediksi yang akurat dari pengamatan masa lalu. Proses *machine learning* mempunyai tiga langkah dasar, yaitu *initialization*, *learning*, dan *testing*, yang menyediakan data keluaran yang efisien dan akurat. *Machine learning* bisa diterapkan pada banyak area, seperti aplikasi identifikasi wajah, prediksi cuaca, *speech reorganization*, klasifikasi, deteksi penipuan, penyaringan spam, dan sebagainya. Algoritma *machine learning* dibagi menjadi tiga (Urso dkk., 2019), yaitu:

- 1) Algoritma *supervised learning*

Algoritma *supervised learning* menggunakan data berlabel atau klasifikasi yang sesuai. Contoh algoritma *supervised learning* adalah regresi linier, *random forest*, *support vector machine*, *naïve bayes*, *decision tree*, dan *K-Nearest Neighbor* (KNN).

- 2) Algoritma *unsupervised learning*

Adalah algoritma *machine learning* yang tidak menggunakan label data karena dapat belajar dari data dengan menemukan pola tersembunyi. Salah satu teknik *unsupervised learning* yang populer adalah *clustering*.

- 3) Algoritma *reinforcement learning*

Algoritma baru *machine learning* dan sangat berbeda dari jenis algoritma *machine learning* sebelumnya. Algoritma ini memungkinkan mesin berinteraksi dengan lingkungan dinamis untuk mencapai suatu tujuan atau sasaran. Contoh algoritma *reinforcement learning* adalah *Active Query Answering* (AQA) pada Google. Sistem ini akan mengulang pertanyaan yang diajukan oleh pengguna Google.

Machine learning merupakan subbidang dari ilmu komputer dan AI, yang belajar dari pola untuk memprediksi. *Machine learning* menggunakan teknik *data mining* dan algoritma pembelajaran lainnya untuk membuat model tentang apa yang terjadi pada data guna memprediksi apa yang akan terjadi selanjutnya (Patel & Prajapati, 2018).

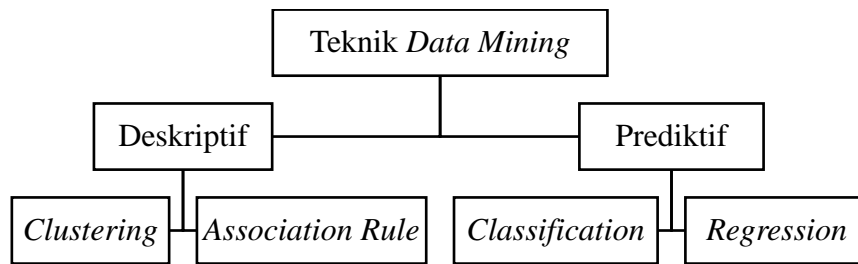
2.2.3. *Data Mining*

Data mining adalah proses penggalian informasi tersembunyi yang sebelumnya tidak diketahui. Proses *data mining* adalah pendekatan teknis, seperti *clustering* dan klasifikasi, termasuk metode yang merupakan bagian dari kecerdasan buatan (AI), pembelajaran mesin (ML), dan statistik (Ginantra dkk., 2021).



Gambar 2.1 Pertemuan Disiplin Ilmu dalam *Data Mining* (Ginantra dkk., 2021)

Data mining bertujuan mencari tren dan pola yang diinginkan dengan menganalisis suatu data yang bisa menunjukkan kelas data untuk membantu mengambil keputusan di masa depan (Harahap dkk., 2018) (Salim dkk., 2020). *Data mining* menggunakan statistik untuk mengekstrak informasi dari data mentah. *Data mining* dapat memanfaatkan data pengalaman masa lalu untuk meningkatkan proses pembelajaran, seperti penerapan klasifikasi (Ginantra dkk., 2021).



Gambar 2.2 Teknik *Data Mining* (Ginantra dkk., 2021)

2.2.4. Klasifikasi

Klasifikasi adalah metode *data mining* yang digunakan untuk memprediksi label atau kelas dari sampel yang dipelajari sebelumnya (Urso dkk., 2019). Klasifikasi adalah proses melatih atau membentuk fungsi tujuan atau target yang digunakan untuk memetakan setiap kumpulan atribut suatu objek ke salah satu label kelas yang telah ditentukan. Pengklasifikasian menerima sejumlah data, yang disebut data latih, terdiri dari kelas-kelas untuk data (Patel & Prajapati, 2018).

Tujuan klasifikasi adalah untuk menemukan model dari data latih untuk membedakan data ke dalam jenis atau kelas yang sesuai. Model tersebut kemudian digunakan untuk mengklasifikasikan data yang tidak diketahui tentang kelas tersebut (Bahri & Lubis, 2020).

2.2.5. Seleksi Fitur

Seleksi fitur diterapkan untuk mengurangi dimensi data dengan memilih kumpulan fitur yang paling sesuai sebelum menggunakan teknik *data mining* seperti klasifikasi. Algoritma *supervised learning* yang diawasi menghasilkan fungsi dari data pelatihan berkarakter untuk mengubah *input* menjadi *output* yang diinginkan. Tujuan dari penyeleksian fitur adalah untuk menambah jumlah fitur dengan menghilangkan fitur-fitur yang berlebihan atau memilih fitur-fitur yang paling berguna untuk meningkatkan penyederhanaan klasifikasi. Manfaat seleksi fitur adalah mengurangi jumlah data yang diperlukan untuk proses pembelajaran, mengurangi kebutuhan memori untuk penyimpanan data, meningkatkan waktu komputasi, serta meningkatkan kecepatan dan akurasi klasifikasi (Brezocnik, 2017).

2.2.6. Algoritma C4.5

Algoritma C4.5 merupakan teknik klasifikasi dengan membentuk pohon keputusan. Algoritma C4.5 digunakan untuk mengklasifikasikan data berdasarkan atribut numerik atau kategorikal (Normah dkk., 2020). C4.5 adalah jenis struktur data nonlinier karena menggambarkan hubungan hirarki antar elemen. Hasil proses klasifikasi yang berupa aturan dapat digunakan untuk memprediksi nilai atribut diskret atau numerik dari data baru (Lutfiyana, 2018). Berikut langkah perhitungan algoritma C4.5 (Nazir dkk., 2022), yaitu:

- 1) Menyiapkan data latih yang diambil dari data masa lalu dan dikelompokkan ke dalam kelas tertentu, kemudian menghitung jumlah kasus *class* serta nilai *entropy* dari semua kasus. Menghitung nilai *entropy* menggunakan persamaan berikut.

$$Entropy(S) = \sum_{i=0}^n - p_i \times \log_2(p_i) \quad (2.1)$$

dengan:

S adalah himpunan kasus.

n adalah jumlah partisi S .

p_i adalah proporsi dari S_i terhadap S .

- 2) Menghitung nilai *entropy* dan nilai *gain* setiap atribut. Nilai *gain* tertinggi adalah atribut yang menjadi akar atau *root* dari pohon keputusan yang akan dibuat. Menghitung nilai *gain* menggunakan persamaan berikut.

$$Gain(S, A) = Entropy(S) - \sum_{i=0}^n \frac{|S_i|}{|S|} \times Entropy(S_i) \quad (2.2)$$

dengan:

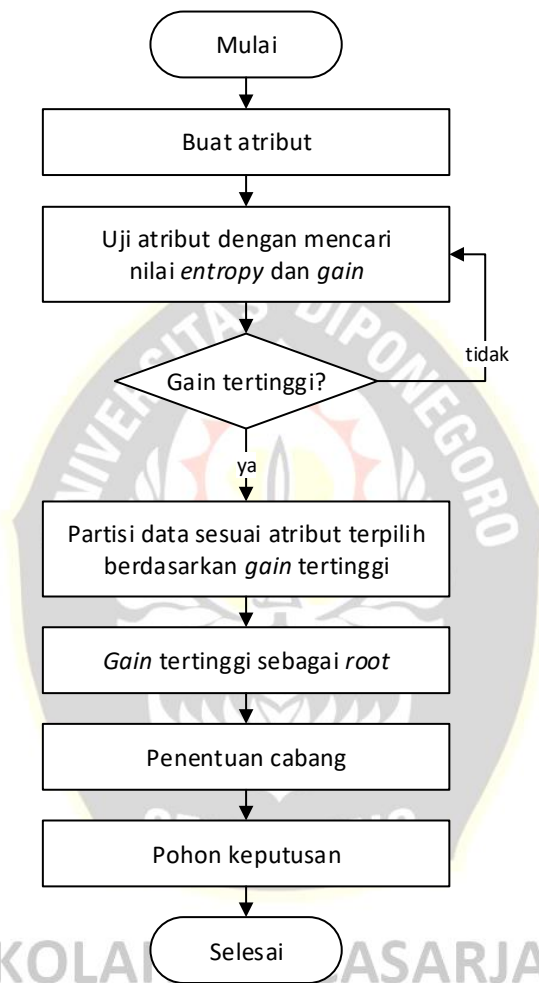
A adalah atribut.

n adalah jumlah partisi atribut A .

$|S_i|$ adalah jumlah kasus pada partisi ke- i .

$|S|$ adalah jumlah kasus dalam S .

- 3) Nilai *entropy* dan *gain* dihitung untuk semua atribut agar mendapatkan nilai *gain* tertinggi. Ulangi proses untuk setiap cabang hingga semua kasus di cabang tersebut memiliki kelas yang sama.



Gambar 2.3 *Flowchart* Klasifikasi Menggunakan C4.5 (Saputra & Prasetyo, 2020)

2.2.7. Algoritma *Particle Swarm Optimization* (PSO)

PSO merupakan algoritma optimasi yang meniru proses kehidupan yang terjadi pada populasi burung dan ikan dalam bertahan hidup. Algoritma PSO dapat digunakan pada permasalahan kontinu, diskret, linier, maupun nonlinier (Nazir dkk., 2022). Dalam algoritma PSO, populasi disebut kawanan dan individu disebut *particle*. Setiap *particle* akan bergerak dengan kecepatan yang sesuai dengan area pencarian. Setiap partikel PSO cenderung untuk terbang ke area pencarian yang

lebih baik selama proses pencarian (Sulistiyanto, 2018). PSO memiliki sejumlah parameter yang dapat diatur, ketika syarat pengaturan parameter terpenuhi maka PSO akan konvergen (Van Den Bergh & Engelbrecht, 2010). Persamaan perpindahan kecepatan dan posisi partikel sesuai dengan persamaan (2,3) dan persamaan (2,4) berikut.

$$V_i(t) = w V_i(t - 1) + c_1 r [X_{Pbest\ i} - X_i(t)] + c_2 r [X_{Gbest} - X_i(t)] \quad (2.3)$$

$$X_i(t) = X_i(t - 1) + v_i(t) \quad (2.4)$$

dengan:

$V_i(t)$ adalah kecepatan partikel i saat iterasi t .

w adalah bobot inersia.

$X_i(t)$ adalah posisi partikel i saat iterasi t .

$X_{Pbest\ i}$ adalah posisi terbaik partikel i .

X_{Gbest} adalah posisi terbaik global.

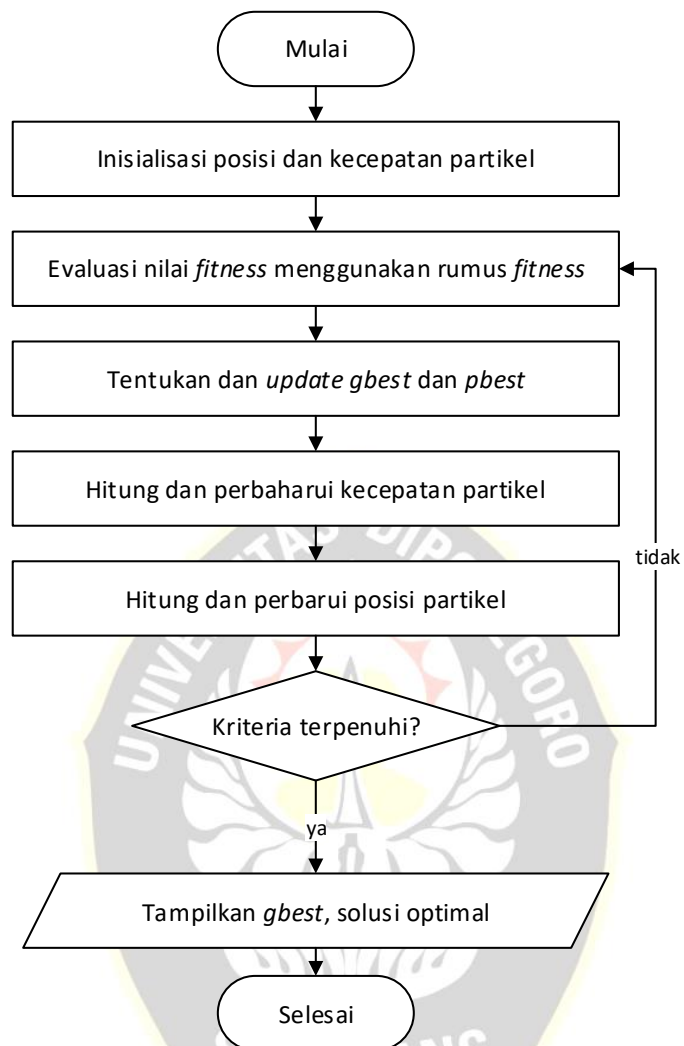
c_1 adalah *learning rates* untuk kemampuan individu (cognitive).

c_2 adalah *learning rates* untuk pengaruh sosial (group).

r_1 dan r_2 adalah bilangan *random* yang bernilai antara 0 sampai 1.



SEKOLAH PASCASARJANA



Gambar 2.4 *Flowchart* Seleksi Fitur pada PSO (Saputra & Prasetyo, 2020)

SEKOLAH PASCASARJANA