E-ISSN: 3025-0994
Halaman 4947-4961
Volume 4 Nomor 3 Tahun 2026

# Prediksi Gender Member GYM Menggunakan Algoritma Decision Tree

**Bayu Eka Susanto[1], Sujatmiko Ginting[2], Aidul Safii[3]**

[1,2,3] Magister Teknologi Informasi, Universitas Pembangunan Panca Budi, Medan, Indonesia
e-mail: Bayususanto2311@gmail.com[1] , sujatmikoginting5@gmail.com[2] , aidulsafii0707@gmail.com[3]

**Abstrak**

Perkembangan data mining memberikan peluang untuk mengolah data member gym menjadi informasi prediktif yang dapat mendukung pengambilan keputusan dan peningkatan layanan. Penelitian ini bertujuan memprediksi gender member gym menggunakan algoritma Decision Tree pada aplikasi RapidMiner serta mengidentifikasi atribut yang paling berpengaruh dalam proses klasifikasi. Penelitian menggunakan pendekatan kuantitatif dengan desain eksperimen data mining. Dataset terdiri atas atribut usia, tinggi badan, berat badan, Body Mass Index (BMI), frekuensi latihan, durasi latihan, jenis aktivitas olahraga, dan gender sebagai label. Tahapan penelitian meliputi pengumpulan data, pembersihan nilai kosong dan duplikasi, transformasi atribut kategorikal, pembagian data training dan testing, pembentukan model Decision Tree, serta evaluasi menggunakan confusion matrix dan accuracy. Hasil pengujian menunjukkan bahwa model menghasilkan 45 prediksi laki-laki dan 46 prediksi perempuan yang benar, dengan lima false positive dan empat false negative. Berdasarkan hasil tersebut, model memperoleh accuracy sebesar 91%, yang menunjukkan kemampuan klasifikasi yang baik pada dataset yang digunakan. Struktur pohon keputusan memperlihatkan bahwa BMI dan frekuensi latihan menjadi atribut dominan dalam pembentukan aturan klasifikasi. RapidMiner memudahkan integrasi proses preprocessing, pemodelan, dan evaluasi melalui antarmuka visual yang sistematis. Temuan penelitian menunjukkan bahwa Decision Tree dapat digunakan sebagai metode yang efektif dan mudah diinterpretasikan untuk menganalisis karakteristik member gym. Meskipun demikian, penerapan model perlu memperhatikan representativitas data, potensi bias, perlindungan data pribadi, dan validasi pada dataset yang lebih besar sebelum digunakan dalam pengambilan keputusan operasional.

**Kata Kunci:** Data Mining, Decision Tree, Rapidminer, Prediksi Gender, Member Gym

**Abstract**

*The development of data mining technology provides significant opportunities in data processing, resulting in predictive information that can be used for decision-making. One application of data mining can be carried out in the fitness field, particularly in the analysis of gym member data. This study aims to predict the gender of gym members using the Decision Tree algorithm in the RapidMiner application. The dataset used consists of several attributes, namely age, height, weight, Body Mass Index (BMI), exercise frequency, exercise duration, and type of sports activity. The research method used is a quantitative approach involving data collection, data preprocessing, training and testing data distribution, application of the Decision Tree algorithm, and model evaluation using a confusion matrix and accuracy. The results show that the Decision Tree algorithm produces an accuracy level of 91% in predicting the gender of gym members. In addition, the BMI and exercise frequency attributes are the most influential factors in the classification process. The use of RapidMiner facilitates the data mining implementation process more easily and efficiently. This study proves that the Decision Tree*

*algorithm can be used as an effective classification method for data mining-based gym member data analysis.*

**Keywords:** Data Mining, Decision Tree, RapidMiner, Gender Prediction, Gym Members

## LATAR BELAKANG

Perkembangan teknologi informasi dan kecerdasan buatan (Artificial Intelligence/AI) telah membawa perubahan besar dalam berbagai bidang kehidupan, termasuk pada sektor kesehatan dan kebugaran. Salah satu cabang AI yang berkembang pesat adalah data mining, yaitu proses pengolahan dan analisis data dalam jumlah besar untuk menemukan pola, hubungan, serta informasi tersembunyi yang dapat digunakan dalam pengambilan keputusan. Teknik data mining saat ini banyak diterapkan dalam berbagai bidang seperti pendidikan, kesehatan, bisnis, olahraga, dan industri jasa karena mampu menghasilkan informasi yang lebih akurat dan efisien (Han, Pei, & Tong, 2022).

Industri kebugaran atau gym merupakan salah satu sektor yang mengalami pertumbuhan signifikan dalam beberapa tahun terakhir. Meningkatnya kesadaran masyarakat terhadap pentingnya menjaga kesehatan dan kebugaran tubuh membuat jumlah pengguna layanan gym terus meningkat. Setiap member gym menghasilkan berbagai data seperti usia, berat badan, tinggi badan, indeks massa tubuh (BMI), frekuensi latihan, durasi latihan, serta jenis aktivitas olahraga yang dilakukan. Data-data tersebut apabila dianalisis dengan baik dapat menghasilkan informasi penting yang berguna dalam meningkatkan kualitas pelayanan gym dan memahami karakteristik member secara lebih mendalam (Wibowo & Nugroho, 2021).

Namun, pada kenyataannya sebagian besar data member gym hanya digunakan sebagai arsip administrasi tanpa dilakukan analisis lebih lanjut. Padahal data tersebut memiliki potensi besar untuk dimanfaatkan dalam menghasilkan informasi prediktif yang dapat membantu pengelola gym dalam menentukan strategi pelayanan maupun pemasaran. Salah satu bentuk penerapan data mining yang dapat dilakukan adalah klasifikasi atau prediksi gender member gym berdasarkan atribut tertentu. Prediksi gender dapat membantu pihak gym memahami pola latihan antara laki-laki dan perempuan sehingga program latihan dan pelayanan dapat disesuaikan dengan kebutuhan masing-masing kelompok pengguna (Prasetyo, Gunawan, & Akbar, 2023).

Klasifikasi merupakan salah satu teknik dalam data mining yang digunakan untuk mengelompokkan data ke dalam kelas tertentu berdasarkan karakteristik data yang dimiliki. Dalam proses klasifikasi, algoritma mempelajari pola dari data sebelumnya untuk menghasilkan model prediksi yang dapat digunakan pada data baru. Salah satu algoritma klasifikasi yang cukup populer dan banyak digunakan adalah Decision Tree. Algoritma ini bekerja dengan membentuk struktur pohon keputusan berdasarkan atribut-atribut tertentu sehingga menghasilkan aturan klasifikasi yang mudah dipahami dan diinterpretasikan (Sari & Hidayat, 2022). Decision Tree memiliki beberapa keunggulan dibandingkan algoritma klasifikasi lainnya, yaitu proses pengolahan data yang sederhana, visualisasi berupa pohon keputusan yang mudah dipahami, tingkat akurasi yang cukup baik, serta kemampuan menentukan atribut yang paling berpengaruh terhadap hasil prediksi (Rahman, Putra, & Wijaya, 2021).

Dalam penelitian ini, proses pengolahan data menggunakan aplikasi RapidMiner, salah satu perangkat lunak data mining yang banyak digunakan untuk analisis data, machine learning, dan predictive analytics. RapidMiner menyediakan berbagai fitur yang mendukung proses preprocessing data, penerapan algoritma klasifikasi, hingga evaluasi hasil model tanpa memerlukan kemampuan pemrograman yang kompleks, sehingga banyak digunakan dalam penelitian akademik maupun industri (Fauzi, Saputra, & Ramadhan, 2022).

Beberapa penelitian sebelumnya menunjukkan bahwa algoritma Decision Tree memiliki performa yang baik dalam proses klasifikasi data, baik pada data kesehatan (Rahman, Putra, & Wijaya, 2021) maupun data olahraga dan kebugaran (Sari & Hidayat,

2022), serta penggunaan RapidMiner dinilai mampu mempercepat proses pengolahan data dan evaluasi model secara efisien (Pratama, Kurniawan, & Sembiring, 2024). Penerapan algoritma Decision Tree pada data member gym diharapkan mampu menghasilkan model prediksi gender yang akurat berdasarkan atribut-atribut yang dimiliki member, sekaligus mengetahui atribut yang paling memengaruhi proses prediksi gender, sehingga dapat digunakan oleh pihak gym dalam menyusun strategi pelayanan dan program latihan yang lebih sesuai.

Dengan adanya penelitian ini, diharapkan pengelola gym dapat memanfaatkan data member secara lebih optimal dan tidak hanya menjadikannya sebagai arsip administrasi semata, serta dapat menjadi referensi bagi penelitian selanjutnya terkait penerapan algoritma klasifikasi dalam bidang olahraga, kesehatan, maupun sistem informasi berbasis data mining.

## METODE

Penelitian ini menggunakan metode kuantitatif dengan pendekatan data mining untuk memprediksi gender member gym menggunakan algoritma Decision Tree pada aplikasi RapidMiner. Jenis penelitian yang digunakan adalah penelitian eksperimen dengan pendekatan klasifikasi data, yang bertujuan mengetahui performa algoritma Decision Tree dalam mengelompokkan data ke dalam kategori gender laki-laki dan perempuan.

Data yang digunakan merupakan data member gym yang terdiri dari delapan atribut, yaitu usia, tinggi badan, berat badan, Body Mass Index (BMI), frekuensi latihan, durasi latihan, jenis aktivitas olahraga, dan gender. Gender digunakan sebagai label atau target klasifikasi, sedangkan atribut lainnya digunakan sebagai variabel prediktor dalam pembentukan model Decision Tree. Teknik pengumpulan data dilakukan melalui dokumentasi data member gym yang tersedia, yang kemudian disusun ke dalam format spreadsheet sebelum diimpor ke aplikasi RapidMiner untuk diproses dan dianalisis.

Proses penelitian dilakukan melalui enam tahapan yang tersusun secara sistematis. Tahap pertama adalah pengumpulan data member gym yang meliputi atribut fisik dan aktivitas latihan. Tahap kedua adalah preprocessing data, yang meliputi pembersihan data kosong (missing value), penghapusan data duplikat, transformasi data kategorikal, serta normalisasi data apabila diperlukan. Tahap ketiga adalah pembagian dataset menjadi data training untuk membangun model dan data testing untuk menguji performa model. Tahap keempat adalah penerapan algoritma Decision Tree menggunakan RapidMiner untuk membentuk model klasifikasi berdasarkan atribut data member gym. Tahap kelima adalah evaluasi model menggunakan confusion matrix dan accuracy, dan tahap terakhir adalah analisis hasil untuk mengetahui tingkat akurasi model serta atribut yang paling berpengaruh dalam proses prediksi gender.

Decision Tree merupakan algoritma klasifikasi yang bekerja dengan membentuk struktur pohon keputusan berdasarkan atribut data tertentu, di mana setiap cabang pada pohon merepresentasikan hasil keputusan dari atribut tertentu hingga menghasilkan kelas akhir. Tingkat ketidakpastian pada data dihitung menggunakan rumus entropy berikut.

$$Entropy(S) = – \Sigma\ pi\ log2\ pi \quad (1)$$

Selanjutnya, perhitungan gain digunakan untuk menentukan atribut terbaik dalam pembentukan pohon keputusan, sebagaimana rumus berikut.

$$Gain(S,A) = Entropy(S) – \Sigma\ (|Sv| / |S|)\ Entropy(Sv) \quad (2)$$

dengan S adalah himpunan kasus, A adalah atribut, Sv adalah subset data berdasarkan atribut, dan pi adalah probabilitas kelas ke-i.

Penelitian ini menggunakan dua perangkat lunak pendukung, yaitu RapidMiner yang digunakan untuk preprocessing data, penerapan algoritma Decision Tree, dan evaluasi model klasifikasi, serta Microsoft Excel yang digunakan untuk pengelolaan awal dataset sebelum diimpor ke RapidMiner. Tampilan proses implementasi algoritma pada RapidMiner disajikan pada Gambar 1.

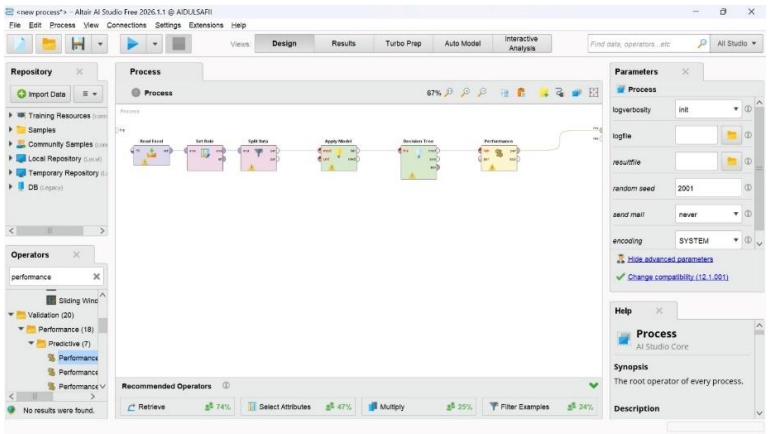

**Gambar 1. Tampilan Proses Implementasi Algoritma Decision Tree pada RapidMiner**

Evaluasi model dilakukan menggunakan confusion matrix untuk mengetahui performa klasifikasi algoritma Decision Tree. Tingkat akurasi dihitung menggunakan rumus berikut.

$$Accuracy = (TP + TN) / (TP + TN + FP + FN) \times 100\% \quad (3)$$

dengan TP (True Positive) adalah data positif yang diprediksi benar, TN (True Negative) adalah data negatif yang diprediksi benar, FP (False Positive) adalah data negatif yang diprediksi positif, dan FN (False Negative) adalah data positif yang diprediksi negatif. Semakin tinggi nilai accuracy yang diperoleh, semakin baik performa model Decision Tree dalam memprediksi gender member gym.

## HASIL DAN PEMBAHASAN

Penelitian ini menggunakan dataset member gym yang terdiri dari atribut usia, tinggi badan, berat badan, Body Mass Index (BMI), frekuensi latihan, durasi latihan, jenis aktivitas olahraga, dan gender. Sebelum dilakukan proses klasifikasi, data terlebih dahulu melalui tahap preprocessing yang meliputi pembersihan data kosong (missing value), penghapusan data duplikat, serta transformasi atribut kategorikal agar dapat diproses oleh algoritma Decision Tree. Hasil preprocessing menunjukkan bahwa dataset telah siap digunakan pada tahap pemodelan klasifikasi, kemudian dataset dibagi menjadi data training dan data testing untuk membangun serta menguji model klasifikasi.

Proses klasifikasi dilakukan menggunakan aplikasi RapidMiner dengan algoritma Decision Tree, melalui tahapan mengimpor dataset ke RapidMiner, menentukan atribut label yaitu gender, membagi data training dan testing, menghubungkan operator Decision Tree, serta melakukan pengujian model menggunakan operator Apply Model dan Performance. Model Decision Tree menghasilkan struktur pohon keputusan yang menunjukkan hubungan antar atribut dalam menentukan klasifikasi gender member gym, di mana atribut dengan nilai gain tertinggi menjadi root node atau akar pohon keputusan. Berdasarkan hasil pengolahan data, atribut yang paling berpengaruh dalam proses klasifikasi adalah BMI dan frekuensi latihan, yang menunjukkan bahwa pola aktivitas olahraga dan kondisi fisik member memiliki hubungan terhadap proses prediksi gender.

Pengujian model dilakukan menggunakan confusion matrix untuk mengetahui tingkat performa algoritma Decision Tree dalam memprediksi gender member gym, sebagaimana disajikan pada Tabel 1.

**Tabel 1. Hasil Confusion Matrix**

| Prediksi | Laki-laki | Perempuan |
|---|---|---|
| Laki-laki | 45 | 5 |
| Perempuan | 4 | 46 |

Berdasarkan confusion matrix tersebut diperoleh True Positive (TP) = 45, True Negative (TN) = 46, False Positive (FP) = 5, dan False Negative (FN) = 4, sehingga

perhitungan accuracy menggunakan rumus (3) menghasilkan nilai (45 + 46) / (45 + 46 + 5 + 4) x 100% = 91%. Nilai tersebut menunjukkan bahwa algoritma Decision Tree memiliki performa yang baik dalam melakukan prediksi gender member gym.

Tingginya nilai accuracy menunjukkan bahwa atribut-atribut yang digunakan dalam penelitian ini memiliki hubungan yang cukup kuat terhadap proses klasifikasi gender. Atribut BMI menjadi salah satu faktor yang paling berpengaruh dalam pembentukan pohon keputusan karena perbedaan karakteristik fisik antara laki-laki dan perempuan memengaruhi hasil pengelompokan data. Selain itu, frekuensi latihan juga memberikan pengaruh terhadap hasil klasifikasi karena pola aktivitas olahraga pada setiap gender memiliki kecenderungan yang berbeda. Keunggulan algoritma Decision Tree dalam penelitian ini terletak pada kemampuannya menghasilkan aturan keputusan yang mudah dipahami, sehingga dapat membantu pengelola gym memahami pola klasifikasi gender berdasarkan data member secara lebih jelas. Penggunaan RapidMiner juga mempermudah proses implementasi data mining karena menyediakan antarmuka visual yang mudah digunakan tanpa memerlukan pemrograman yang kompleks, sehingga seluruh proses mulai dari preprocessing hingga evaluasi model dapat dilakukan secara terintegrasi dalam satu platform.

Hasil penelitian ini sejalan dengan penelitian Rahman, Putra, dan Wijaya (2021) yang menyatakan bahwa algoritma Decision Tree memiliki tingkat akurasi yang baik dalam proses klasifikasi data, serta penelitian Nugraha dan Permata (2022) yang menunjukkan bahwa Decision Tree efektif digunakan pada klasifikasi data olahraga karena mampu menghasilkan model yang mudah diinterpretasikan. Meskipun tingkat accuracy sebesar 91% tergolong baik, masih terdapat beberapa kesalahan klasifikasi yang disebabkan oleh kemiripan karakteristik antar data member, yang dapat dipengaruhi oleh jumlah dataset yang terbatas, variasi atribut yang kurang lengkap, maupun adanya data dengan karakteristik hampir serupa antara laki-laki dan perempuan. Oleh karena itu, penelitian selanjutnya disarankan menggunakan jumlah dataset yang lebih besar, menambahkan atribut lain, serta membandingkan algoritma Decision Tree dengan algoritma klasifikasi lain seperti Naive Bayes, Random Forest, maupun Support Vector Machine (SVM) untuk mengetahui algoritma dengan performa terbaik dalam prediksi gender member gym.

## Pembahasan

### Karakteristik Dataset dan Relevansinya terhadap Proses Klasifikasi

Dataset yang digunakan dalam penelitian ini memadukan atribut demografis, antropometris, dan perilaku latihan. Usia menggambarkan tahapan perkembangan dan kemungkinan perbedaan pola aktivitas, sedangkan tinggi badan, berat badan, serta BMI merepresentasikan kondisi fisik member pada saat data dicatat. Frekuensi dan durasi latihan memberikan informasi mengenai intensitas keterlibatan member dalam kegiatan kebugaran, sementara jenis aktivitas olahraga menggambarkan preferensi latihan. Kombinasi atribut tersebut membuat proses klasifikasi tidak hanya bertumpu pada satu karakteristik, tetapi pada pola hubungan antarfaktor yang muncul di dalam dataset. Dalam konteks data mining, keberagaman atribut merupakan aspek penting karena model membutuhkan informasi yang cukup untuk membentuk batas keputusan. Han, Pei, dan Tong (2022) menjelaskan bahwa kualitas pola klasifikasi dipengaruhi oleh relevansi atribut, konsistensi data, dan kemampuan algoritma dalam memisahkan kelas. Oleh sebab itu, penggunaan atribut fisik dan aktivitas latihan dalam penelitian ini dapat dipahami sebagai upaya membangun representasi data member yang lebih komprehensif daripada hanya menggunakan satu variabel tunggal.

Meskipun demikian, relevansi suatu atribut harus dibaca secara kontekstual terhadap dataset penelitian. Temuan bahwa BMI dan frekuensi latihan menjadi atribut dominan tidak berarti bahwa kedua atribut tersebut secara universal menentukan gender seseorang. Hasil tersebut menunjukkan bahwa, pada data yang dianalisis, terdapat pola statistik yang membuat kedua atribut memberikan penurunan ketidakpastian paling besar ketika pohon keputusan dibentuk. Pola tersebut dapat dipengaruhi oleh komposisi sampel, kebiasaan latihan member, rentang usia, program yang tersedia di gym, maupun cara pencatatan data. Dengan demikian,

interpretasi hasil sebaiknya diarahkan pada karakteristik kelompok data, bukan pada generalisasi biologis atau sosial yang terlalu luas. Pendekatan ini penting agar hasil penelitian tetap berada dalam kerangka klasifikasi berbasis data dan tidak berubah menjadi pelabelan yang bersifat deterministik. Husein dan Rambe (2023) menekankan bahwa prediksi demografis menggunakan machine learning perlu mempertimbangkan konteks populasi karena model pada dasarnya mempelajari keteraturan yang terdapat dalam sampel pelatihan.

**Kontribusi Tahap Preprocessing terhadap Kualitas Model**

Tahap preprocessing memiliki posisi yang sangat menentukan karena Decision Tree tetap dapat menghasilkan aturan yang menyesatkan apabila data masukan mengandung nilai kosong, duplikasi, ketidakkonsistenan kategori, atau pencatatan ekstrem yang tidak diperiksa. Pembersihan missing value mencegah terbentuknya cabang berdasarkan data yang tidak lengkap, sedangkan penghapusan data duplikat mengurangi kemungkinan model memberikan bobot berlebihan pada pola yang sebenarnya hanya merupakan pengulangan pencatatan. Transformasi data kategorikal diperlukan agar jenis aktivitas olahraga dapat dikenali secara konsisten oleh perangkat lunak. Putri dan Syahril (2021) menjelaskan bahwa preprocessing bukan sekadar tahap administratif, tetapi bagian dari proses peningkatan kualitas informasi sebelum pemodelan dilakukan. Dalam penelitian ini, kesiapan dataset setelah preprocessing mendukung proses pembentukan pohon keputusan dan membantu memastikan bahwa nilai accuracy yang diperoleh berasal dari data yang telah melalui pemeriksaan awal.

Preprocessing juga perlu dipahami sebagai mekanisme pengendalian kualitas penelitian. Apabila kategori aktivitas ditulis dengan variasi ejaan yang berbeda, misalnya kategori yang sama dicatat menggunakan istilah yang tidak seragam, RapidMiner dapat memperlakukannya sebagai nilai yang berbeda. Hal tersebut berpotensi memecah data ke dalam kelompok kecil dan mengurangi stabilitas aturan. Demikian pula, kesalahan pengukuran tinggi atau berat badan dapat menghasilkan BMI yang tidak wajar dan mendorong pohon membuat pemisahan pada ambang yang tidak representatif. Oleh karena itu, dokumentasi mengenai jumlah data awal, jumlah data setelah pembersihan, aturan penanganan missing value, dan proses transformasi kategori akan memperkuat transparansi penelitian. Penjelasan yang lebih rinci juga memungkinkan penelitian direplikasi oleh peneliti lain. Praktik dokumentasi preprocessing sejalan dengan prinsip data mining yang menempatkan kualitas data sebagai fondasi utama sebelum algoritma dibandingkan atau dievaluasi (Han et al., 2022).

**Interpretasi Proses Pembentukan Pohon Keputusan**

Decision Tree membangun model dengan memilih atribut yang mampu memisahkan kelas secara paling informatif. Perhitungan entropy menggambarkan tingkat ketidakmurnian kelas, sedangkan information gain menunjukkan besarnya pengurangan ketidakpastian setelah data dipisahkan berdasarkan suatu atribut. Atribut dengan gain tertinggi ditempatkan pada bagian atas pohon karena memberikan pemisahan awal yang paling efektif. Setelah itu, proses yang sama diterapkan pada setiap subset hingga terbentuk daun keputusan. Keunggulan mekanisme ini adalah setiap prediksi dapat ditelusuri melalui rangkaian aturan yang jelas. Pengelola atau peneliti dapat melihat atribut apa yang digunakan, ambang pemisahan yang dipilih, serta jalur yang mengarahkan data ke kelas akhir. Kurniawan dan Saputri (2023) menyatakan bahwa keterbacaan aturan menjadi salah satu alasan Decision Tree banyak digunakan pada penelitian klasifikasi yang membutuhkan interpretasi model.

Dalam penelitian ini, dominasi BMI dan frekuensi latihan dapat dijelaskan melalui kemampuan kedua atribut tersebut dalam mengurangi campuran kelas pada node tertentu. Apabila suatu rentang BMI dan pola frekuensi latihan lebih banyak ditempati salah satu kelas dalam data training, algoritma akan menggunakan informasi itu untuk memisahkan data. Akan tetapi, aturan tersebut tetap bersifat probabilistik karena terdapat kemungkinan member dengan karakteristik serupa berasal dari kelas yang berbeda. Hal ini terlihat dari masih adanya sembilan kesalahan klasifikasi. Dengan demikian, pohon keputusan sebaiknya dibaca sebagai

representasi pola mayoritas, bukan aturan mutlak. Visualisasi pohon lengkap, termasuk nilai split, jumlah data pada setiap node, dan distribusi kelas pada daun, akan memperkaya analisis karena pembaca dapat menilai apakah suatu keputusan didukung oleh jumlah sampel yang memadai atau hanya oleh kelompok data yang kecil.

**Makna Atribut BMI dalam Model**

BMI merupakan indeks yang diperoleh dari hubungan berat badan dan kuadrat tinggi badan. Dalam konteks dataset gym, atribut ini merangkum dua variabel fisik menjadi satu indikator numerik sehingga dapat membantu algoritma menemukan pemisahan yang lebih ringkas. Ketika BMI ditempatkan sebagai atribut penting, hal tersebut menunjukkan bahwa kombinasi berat dan tinggi memberikan informasi klasifikasi yang lebih kuat dibandingkan apabila keduanya dibaca secara terpisah pada sebagian cabang. Temuan ini sejalan dengan pemanfaatan atribut antropometris dalam analisis kesehatan dan kebugaran yang dikemukakan oleh Hidayati dan Lestari (2021). Namun, BMI memiliki keterbatasan karena tidak membedakan massa otot dan massa lemak, sehingga dua member dengan BMI sama dapat memiliki komposisi tubuh yang berbeda. Kondisi tersebut sangat relevan pada populasi gym karena sebagian member melakukan latihan pembentukan otot.

Oleh sebab itu, hasil penelitian tidak seharusnya menempatkan BMI sebagai ukuran tunggal untuk memahami karakteristik member. Dalam penerapan yang lebih luas, BMI dapat dilengkapi dengan persentase lemak tubuh, lingkar tubuh, massa otot, tujuan latihan, lama menjadi member, dan riwayat aktivitas fisik. Penambahan atribut tersebut berpotensi membantu model membedakan data yang saat ini masih tumpang tindih. Selain itu, analisis nilai ambang BMI yang digunakan pada pohon perlu dilakukan untuk memastikan bahwa split tidak muncul hanya karena karakteristik sampel tertentu. Pengujian pada data dari gym lain akan menunjukkan apakah pola tersebut konsisten atau berubah ketika populasi, fasilitas, dan program latihan berbeda. Dengan demikian, kontribusi BMI dalam penelitian ini dapat dipandang sebagai temuan awal yang kuat pada dataset yang tersedia, tetapi masih membutuhkan pengujian eksternal sebelum dijadikan dasar generalisasi.

**Makna Frekuensi dan Durasi Latihan**

Frekuensi latihan menjadi atribut dominan berikutnya karena mencerminkan seberapa sering member terlibat dalam aktivitas kebugaran selama periode tertentu. Variabel ini dapat berhubungan dengan tujuan latihan, kebiasaan, ketersediaan waktu, serta tingkat komitmen terhadap program gym. Dalam pohon keputusan, frekuensi berfungsi sebagai pembeda perilaku yang melengkapi informasi fisik dari BMI. Kombinasi keduanya memungkinkan model membentuk aturan yang menghubungkan kondisi tubuh dan pola latihan. Sari dan Hidayat (2022) serta Nugraha dan Permata (2022) menunjukkan bahwa data aktivitas olahraga dapat diklasifikasikan secara efektif ketika atribut perilaku dan kondisi fisik dianalisis bersama. Hasil penelitian ini memperkuat pandangan tersebut karena model tidak hanya mengandalkan atribut demografis, tetapi memanfaatkan pola aktivitas aktual yang tercatat pada member.

Durasi latihan tetap memiliki nilai analitis walaupun tidak dilaporkan sebagai atribut paling dominan. Frekuensi tinggi tidak selalu berarti volume latihan yang tinggi apabila setiap sesi berlangsung singkat, sedangkan frekuensi rendah dapat disertai durasi sesi yang panjang. Karena itu, interaksi antara frekuensi dan durasi berpotensi menghasilkan informasi yang lebih bermakna daripada melihat masing-masing variabel secara terpisah. Penelitian lanjutan dapat membentuk atribut turunan berupa total menit latihan per minggu, konsistensi kehadiran bulanan, atau variasi jenis latihan. Atribut turunan tersebut memungkinkan model menangkap beban aktivitas secara lebih utuh. Penggunaan data longitudinal juga akan memperlihatkan apakah pola latihan stabil atau hanya mencerminkan kondisi sesaat ketika dataset dikumpulkan.

**Analisis Confusion Matrix dan Keseimbangan Prediksi**

Confusion matrix memberikan informasi yang lebih rinci daripada accuracy karena menunjukkan posisi kesalahan pada masing-masing kelas. Berdasarkan matriks yang dilaporkan, terdapat 45 data laki-laki yang diklasifikasikan dengan benar dan 46 data

perempuan yang diklasifikasikan dengan benar. Sebanyak lima data masuk ke kategori false positive dan empat data masuk ke kategori false negative. Jumlah prediksi benar mencapai 91 dari total 100 data pengujian, sehingga accuracy model adalah 91%. Distribusi kesalahan yang relatif seimbang menunjukkan bahwa model tidak hanya berhasil pada salah satu kelas. Wijaya dan Fadillah (2024) menjelaskan bahwa confusion matrix membantu peneliti menilai apakah accuracy tinggi disertai kemampuan klasifikasi yang proporsional pada setiap kelas.

Berdasarkan angka tersebut, precision untuk kelas positif dapat dihitung sebesar 45/(45+5) atau 90%, sedangkan recall sebesar 45/(45+4) atau sekitar 91,84%. Nilai F1-score yang menggabungkan precision dan recall berada di sekitar 90,91%. Specificity terhadap kelas negatif adalah 46/(46+5) atau sekitar 90,20%, sedangkan balanced accuracy berada di sekitar 91,02%. Perhitungan tambahan ini memperlihatkan bahwa performa kedua kelas cukup konsisten dan tidak ada perbedaan ekstrem antara kemampuan mengenali kelas positif dan kelas negatif. Walaupun metrik tersebut belum dicantumkan sebagai hasil utama, pembahasannya membantu memberikan gambaran evaluasi yang lebih lengkap. Pada penelitian berikutnya, RapidMiner dapat digunakan untuk melaporkan precision, recall, F1-score, area under the curve, dan nilai kappa agar kualitas model tidak hanya dinilai dari satu indikator.

**Analisis Kesalahan Klasifikasi**

Sembilan kesalahan klasifikasi merupakan bagian penting yang perlu dianalisis karena data yang salah diprediksi dapat menunjukkan batas kemampuan model. Kesalahan tersebut dapat muncul ketika karakteristik fisik dan pola latihan antarkelas saling tumpang tindih. Seorang member dapat memiliki BMI, frekuensi, durasi, dan jenis latihan yang sangat mirip dengan member dari kelas lain, sehingga pohon keputusan tidak memperoleh informasi yang cukup untuk membedakannya. Selain itu, split pada Decision Tree bersifat tegas; data yang berada sedikit di bawah dan sedikit di atas ambang dapat diarahkan ke cabang berbeda meskipun karakteristiknya hampir sama. Situasi ini menjelaskan mengapa model yang mudah diinterpretasikan tetap dapat menghasilkan kesalahan pada area perbatasan kelas.

Analisis error dapat dilakukan dengan menelusuri sembilan data tersebut dan membandingkan jalur keputusan yang dilewati. Peneliti dapat mengidentifikasi apakah kesalahan terkonsentrasi pada rentang BMI tertentu, pada member dengan frekuensi latihan menengah, atau pada jenis aktivitas yang jumlah datanya sedikit. Informasi ini akan membantu menentukan atribut tambahan yang paling diperlukan. Apabila kesalahan banyak terjadi pada member dengan BMI tinggi karena massa otot, misalnya, penambahan persentase lemak dan massa otot menjadi relevan. Jika kesalahan muncul pada kategori aktivitas yang heterogen, kategori tersebut dapat didefinisikan ulang secara lebih spesifik. Dengan demikian, error bukan sekadar kekurangan model, tetapi sumber informasi untuk memperbaiki desain dataset dan eksperimen berikutnya.

**Interpretasi Accuracy Sebesar 91 Persen**

Accuracy 91% menunjukkan bahwa Decision Tree mampu mengenali sebagian besar pola dalam data testing. Nilai ini tergolong baik untuk menunjukkan kelayakan awal model pada dataset penelitian. Hasil tersebut sejalan dengan penelitian Rahman, Putra, dan Wijaya (2021) yang menemukan bahwa Decision Tree dapat memberikan performa klasifikasi yang baik pada data kesehatan, serta Nugraha dan Permata (2022) pada data aktivitas olahraga. Meskipun demikian, accuracy harus dibaca bersama desain evaluasi. Nilai performa dapat berubah bergantung pada rasio pembagian data training dan testing, proses pengacakan, jumlah sampel, distribusi kelas, serta parameter pohon. Oleh karena itu, accuracy 91% merupakan performa pada konfigurasi eksperimen yang digunakan, bukan jaminan bahwa model akan selalu mencapai angka yang sama pada seluruh populasi member gym.

Keseimbangan jumlah kelas pada data testing memberi konteks yang baik bagi nilai accuracy. Berdasarkan confusion matrix, total data aktual pada masing-masing kelas relatif seimbang, sehingga accuracy tidak tampak didominasi oleh kelas mayoritas. Namun, pemeriksaan distribusi kelas pada keseluruhan dataset tetap diperlukan. Jika data training

tidak seimbang, pohon dapat membentuk aturan yang lebih menguntungkan kelas tertentu meskipun data testing terlihat seimbang. Penggunaan stratified sampling dapat membantu mempertahankan proporsi kelas pada proses pembagian data. Selain itu, pengujian berulang atau cross-validation akan menghasilkan estimasi performa yang lebih stabil daripada satu kali pembagian. Pratama, Kurniawan, dan Sembiring (2024) menekankan pentingnya perbandingan performa dengan skema evaluasi yang konsisten agar kesimpulan antaralgoritma dapat dipertanggungjawabkan.

**Kelebihan Interpretabilitas Decision Tree**

Salah satu kontribusi penting Decision Tree adalah kemampuannya menghasilkan aturan yang mudah dipahami oleh pengguna nonteknis. Dalam konteks pengelolaan gym, hasil klasifikasi tidak hanya berupa label, tetapi dapat dijelaskan melalui jalur atribut yang digunakan. Transparansi tersebut berbeda dengan beberapa model yang menghasilkan prediksi tanpa aturan yang mudah ditelusuri. Interpretabilitas bermanfaat ketika model digunakan untuk eksplorasi pola data, karena pengelola dapat memahami hubungan yang ditemukan dan menilai apakah pola tersebut masuk akal secara operasional. Kurniawan dan Saputri (2023) menyebutkan bahwa model prediktif yang dapat dijelaskan lebih mudah diterima oleh pengguna karena alasan di balik keputusan dapat dikomunikasikan.

Namun, interpretabilitas tidak berarti bahwa seluruh aturan otomatis benar secara substantif. Pohon hanya menggambarkan pola yang memaksimalkan pemisahan kelas pada data. Aturan dapat berubah apabila sampel bertambah, distribusi member bergeser, atau parameter seperti kedalaman maksimum dan minimal jumlah data pada daun diubah. Pohon yang terlalu dalam berisiko menghafal data training atau overfitting, sedangkan pohon yang terlalu dangkal dapat kehilangan pola penting atau underfitting. Oleh karena itu, pengaturan pruning, minimal leaf size, dan kriteria penghentian perlu dilaporkan. Visualisasi pohon yang telah dipangkas juga sebaiknya dipilih agar keseimbangan antara accuracy dan kesederhanaan model dapat dinilai.

**Peran RapidMiner dalam Reproduksibilitas Analisis**

RapidMiner memberikan lingkungan berbasis operator yang memudahkan rangkaian analisis disusun secara visual. Dataset dapat dihubungkan dengan operator preprocessing, pembagian data, pembentukan Decision Tree, Apply Model, dan Performance dalam satu alur. Keuntungan pendekatan tersebut adalah setiap tahap dapat diamati dan disimpan sebagai proses yang dapat dijalankan ulang. Fauzi, Saputra, dan Ramadhan (2022) serta Sembiring dan Andriani (2022) menjelaskan bahwa penggunaan RapidMiner membantu integrasi pemrosesan data dan evaluasi model tanpa menuntut penulisan kode yang kompleks. Hal ini relevan bagi penelitian terapan karena peneliti dapat lebih fokus pada pemilihan data, desain eksperimen, dan interpretasi hasil.

Walaupun antarmuka visual memudahkan implementasi, reproduksibilitas tetap bergantung pada dokumentasi parameter. Penelitian sebaiknya mencantumkan versi RapidMiner, rasio training-testing, metode sampling, random seed, kriteria Decision Tree, maksimal kedalaman, minimal gain, pruning, dan penanganan missing value. Tanpa parameter tersebut, peneliti lain mungkin memperoleh pohon dan accuracy yang berbeda meskipun menggunakan dataset sama. Penyimpanan file proses RapidMiner dan kamus data juga akan meningkatkan keterlacakan penelitian. Dalam pengembangan lanjutan, hasil RapidMiner dapat dibandingkan dengan implementasi menggunakan Python atau perangkat lain untuk memastikan bahwa pola yang ditemukan tidak bergantung pada satu platform.

**Implikasi bagi Pengelolaan dan Pelayanan Gym**

Hasil klasifikasi dapat memberikan pemahaman awal mengenai pola member yang tersimpan dalam basis data gym. Dari sudut pandang pengelolaan, analisis data dapat mendorong perubahan dari pencatatan administratif menjadi pemanfaatan informasi untuk perencanaan layanan. Pengelola dapat mengevaluasi distribusi aktivitas, frekuensi kehadiran, kebutuhan fasilitas, dan respons terhadap program latihan. Wibowo dan Nugroho (2021) menunjukkan bahwa analisis data pelanggan pusat kebugaran dapat membantu pemahaman

karakteristik pengguna. Namun, manfaat utama penelitian ini bukan sekadar menebak gender, melainkan menunjukkan bahwa data operasional gym dapat diolah menjadi pola yang terukur.

Penerapan praktis sebaiknya diarahkan pada kebutuhan yang langsung memberikan nilai bagi member, misalnya rekomendasi jadwal kelas, pengingat latihan, analisis risiko berhenti berlangganan, segmentasi berdasarkan tujuan kebugaran, dan evaluasi efektivitas program. Gender dapat menjadi salah satu variabel deskriptif apabila dikumpulkan secara sah dan sukarela, tetapi keputusan layanan sebaiknya lebih banyak didasarkan pada tujuan, kemampuan fisik, preferensi, riwayat kesehatan, dan respons latihan individu. Pendekatan tersebut lebih mendukung personalisasi dan menghindari asumsi bahwa seluruh member dalam satu gender memiliki kebutuhan yang sama. Prasetyo, Gunawan, dan Akbar (2023) menegaskan bahwa predictive analytics pada perilaku member gym dapat digunakan untuk memahami kebutuhan pengguna secara lebih terarah.

**Personalisasi Program Latihan dan Batas Penggunaan Model**

Model klasifikasi dapat menjadi titik awal untuk mengenali pola, tetapi tidak layak digunakan sebagai satu-satunya dasar penyusunan program latihan. Program kebugaran memerlukan pertimbangan kondisi kesehatan, tujuan latihan, pengalaman, kapasitas fisik, potensi cedera, dan preferensi member. Atribut yang tersedia dalam penelitian belum mencakup seluruh faktor tersebut. Oleh karena itu, hasil Decision Tree sebaiknya diposisikan sebagai informasi pendukung bagi pengelola atau instruktur, bukan sebagai pengganti asesmen profesional. Penggunaan model secara hati-hati akan mencegah interpretasi berlebihan terhadap accuracy 91%.

Keterbatasan penggunaan juga terlihat dari tujuan prediksi gender itu sendiri. Dalam basis data nyata, gender biasanya dapat diperoleh langsung melalui data registrasi apabila memang diperlukan dan pengguna menyetujuinya. Dengan demikian, nilai ilmiah penelitian lebih kuat pada demonstrasi proses klasifikasi, identifikasi atribut penting, dan evaluasi Decision Tree dibandingkan kebutuhan operasional untuk menebak identitas. Penelitian berikutnya dapat mengalihkan target ke variabel yang lebih bermanfaat dan tidak sensitif, seperti tingkat keaktifan, potensi perpanjangan membership, pilihan kelas, atau keberhasilan mencapai target latihan. Dataset dan alur eksperimen yang sama dapat disesuaikan untuk menjawab persoalan tersebut.

**Privasi, Etika, dan Potensi Bias**

Data tinggi badan, berat badan, BMI, pola latihan, dan gender termasuk informasi pribadi yang perlu dilindungi. Pengumpulan dan analisis data harus dilakukan berdasarkan tujuan yang jelas, persetujuan yang memadai, pembatasan akses, serta penyimpanan yang aman. Identitas member sebaiknya dianonimkan sebelum data diimpor ke RapidMiner. Hasil prediksi juga tidak boleh digunakan untuk mempermalukan, mendiskriminasi, atau membatasi akses layanan. Prinsip minimisasi data penting diterapkan, yaitu hanya menggunakan atribut yang benar-benar diperlukan untuk tujuan penelitian.

Potensi bias dapat muncul apabila dataset tidak mewakili keragaman populasi member. Gym tertentu mungkin memiliki lokasi, biaya, jenis fasilitas, atau kelompok pelanggan yang spesifik. Model yang dilatih pada satu tempat dapat merefleksikan pola lokal dan memberikan performa lebih rendah ketika diterapkan pada tempat lain. Selain itu, penggunaan kategori gender yang terbatas pada dua kelas tidak menangkap keragaman identitas gender dan dapat menimbulkan persoalan etis jika hasil diperlakukan sebagai penentuan identitas. Oleh karena itu, model harus dipahami sebagai eksperimen klasifikasi pada label dataset, bukan alat untuk menetapkan identitas seseorang. Evaluasi fairness dapat dilakukan dengan memeriksa distribusi kesalahan pada kelompok usia, rentang BMI, dan jenis aktivitas yang berbeda.

**Validitas, Generalisasi, dan Kebutuhan Cross-Validation**

Generalisasi menunjukkan kemampuan model mempertahankan performa pada data baru yang tidak digunakan dalam pelatihan. Pembagian training dan testing merupakan langkah dasar untuk mengukur kemampuan tersebut, tetapi satu kali pembagian dapat

menghasilkan estimasi yang sensitif terhadap komposisi data. Apabila beberapa pola penting kebetulan lebih banyak masuk ke data training, accuracy dapat meningkat; sebaliknya, jika kasus sulit terkonsentrasi di data testing, accuracy dapat menurun. Cross-validation membagi data ke beberapa fold dan mengulangi proses pelatihan-pengujian sehingga setiap data memperoleh kesempatan menjadi data uji. Nilai rata-rata dan variasi performa dari seluruh fold akan memberikan gambaran stabilitas model yang lebih kuat.

Untuk dataset berukuran terbatas, stratified k-fold cross-validation dapat dipertimbangkan agar proporsi laki-laki dan perempuan tetap seimbang pada setiap fold. Selain rata-rata accuracy, penelitian perlu melaporkan standar deviasi, precision, recall, dan F1-score. Apabila variasi antar-fold kecil, model dapat dianggap relatif stabil; apabila variasinya besar, diperlukan penambahan data atau penyederhanaan pohon. Validasi eksternal menggunakan dataset dari gym berbeda menjadi langkah berikutnya untuk menguji apakah BMI dan frekuensi latihan tetap menjadi atribut dominan. Tanpa pengujian eksternal, kesimpulan sebaiknya dibatasi pada dataset penelitian.

**Perbandingan dengan Algoritma Klasifikasi Lain**

Decision Tree dipilih karena sederhana dan interpretatif, tetapi belum dapat disimpulkan sebagai algoritma terbaik sebelum dibandingkan dengan model lain menggunakan data dan skema evaluasi yang sama. Naive Bayes dapat memberikan baseline yang cepat, Support Vector Machine dapat membentuk batas keputusan yang lebih kompleks, sedangkan Random Forest dapat mengurangi ketergantungan pada satu pohon melalui penggabungan banyak pohon. Pratama, Kurniawan, dan Sembiring (2024) menunjukkan bahwa perbandingan algoritma menggunakan RapidMiner membantu menilai perbedaan performa secara sistematis. Penelitian lanjutan dapat membandingkan accuracy, precision, recall, F1-score, waktu proses, dan interpretabilitas.

Random Forest mungkin memberikan performa lebih stabil ketika hubungan atribut kompleks, tetapi interpretasinya tidak sesederhana satu Decision Tree. SVM dapat efektif pada pemisahan tertentu, tetapi membutuhkan penyesuaian parameter dan normalisasi yang lebih hati-hati. Naive Bayes mudah diterapkan, namun asumsi independensi antaratribut dapat kurang sesuai karena berat badan, tinggi badan, dan BMI saling berkaitan. Dengan demikian, pemilihan algoritma seharusnya mempertimbangkan keseimbangan antara performa, kebutuhan penjelasan, jumlah data, dan tujuan penggunaan. Decision Tree tetap memiliki nilai penting sebagai model dasar yang transparan dan mudah diaudit.

**Pengembangan Atribut dan Desain Dataset**

Kualitas penelitian berikutnya dapat ditingkatkan melalui penambahan atribut yang lebih relevan terhadap perilaku member. Atribut tersebut dapat mencakup lama keanggotaan, jumlah kunjungan per bulan, tujuan latihan, preferensi kelas, waktu latihan, riwayat cedera, status keanggotaan aktif, dan perubahan ukuran tubuh. Data longitudinal memungkinkan analisis perubahan dari waktu ke waktu, sedangkan dataset saat ini lebih menggambarkan kondisi pada titik pencatatan tertentu. Lubis dan Harahap (2022) menjelaskan bahwa data sistem informasi olahraga dapat memberikan nilai lebih besar ketika variabel aktivitas dicatat secara konsisten dan dianalisis sebagai rangkaian perilaku.

Definisi operasional setiap atribut juga perlu dibuat jelas. Frekuensi latihan harus memiliki satuan waktu tertentu, durasi perlu dinyatakan dalam menit per sesi atau total per minggu, dan jenis aktivitas harus menggunakan kategori yang konsisten. BMI sebaiknya dihitung otomatis dari tinggi dan berat untuk mengurangi kesalahan input. Proses validasi dapat menandai nilai di luar rentang wajar sebelum data digunakan. Dengan desain data yang lebih baik, penelitian tidak hanya meningkatkan accuracy, tetapi juga menghasilkan aturan yang lebih mudah ditafsirkan dan digunakan secara bertanggung jawab.

**Keterbatasan Penelitian**

Penelitian ini memiliki beberapa keterbatasan yang perlu dinyatakan secara eksplisit. Pertama, jumlah dan sumber dataset belum dijelaskan secara rinci, sehingga representativitas populasi member belum dapat dinilai sepenuhnya. Kedua, evaluasi masih berfokus pada

accuracy dan satu confusion matrix, sedangkan metrik lain dan variasi performa belum dilaporkan. Ketiga, parameter Decision Tree dan rasio pembagian data belum dijabarkan secara lengkap. Keempat, atribut yang digunakan masih terbatas sehingga tidak seluruh variasi karakteristik member dapat ditangkap. Kelima, target prediksi berupa gender merupakan variabel sensitif dan manfaat operasionalnya perlu dipertimbangkan secara hati-hati.

Keterbatasan tersebut tidak menghilangkan kontribusi penelitian sebagai implementasi awal Decision Tree menggunakan RapidMiner. Justru, identifikasi keterbatasan membantu menempatkan hasil secara proporsional. Accuracy 91% menunjukkan potensi model pada data yang digunakan, sementara analisis tambahan diperlukan untuk menilai stabilitas dan generalisasi. Dengan menambahkan dokumentasi dataset, cross-validation, metrik evaluasi lengkap, uji pembanding, dan pembahasan etika, penelitian selanjutnya dapat menghasilkan kesimpulan yang lebih kuat.

**Arah Penelitian Selanjutnya**

Penelitian selanjutnya disarankan menggunakan dataset yang lebih besar dan berasal dari beberapa pusat kebugaran agar variasi populasi meningkat. Penggunaan stratified cross-validation dapat memberikan evaluasi yang lebih stabil. Decision Tree dapat dibandingkan dengan Naive Bayes, Random Forest, SVM, k-Nearest Neighbor, dan model boosting. Proses tuning parameter juga dapat dilakukan untuk menemukan kedalaman pohon, minimal gain, dan pruning yang menghasilkan keseimbangan terbaik antara accuracy dan kompleksitas. Selain itu, analisis feature importance dapat dilengkapi dengan permutation importance untuk menilai konsistensi kontribusi atribut.

Target klasifikasi dapat dikembangkan ke permasalahan yang lebih relevan bagi layanan gym, seperti prediksi churn member, tingkat keaktifan, pilihan program, risiko tidak mencapai target, atau rekomendasi kelas. Pengembangan tersebut tetap perlu memperhatikan privasi dan menghindari keputusan otomatis yang merugikan member. Dashboard analitik dapat dibangun agar pengelola melihat tren agregat tanpa mengakses identitas individu. Dengan demikian, penerapan data mining tidak hanya menghasilkan model dengan nilai accuracy tinggi, tetapi juga memberikan manfaat layanan yang nyata dan bertanggung jawab.

**Sensitivitas Model terhadap Perubahan Distribusi Data**

Model klasifikasi yang diterapkan pada lingkungan operasional akan menghadapi perubahan distribusi data dari waktu ke waktu. Komposisi member dapat berubah akibat promosi, pembukaan kelas baru, perubahan harga keanggotaan, tren olahraga, atau pergantian lokasi. Perubahan tersebut dapat menyebabkan pola BMI, frekuensi latihan, durasi, dan aktivitas tidak lagi sama dengan data yang digunakan saat model dibangun. Fenomena ini dikenal sebagai data drift. Apabila model tetap digunakan tanpa evaluasi, accuracy dapat menurun meskipun proses teknis aplikasi tidak mengalami kesalahan. Oleh karena itu, hasil 91% perlu dipandang sebagai titik awal yang harus dipantau, bukan performa permanen. Pengelola dapat menetapkan evaluasi berkala, misalnya setiap beberapa bulan atau setelah jumlah data baru mencapai batas tertentu, untuk membandingkan confusion matrix terbaru dengan hasil awal.

Analisis sensitivitas juga dapat dilakukan dengan mengubah rasio data training dan testing, random seed, serta parameter pohon. Apabila BMI dan frekuensi latihan tetap muncul sebagai atribut utama pada berbagai konfigurasi, temuan dapat dianggap lebih stabil. Sebaliknya, apabila root node sering berubah, hal tersebut menunjukkan bahwa struktur pohon sensitif terhadap komposisi sampel. Penggunaan bootstrap atau repeated cross-validation dapat membantu mengukur konsistensi pemilihan atribut. Selain itu, distribusi nilai pada data baru harus dibandingkan dengan distribusi data pelatihan. Rentang usia, BMI, atau frekuensi yang berada jauh di luar data awal sebaiknya ditandai karena prediksi pada wilayah tersebut merupakan ekstrapolasi yang kurang dapat dipercaya. Pendekatan ini membuat

penggunaan model lebih terkontrol dan mengurangi risiko keputusan berdasarkan pola yang sudah tidak relevan.

**Kesiapan Implementasi dan Pemeliharaan Model**

Sebelum model digunakan di lingkungan gym, diperlukan tahapan implementasi yang memisahkan eksperimen penelitian dari sistem operasional. Dataset harus disimpan dalam format yang konsisten, proses perhitungan BMI perlu distandardisasi, dan kategori aktivitas harus menggunakan kode yang sama dengan data training. Model kemudian dapat ditempatkan sebagai modul analitik yang menghasilkan prediksi atau ringkasan pola. Setiap prediksi sebaiknya disertai informasi versi model dan tanggal pemrosesan agar dapat diaudit. Log sistem perlu mencatat data masukan, keluaran, serta kemungkinan kesalahan tanpa menyimpan informasi pribadi secara berlebihan. Penerapan tersebut memungkinkan pengelola mengevaluasi apakah model bekerja sesuai desain dan mengetahui kapan pembaruan diperlukan.

Pemeliharaan model meliputi penambahan data baru, pemeriksaan kualitas, pelatihan ulang, pengujian, dan persetujuan sebelum versi baru digunakan. Perubahan model tidak hanya dinilai berdasarkan peningkatan accuracy, tetapi juga kestabilan precision dan recall, kesederhanaan aturan, serta dampak terhadap kelompok data yang berbeda. Model baru harus dibandingkan dengan model lama pada dataset uji yang sama. Jika peningkatan performa sangat kecil tetapi struktur pohon menjadi jauh lebih kompleks, model lama mungkin lebih sesuai karena lebih mudah dijelaskan. Dokumentasi perubahan, parameter, dan alasan pemilihan versi akan membantu tata kelola sistem. Dengan demikian, penelitian dapat berkembang dari eksperimen satu kali menjadi siklus analitik yang terukur, transparan, dan dapat dipertanggungjawabkan.

**Penyajian Hasil kepada Pengguna Nonteknis**

Nilai accuracy dan confusion matrix perlu diterjemahkan ke dalam bahasa yang mudah dipahami pengelola gym. Pernyataan bahwa accuracy mencapai 91% dapat dijelaskan sebagai 91 prediksi benar dari 100 data uji, sedangkan sembilan data lainnya salah diklasifikasikan. Penjelasan tersebut mencegah anggapan bahwa model selalu benar. Visualisasi dapat menampilkan jumlah prediksi benar dan salah, atribut yang paling sering digunakan, serta contoh jalur keputusan tanpa membuka identitas member. Diagram pohon sebaiknya disederhanakan agar node utama dan aturan penting terlihat jelas. Penyajian yang baik akan membantu pengguna memahami manfaat sekaligus batas model.

Komunikasi hasil juga harus membedakan antara hubungan statistik dan hubungan sebab-akibat. Temuan BMI dan frekuensi latihan sebagai atribut dominan tidak membuktikan bahwa kedua variabel menyebabkan gender, melainkan menunjukkan bahwa keduanya membantu pemisahan kelas dalam dataset. Perbedaan ini penting agar hasil tidak disalahgunakan. Laporan kepada pengelola dapat menekankan bahwa model digunakan untuk eksplorasi data dan evaluasi metode, bukan untuk menetapkan identitas. Apabila analisis dikembangkan ke target yang lebih relevan seperti churn atau keaktifan, dashboard dapat menyajikan tingkat risiko bersama faktor pendukung dan rekomendasi tindak lanjut yang tetap memerlukan penilaian manusia. Pendekatan human-in-the-loop menjaga agar keputusan akhir tidak sepenuhnya diserahkan kepada algoritma.

**Kontribusi Keseluruhan Penelitian**

Secara keseluruhan, penelitian menunjukkan bahwa Decision Tree dapat diterapkan melalui RapidMiner untuk mengklasifikasikan data member gym dengan performa yang baik. Accuracy 91%, jumlah kesalahan yang relatif seimbang, serta munculnya BMI dan frekuensi latihan sebagai atribut dominan memberikan bukti bahwa dataset memuat pola yang dapat dipelajari. Kekuatan utama penelitian terletak pada alur yang mudah dipahami, mulai dari preprocessing, pembentukan model, visualisasi pohon, hingga evaluasi confusion matrix. Hasil tersebut mendukung penelitian terdahulu mengenai efektivitas Decision Tree pada data kesehatan, olahraga, dan perilaku pengguna (Rahman et al., 2021; Sari & Hidayat, 2022; Sembiring & Andriani, 2022).

Kontribusi penelitian juga terletak pada dorongan untuk memanfaatkan data member secara lebih analitis. Namun, nilai model harus dibaca dalam batas dataset, desain evaluasi, dan tujuan penggunaan. Model tidak boleh dipakai sebagai penentu identitas atau sebagai dasar diskriminasi layanan. Dengan validasi yang lebih kuat, atribut yang lebih relevan, dokumentasi parameter, dan perlindungan data, pendekatan yang dikembangkan dapat menjadi dasar bagi sistem analitik kebugaran yang lebih luas. Pembahasan ini menegaskan bahwa keberhasilan data mining bukan hanya ditentukan oleh tingginya accuracy, tetapi juga oleh kualitas data, interpretabilitas, generalisasi, etika, dan manfaat nyata bagi pengguna.

## SIMPULAN

Penelitian ini membuktikan bahwa algoritma Decision Tree efektif digunakan untuk memprediksi gender member gym berdasarkan atribut usia, tinggi badan, berat badan, BMI, frekuensi latihan, dan durasi latihan, dengan menghasilkan tingkat accuracy sebesar 91% melalui pengujian confusion matrix pada aplikasi RapidMiner. Atribut BMI dan frekuensi latihan terbukti paling berpengaruh dalam pembentukan pohon keputusan. Pengelola gym disarankan memanfaatkan hasil klasifikasi ini untuk menyusun program latihan dan strategi pelayanan yang lebih sesuai dengan karakteristik member. Penelitian selanjutnya disarankan menambah jumlah dataset dan atribut, serta membandingkan Decision Tree dengan algoritma lain seperti Naive Bayes atau Random Forest.

## UCAPAN TERIMA KASIH

Penelitian ini tidak menerima pendanaan khusus dari lembaga manapun. Penulis mengucapkan terima kasih kepada Program Studi Magister Teknologi Informasi, Universitas Pembangunan Panca Budi, Medan, atas dukungan fasilitas yang diberikan selama penelitian ini berlangsung.

## DAFTAR PUSTAKA

Amin, M., Rizal, C., & Muslem, I. (2025). Development Of Multimodal Generative AI Models For Adaptive Education Personalization In The Era Of Quantum Machine Learning.

Fauzi, M., Saputra, E., & Ramadhan, R. (2022). Data Mining Implementation Using Rapidminer For Predictive Analysis. Procedia Computer Science, 216, 451–458. DOI: 10.1016/J.Procs.2022.12.158

Han, J., Pei, J., & Tong, H. (2022). Data Mining: Concepts And Techniques. Morgan Kaufmann. DOI: 10.1016/C2019-0-03254-0

Hidayati, S., & Lestari, P. (2021). Application Of Machine Learning In Health And Fitness Industry. Journal Of Physics: Conference Series, 1899(1), 012101. DOI: 10.1088/1742-6596/1899/1/012101

Husein, A., & Rambe, M. (2023). Machine Learning Approaches For Demographic Prediction Analysis. Procedia Computer Science, 227, 205–212. DOI: 10.1016/J.Procs.2023.10.521

Kurniawan, A., & Saputri, N. (2023). Predictive Modeling Using Decision Tree In Data Mining. International Journal Of Computer Applications, 185(20), 25–31. DOI: 10.5120/Ijca2023922561

Lubis, R., & Harahap, F. (2022). Utilization Of Data Mining Techniques In Sports Information Systems. Journal Of Applied Informatics, 9(2), 100–109. DOI: 10.25124/Jai.V9i2.4871

Novelan, M. S., Efendi, S., Sihombing, P., & Mawengkang, H. (2023). Vehicle Routing Problem Optimization With Machine Learning In Imbalanced Classification Vehicle Route Data. Eastern-European Journal Of Enterprise Technologies, 5(3(125)), 49–56.

Nugraha, F., & Permata, D. (2022). Decision Tree Algorithm For Classification Of Sports Activity Data. TELKOMNIKA, 20(4), 812–820. DOI: 10.12928/TELKOMNIKA.V20i4.23112

Prasetyo, H., Gunawan, R., & Akbar, M. (2023). Predictive Analytics For Gym Member Behavior Using Machine Learning Approaches. International Journal Of Intelligent Systems And Applications, 15(3), 120–129. DOI: 10.5815/Ijisa.2023.03.10

Pratama, R., Kurniawan, D., & Sembiring, M. (2024). Comparative Analysis Of Classification Algorithms Using Rapidminer. Journal Of Computer Science And Technology Studies, 6(1), 33–41. DOI: 10.32996/Jcsts.2024.6.1.5

Putri, M., & Syahril, M. (2021). Data Preprocessing Techniques In Machine Learning Classification. Journal Of Information Technology Research, 14(3), 77–88. DOI: 10.4018/JITR.2021070105

Rahman, A., Putra, D., & Wijaya, F. (2021). Classification Analysis Using Decision Tree Algorithm In Healthcare Data Mining. Journal Of Information Systems Engineering And Business Intelligence, 7(2), 145–153. DOI: 10.20473/Jisebi.7.2.145-153

Sari, N., & Hidayat, R. (2022). Implementation Of Decision Tree Algorithm For Sports Data Classification. International Journal Of Advanced Computer Science And Applications, 13(5), 455–462. DOI: 10.14569/IJACSA.2022.0130554

Sembiring, R., & Andriani, D. (2022). Rapidminer-Based Classification Analysis On User Behavior Data. Journal Of Data Science And Information Systems, 5(2), 90–98. DOI: 10.47738/Jdsis.V5i2.112

Wibowo, A., & Nugroho, Y. (2021). Analysis Of Fitness Center Customer Data Using Classification Techniques. Journal Of Big Data, 8(1), 88–97. DOI: 10.1186/S40537-021-00492-1

Wijaya, T., & Fadillah, R. (2024). Evaluation Of Classification Models Using Confusion Matrix And Accuracy Testing. International Journal Of Informatics And Data Science, 3(1), 15–24. DOI: 10.20895/Ijids.2024.3.1.102