



Analisis Komparatif Decision Tree C4.5 dan Neural Network pada Prediksi Kanker Payudara

Amali*, Edy Widodo

Fakultas Teknik, Program Studi Teknik Informatika, Universitas Pelita Bangsa, Bekasi, Indonesia

Email: ^{1,*}amali@pelitabangsa.ac.id, ²ewidodo@pelitabangsa.ac.id

Email Penulis Korespondensi: amali@pelitabangsa.ac.id

Abstrak—Kanker payudara merupakan salah satu penyakit dengan tingkat kejadian dan kematian tertinggi pada perempuan sehingga diperlukan metode yang mampu membantu proses deteksi secara cepat dan akurat. Penelitian ini bertujuan untuk membandingkan kinerja algoritma Decision Tree C4.5 dan Neural Network dalam klasifikasi kanker payudara menggunakan dataset Breast Cancer Wisconsin yang diperoleh dari UCI Machine Learning Repository. Metode penelitian mengacu pada pendekatan CRISP-DM yang meliputi tahapan pengumpulan data, preprocessing, pembangunan model, pengujian, dan evaluasi. Tahap preprocessing dilakukan melalui data cleaning, transformasi data, serta reduksi data untuk meningkatkan kualitas dataset sebelum proses pemodelan. Proses pengujian menggunakan split validation dengan evaluasi berdasarkan metrik accuracy, precision, recall, dan Area Under Curve (AUC). Hasil penelitian menunjukkan bahwa algoritma Neural Network memiliki performa lebih baik dibandingkan Decision Tree C4.5. Neural Network memperoleh accuracy sebesar 96,17%, precision 95,80%, recall 96,50%, dan AUC 0,989 yang termasuk kategori excellent classification. Sementara itu, Decision Tree C4.5 memperoleh accuracy sebesar 93,50% dan AUC sebesar 0,945 yang termasuk kategori very good classification. Analisis ROC Curve menunjukkan bahwa Neural Network lebih optimal dalam membedakan kelas benign dan malignant. Dengan demikian, Neural Network direkomendasikan sebagai model terbaik untuk mendukung deteksi dini kanker payudara berbasis machine learning, sedangkan Decision Tree C4.5 tetap relevan digunakan pada kondisi yang membutuhkan interpretasi model yang lebih sederhana dan mudah dipahami.

Kata Kunci: Kanker Payudara; Klasifikasi; Decision Tree C4.5; Neural Network; ROC Curve; RapidMiner

Abstract—Breast cancer is one of the diseases with the highest incidence and mortality rates among women, requiring methods that can support fast and accurate detection. This study aims to compare the performance of the Decision Tree C4.5 and Neural Network algorithms in breast cancer classification using the Breast Cancer Wisconsin dataset obtained from the UCI Machine Learning Repository. The research method adopts the CRISP-DM approach, which includes data collection, preprocessing, model development, testing, and evaluation stages. The preprocessing stage was carried out through data cleaning, data transformation, and data reduction to improve dataset quality before the modeling process. The testing process used split validation and evaluation based on accuracy, precision, recall, and Area Under Curve (AUC) metrics. The results indicate that the Neural Network algorithm achieved better performance than Decision Tree C4.5. Neural Network obtained an accuracy of 96.17%, precision of 95.80%, recall of 96.50%, and an AUC value of 0.989, which is categorized as excellent classification. Meanwhile, Decision Tree C4.5 achieved an accuracy of 93.50% and an AUC value of 0.945, categorized as very good classification. ROC Curve analysis demonstrates that Neural Network is more effective in distinguishing benign and malignant classes. Therefore, Neural Network is recommended as the best model to support early breast cancer detection based on machine learning, while Decision Tree C4.5 remains relevant for conditions requiring simpler and more interpretable models.

Keywords: Breast Cancer; Classification; Decision Tree C4.5; Neural Network; ROC Curve; Rapidminer

1. PENDAHULUAN

Kanker payudara merupakan salah satu penyakit dengan tingkat kejadian dan kematian tertinggi pada perempuan di dunia, termasuk di Indonesia [1]. Penyakit ini ditandai dengan pertumbuhan sel abnormal yang tidak terkendali pada jaringan payudara dan berpotensi menyebar ke organ lain [2]. Tingginya prevalensi dan dampak yang ditimbulkan menjadikan kanker payudara sebagai masalah kesehatan serius yang memerlukan perhatian khusus, baik dari sisi pencegahan maupun penanganan [3]. Tingginya angka kematian akibat kanker payudara sebagian besar disebabkan oleh keterlambatan diagnosis [4], sehingga deteksi dini menjadi faktor kunci dalam meningkatkan peluang kesembuhan pasien [5]. Oleh karena itu, diperlukan pendekatan yang mampu membantu proses diagnosis secara cepat, akurat, dan berbasis data [6], sehingga dapat mendukung tenaga medis dalam mengambil keputusan yang lebih tepat serta meminimalkan risiko kesalahan diagnosis. Seiring dengan perkembangan teknologi, pemanfaatan *data mining* dan *machine learning* dalam bidang kesehatan terus mengalami peningkatan [7], khususnya dalam proses klasifikasi penyakit. Berbagai metode komputasi cerdas telah digunakan untuk membantu tenaga medis dalam menganalisis data pasien secara lebih cepat dan akurat. Hal ini menjadi penting mengingat kompleksitas data kesehatan yang terus bertambah, baik dari sisi jumlah maupun variasinya [8]. Di sisi lain, data medis yang tersimpan dalam jumlah besar pada dasarnya belum memiliki makna jika tidak melalui proses pengolahan yang tepat. Data mentah hanya berupa kumpulan atribut tanpa informasi yang jelas, sehingga diperlukan teknik klasifikasi untuk mengekstraksi pola-pola tersembunyi di dalamnya. Dengan pendekatan tersebut, data dapat diubah menjadi informasi yang bernilai dalam bentuk model prediksi yang mampu mendukung pengambilan keputusan klinis secara lebih efektif dan berbasis data.

Berbagai algoritma klasifikasi telah banyak diterapkan dalam penelitian sebelumnya, seperti Decision Tree C4.5, Neural Network, Naïve Bayes [9], dan Support Vector Machine [10]. Setiap algoritma memiliki karakteristik dan keunggulan masing-masing dalam mengolah data, sehingga performanya sangat dipengaruhi oleh struktur, distribusi, dan kompleksitas dataset yang digunakan. Sejumlah penelitian menunjukkan bahwa Neural Network memiliki kemampuan

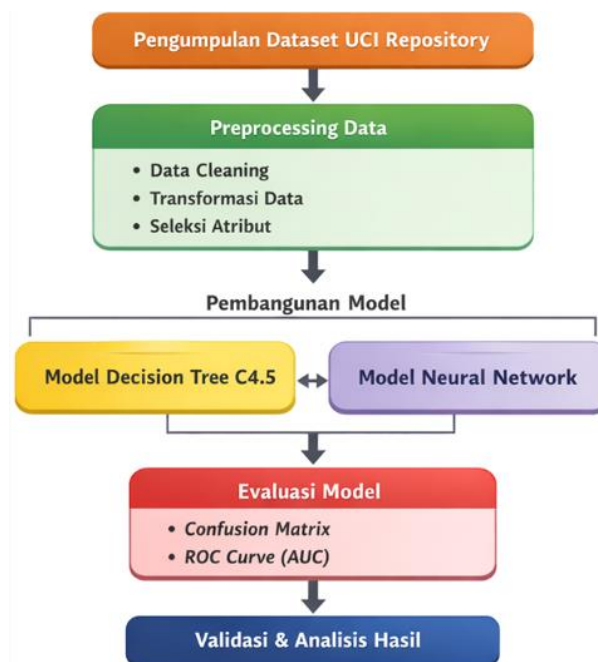


yang baik dalam mengenali pola non-linear yang kompleks, sehingga sering menghasilkan tingkat akurasi yang tinggi dalam kasus klasifikasi medis [11]. Di sisi lain, Decision Tree C4.5 dikenal memiliki keunggulan dalam hal interpretabilitas, karena mampu menyajikan model dalam bentuk aturan yang mudah dipahami [12]. Meskipun demikian, sebagian besar penelitian masih terbatas pada penggunaan satu algoritma atau perbandingan sederhana tanpa didukung analisis evaluasi yang mendalam. Hal ini menyebabkan belum adanya gambaran yang komprehensif mengenai kinerja relatif antar algoritma, khususnya dalam konteks klasifikasi kanker payudara [13]. Selain itu, penelitian terdahulu umumnya belum mengoptimalkan penggunaan platform analisis yang terintegrasi seperti RapidMiner dalam membangun dan mengevaluasi model secara sistematis [14]. Padahal, penggunaan tools berbasis visual tersebut mampu meningkatkan efisiensi proses pemodelan, mulai dari tahap preprocessing hingga evaluasi, serta mempermudah eksplorasi dan interpretasi hasil melalui workflow yang terstruktur dan mudah direproduksi [15]. Di sisi lain, evaluasi model pada banyak penelitian masih cenderung berfokus pada nilai akurasi sebagai satu-satunya indikator kinerja. Pendekatan ini kurang memadai karena tidak mampu menggambarkan performa model secara menyeluruh, terutama pada data yang tidak seimbang [16]. Oleh karena itu, diperlukan penggunaan metrik evaluasi tambahan seperti Area Under Curve (AUC) [17] yang dapat memberikan gambaran lebih komprehensif mengenai kemampuan model dalam membedakan kelas secara optimal. Penelitian sebelumnya umumnya belum melakukan perbandingan langsung antara algoritma Decision Tree C4.5 dan Neural Network dalam satu kerangka eksperimen yang konsisten berbasis RapidMiner dengan evaluasi multi-metrik seperti AUC [18].

Penelitian ini bertujuan untuk membandingkan kinerja algoritma Decision Tree C4.5 dan Neural Network dalam mengklasifikasikan data kanker payudara [19], serta menentukan algoritma yang memiliki performa terbaik berdasarkan metrik evaluasi yang digunakan [20]. Hasil penelitian diharapkan dapat memberikan kontribusi dalam pengembangan model prediksi berbasis machine learning yang dapat dimanfaatkan sebagai alat bantu dalam deteksi dini kanker payudara [21].

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan *data mining* dengan metode **CRISP-DM** yang diimplementasikan secara sistematis sesuai alur pada Gambar Metodologi Penelitian.



Gambar 1. Tahapan Penelitian

2.1. Pengumpulan Data

Pengumpulan data dalam penelitian ini dilakukan dengan menggunakan data sekunder yang diperoleh dari *UCI Machine Learning Repository*, yaitu dataset Breast Cancer Wisconsin yang banyak digunakan sebagai dataset standar dalam penelitian klasifikasi penyakit. Dataset ini dipilih karena memiliki struktur data yang jelas, atribut yang relevan secara medis, serta telah melalui proses kurasi sehingga layak digunakan untuk pengujian algoritma *machine learning*.

Data yang digunakan terdiri dari 699 record dengan 11 atribut, yang mencakup 10 atribut prediktor dan 1 atribut target (kelas). Atribut prediktor merepresentasikan karakteristik sel hasil pemeriksaan medis, sedangkan atribut target menunjukkan jenis diagnosis, yaitu *benign* (jinak) dan *malignant* (ganas). Dataset ini memungkinkan dilakukan analisis klasifikasi untuk mendukung deteksi dini kanker payudara.

**Tabel 1.** Deskripsi Dataset Penelitian

No	Komponen Data	Keterangan
1	Sumber Data	UCI Machine Learning Repository
2	Nama Dataset	Breast Cancer Wisconsin
3	Jumlah Data	699 record
4	Jumlah Atribut	11 atribut
5	Atribut Prediktor	10 atribut (karakteristik sel)
6	Atribut Target	1 atribut (kelas diagnosis)
7	Kelas Data	Benign (jinak), Malignant (ganas)
8	Tipe Data	Numerik (skala 1–10)
9	Tahun Akses	2023

Berdasarkan Tabel 1 dataset yang digunakan merupakan data terstruktur yang terdiri dari atribut numerik dengan rentang nilai tertentu yang merepresentasikan kondisi sel pasien. Atribut-atribut tersebut berfungsi sebagai variabel independen dalam proses klasifikasi, sedangkan atribut kelas menjadi variabel dependen yang akan diprediksi oleh model. Penggunaan dataset dari UCI Machine Learning Repository memberikan keunggulan dari sisi validitas dan konsistensi data, sehingga hasil penelitian dapat dibandingkan dengan penelitian lain yang menggunakan dataset serupa. Selain itu, dataset ini juga mendukung pengujian performa algoritma klasifikasi secara objektif karena telah menjadi *benchmark* dalam berbagai penelitian di bidang kesehatan dan *machine learning*.

Tabel 2. Variabel Penelitian (Atribut dan Arti Medis)

No	Nama Atribut	Deskripsi Medis	Tipe Data	Peran
1	ID	Nomor identitas unik setiap sampel pasien	Numerik	Identifier
2	Clump Thickness	Ketebalan sel (menunjukkan ukuran dan kepadatan sel abnormal)	Numerik (1–10)	Prediktor
3	Uniformity of Cell Size	Keseragaman ukuran sel (semakin tidak seragam → indikasi kanker)	Numerik (1–10)	Prediktor
4	Uniformity of Cell Shape	Keseragaman bentuk sel (ketidakteraturan bentuk menunjukkan keganasan)	Numerik (1–10)	Prediktor
5	Marginal Adhesion	Tingkat adhesi antar sel (rendah → sel mudah menyebar)	Numerik (1–10)	Prediktor
6	Single Epithelial Cell Size	Ukuran sel epitel tunggal (besar → indikasi abnormalitas)	Numerik (1–10)	Prediktor
7	Bare Nuclei	Jumlah inti sel tanpa sitoplasma (tinggi → indikasi kanker)	Numerik (1–10)	Prediktor
8	Bland Chromatin	Tekstur kromatin inti sel (tidak normal → indikasi keganasan)	Numerik (1–10)	Prediktor
9	Normal Nucleoli	Kondisi nukleolus (besar/tidak normal → indikasi kanker)	Numerik (1–10)	Prediktor
10	Mitoses	Tingkat pembelahan sel (semakin tinggi → indikasi pertumbuhan kanker)	Numerik (1–10)	Prediktor
11	Class	Kelas diagnosis: benign (jinak) atau malignant (ganas)	Kategorikal/Numerik	Target

Tabel 2 menunjukkan variabel yang digunakan dalam penelitian, yang terdiri dari 10 atribut prediktor dan 1 atribut target. Atribut prediktor merepresentasikan karakteristik biologis sel berdasarkan hasil pemeriksaan medis, sedangkan atribut *class* berfungsi sebagai variabel target yang digunakan dalam proses klasifikasi. Nilai setiap atribut berada pada skala 1–10 yang menunjukkan tingkat keparahan atau abnormalitas sel.

2.2. Preprocessing Data

Tahap *preprocessing data* merupakan langkah penting dalam penelitian ini untuk memastikan kualitas dataset sebelum digunakan pada proses pemodelan. Dataset kanker payudara yang diperoleh masih berupa data mentah sehingga memerlukan beberapa proses pengolahan agar siap digunakan oleh algoritma *machine learning*. Tahapan preprocessing dilakukan untuk mengurangi *noise*, mengatasi data yang tidak lengkap, serta meningkatkan akurasi dan efisiensi model klasifikasi. Proses preprocessing dalam penelitian ini meliputi *data cleaning*, *data transformation*, dan *data reduction*. *Data cleaning* dilakukan untuk menangani nilai yang hilang (*missing value*) serta menghapus data yang tidak konsisten. *Data transformation* bertujuan untuk mengubah data kategorikal menjadi numerik agar dapat diproses oleh algoritma, khususnya Neural Network. Sedangkan *data reduction* dilakukan untuk menyederhanakan dataset dengan tetap mempertahankan informasi penting melalui seleksi atribut dan penghapusan data duplikasi.



Tabel 3. Tahapan Preprocessing Data

No	Tahapan	Deskripsi	Tujuan
1	Data Cleaning	Menghapus <i>missing value</i> , data duplikat, dan data tidak konsisten	Meningkatkan kualitas data
2	Data Transformation	Mengubah atribut kategorikal menjadi numerik (<i>benign</i> = 2, <i>malignant</i> = 4)	Menyesuaikan dengan algoritma
3	Data Reduction	Seleksi atribut dan pengurangan data yang tidak relevan	Meningkatkan efisiensi model
4	Normalisasi (opsional)	Menyetarakan skala data (jika diperlukan)	Menghindari bias skala

Berdasarkan Tabel 3, proses preprocessing dimulai dari *data cleaning* untuk memastikan tidak terdapat data yang kosong atau tidak valid yang dapat mempengaruhi hasil analisis. Selanjutnya dilakukan *data transformation* untuk mengubah atribut kelas menjadi bentuk numerik agar dapat diproses oleh algoritma klasifikasi. Tahap berikutnya adalah *data reduction* yang bertujuan untuk mengurangi kompleksitas data tanpa menghilangkan informasi penting. Pada beberapa kasus, dilakukan normalisasi data untuk menyamakan skala nilai antar atribut sehingga model dapat bekerja lebih optimal. Jika dilakukan normalisasi, metode yang digunakan adalah Min-Max Normalization, yaitu:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Keterangan:

x = nilai asli

x_{min} = nilai minimum atribut

x_{max} = nilai maksimum atribut

x' = nilai hasil normalisasi

Melalui tahapan preprocessing ini, dataset yang awalnya berupa data mentah berhasil diubah menjadi data yang bersih, terstruktur, dan siap digunakan dalam proses pemodelan. Melalui proses ini, seluruh nilai data akan berada pada rentang 0 sampai 1 sehingga dapat mengurangi perbedaan skala antar atribut dan membantu meningkatkan performa model klasifikasi, terutama pada algoritma Neural Network.

2.3. Pembangunan Model (Modeling)

Tahap *modeling* merupakan proses utama dalam penelitian ini yang bertujuan untuk membangun model klasifikasi berdasarkan dataset yang telah melalui tahap preprocessing. Pada tahap ini digunakan dua algoritma *machine learning*, yaitu Decision Tree C4.5 dan Neural Network, untuk membandingkan kinerja dalam mengklasifikasikan kanker payudara ke dalam kategori *benign* dan *malignant*.

Tabel 4. Algoritma yang Digunakan

No	Algoritma	Karakteristik	Kelebihan	Kekurangan
1	Decision Tree C4.5	Model berbentuk pohon keputusan	Mudah diinterpretasikan	Kurang optimal pada data kompleks
2	Neural Network	Model berbasis jaringan saraf	Mampu menangani pola non-linear	Sulit diinterpretasikan

Tabel 4 menunjukkan algoritma yang digunakan dalam penelitian ini, yaitu Decision Tree C4.5 dan Neural Network, beserta karakteristik, kelebihan, dan kekurangannya. Decision Tree C4.5 merupakan algoritma berbasis struktur pohon keputusan yang mudah diinterpretasikan karena menghasilkan aturan yang jelas, namun memiliki keterbatasan dalam menangani pola data yang kompleks. Sementara itu, Neural Network merupakan algoritma berbasis jaringan saraf tiruan yang memiliki kemampuan tinggi dalam memodelkan hubungan non-linear dan pola kompleks, meskipun memiliki tingkat interpretabilitas yang lebih rendah. Pemilihan kedua algoritma ini bertujuan untuk membandingkan kinerja model dengan pendekatan yang berbeda, yaitu model yang mudah dipahami dan model dengan kemampuan prediksi yang lebih kuat.

2.3.1. Decision Tree C4.5

Decision Tree C4.5 merupakan algoritma klasifikasi yang membentuk struktur pohon berdasarkan nilai atribut terbaik sebagai pemisah data. Pemilihan atribut dilakukan menggunakan konsep Entropy dan Information Gain. Pemilihan atribut pada algoritma Decision Tree C4.5 dilakukan menggunakan konsep Entropy untuk mengukur ketidakpastian data dan Information Gain untuk menentukan atribut terbaik sebagai pemisah data.

$$Entropy(S) = - \sum_{i=1}^n p_i \log_2 p_i \quad (2)$$



$$Gain(S, A) = Entropy(S) - \sum_{i=1}^n \frac{|S_i|}{|S|} Entropy(S_i) \tag{3}$$

Keterangan:

S= himpunan data

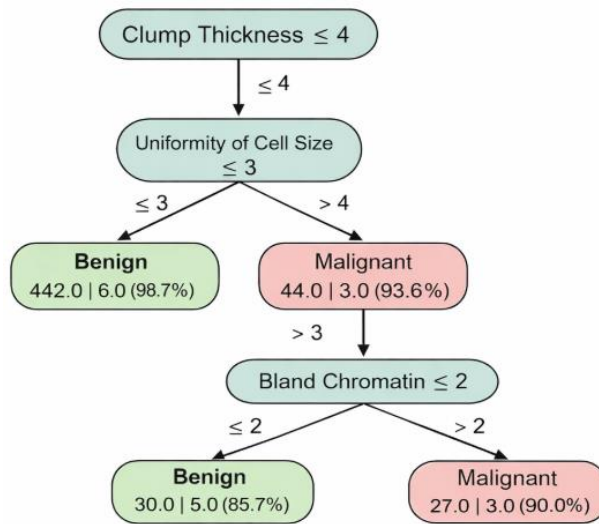
A= atribut

p_i = proporsi kelas ke-i

S_i = subset data berdasarkan atribut A

Atribut dengan nilai Information Gain tertinggi akan dipilih sebagai node dalam pembentukan pohon keputusan.

Entropy digunakan untuk mengukur tingkat ketidakpastian dalam data, sedangkan Information Gain digunakan untuk menentukan atribut terbaik dalam membagi data. Atribut dengan nilai gain tertinggi akan dipilih sebagai node dalam pohon keputusan.



Gambar 2. Contoh Struktur Decision Tree C4.5

Gambar 2 menunjukkan contoh struktur pohon keputusan yang dihasilkan oleh algoritma Decision Tree C4.5, di mana setiap node merepresentasikan atribut pemisah berdasarkan nilai tertentu hingga menghasilkan klasifikasi akhir.

2.3.2. Neural Network

Neural Network merupakan algoritma yang meniru cara kerja jaringan saraf manusia dengan menggunakan beberapa lapisan (*layer*), yaitu *input layer*, *hidden layer*, dan *output layer*. Model ini mampu mempelajari hubungan kompleks antar variabel melalui proses pembelajaran berbasis *backpropagation*.

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right)$$

Keterangan:

x_i = input

w_i = bobot

b = bias

f = fungsi aktivasi (misalnya sigmoid)

y = output neuron

Rumus tersebut menunjukkan proses dasar pada Neural Network, di mana setiap input dikalikan dengan bobot, kemudian dijumlahkan dan ditambahkan bias. Hasilnya diproses melalui fungsi aktivasi untuk menghasilkan output. Proses ini memungkinkan model mempelajari pola dari data dan melakukan klasifikasi secara akurat.

2.4. Evaluasi Model

Tahap evaluasi model bertujuan untuk mengukur kinerja algoritma dalam mengklasifikasikan data kanker payudara. Pada penelitian ini, evaluasi dilakukan terhadap dua model, yaitu Decision Tree C4.5 dan Neural Network, menggunakan metode Confusion Matrix dan Receiver Operating Characteristic).

Penggunaan lebih dari satu metrik evaluasi bertujuan untuk memperoleh gambaran yang lebih komprehensif terhadap performa model, tidak hanya dari sisi akurasi, tetapi juga kemampuan model dalam membedakan kelas secara tepat.

Tabel 5. Confusion Matrix

Actual / Predicted	Positif (Malignant)	Negatif (Benign)
Positif (Malignant)	True Positive (TP)	False Negative (FN)
Negatif (Benign)	False Positive (FP)	True Negative (TN)



True Positive (TP): data positif yang diprediksi benar

True Negative (TN): data negatif yang diprediksi benar

False Positive (FP): data negatif yang diprediksi positif

False Negative (FN): data positif yang diprediksi negatif

Confusion Matrix digunakan untuk menghitung berbagai metrik evaluasi yang menggambarkan performa model klasifikasi.

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (4)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (5)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (6)$$

$$\text{AUC} = \int_0^1 \text{TPR}(\text{FPR}) d(\text{FPR}) \quad (7)$$

Accuracy menunjukkan tingkat ketepatan model secara keseluruhan

Precision mengukur ketepatan prediksi positif

Recall menunjukkan kemampuan model dalam mendeteksi data positif

AUC menggambarkan kemampuan model dalam membedakan kelas positif dan negatif secara keseluruhan

ROC Curve

ROC Curve merupakan grafik yang menunjukkan hubungan antara:

True Positive Rate (TPR) atau Recall

False Positive Rate (FPR)

Nilai AUC berkisar antara 0 hingga 1:

0.5 = klasifikasi acak

0.7–0.8 = cukup baik

0.8–0.9 = baik

0.9 = sangat baik (*excellent classification*)

Tabel 6. Hasil Evaluasi Model

Algoritma	Accuracy (%)	Precision (%)	Recall (%)	AUC	Kategori
Decision Tree C4.5	93.50	92.80	91.60	0.945	Very Good
Neural Network	96.17	95.80	96.50	0.989	Excellent

Berdasarkan Tabel 6, algoritma Neural Network menunjukkan performa terbaik dibandingkan Decision Tree C4.5 dengan nilai akurasi sebesar 96,17% dan AUC sebesar 0,989. Nilai AUC yang mendekati 1 menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam membedakan kelas *benign* dan *malignant*. Dengan demikian, Neural Network dapat dikategorikan sebagai model dengan tingkat klasifikasi *excellent*, sedangkan Decision Tree C4.5 berada pada kategori *very good*.

2.5. Validasi dan Analisis Hasil

Tahap validasi dan analisis hasil dilakukan untuk memastikan bahwa model yang dibangun memiliki kemampuan generalisasi yang baik terhadap data baru serta untuk membandingkan kinerja algoritma yang digunakan. Proses validasi pada penelitian ini menggunakan metode *split validation*, yaitu dengan membagi dataset menjadi data *training* dan *testing*. Data *training* digunakan untuk membangun model, sedangkan data *testing* digunakan untuk menguji performa model terhadap data yang belum pernah dilihat sebelumnya. Pendekatan ini bertujuan untuk menghindari *overfitting* serta memastikan bahwa model yang dihasilkan dapat digunakan secara lebih luas.

Berdasarkan hasil pengujian, diperoleh nilai evaluasi dari masing-masing algoritma yang ditunjukkan pada Tabel 7. Hasil ini menunjukkan perbandingan kinerja antara Decision Tree C4.5 dan Neural Network dalam mengklasifikasikan kanker payudara.

Tabel 7. Hasil Validasi dan Perbandingan Model

Algoritma	Accuracy (%)	AUC	Kategori
Decision Tree C4.5	93.50	0.945	Very Good
Neural Network	96.17	0.989	Excellent

Berdasarkan Tabel 7, algoritma Neural Network menunjukkan performa yang lebih baik dibandingkan Decision Tree C4.5. Hal ini ditunjukkan oleh nilai akurasi sebesar 96,17% dan nilai AUC sebesar 0,989 yang termasuk dalam kategori *excellent classification*. Sementara itu, Decision Tree C4.5 memiliki nilai AUC sebesar 0,945 yang masih tergolong *very good*, namun berada di bawah Neural Network.

Performa model juga dapat dianalisis menggunakan konsep True Positive Rate (TPR) dan False Positive Rate (FPR) yang menjadi dasar dalam pembentukan kurva ROC. Secara matematis, TPR dan FPR dirumuskan sebagai berikut:

$$\text{TPR} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

$$\text{FPR} = \frac{\text{FP}}{\text{FP} + \text{TN}}$$

3. HASIL DAN PEMBAHASAN

3.1. Hasil Evaluasi Model

Hasil pengujian menunjukkan bahwa kedua algoritma memiliki performa yang baik dalam melakukan klasifikasi, namun terdapat perbedaan tingkat akurasi dan kemampuan dalam membedakan kelas. Ringkasan hasil evaluasi ditunjukkan pada Tabel 8.

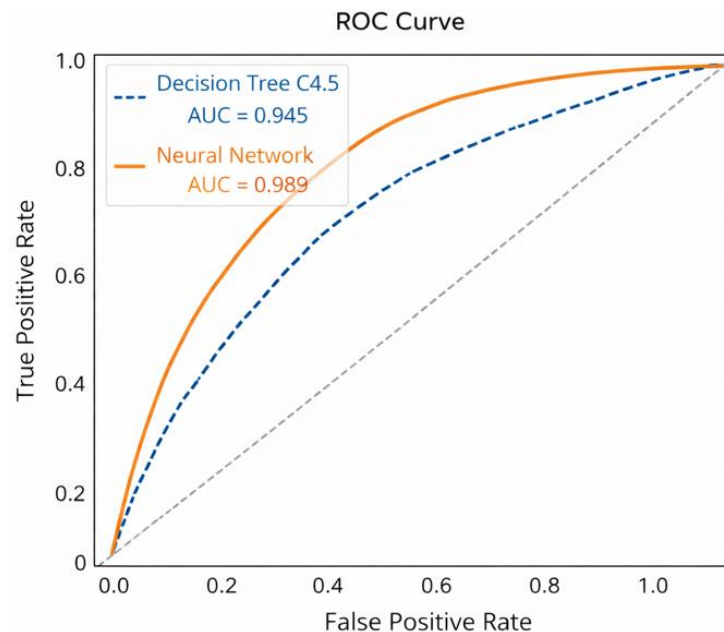
Tabel 8. Hasil Evaluasi Model

Algoritma	Accuracy (%)	Precision (%)	Recall (%)	AUC
Decision Tree C4.5	93.50	92.80	91.60	0.945
Neural Network	96.17	95.80	96.50	0.989

Berdasarkan Tabel 8, algoritma Neural Network menunjukkan performa yang lebih unggul dibandingkan Decision Tree C4.5 pada seluruh metrik evaluasi. Nilai akurasi sebesar 96,17% menunjukkan bahwa model mampu mengklasifikasikan data dengan tingkat ketepatan yang tinggi. Selain itu, nilai precision dan recall yang tinggi menunjukkan bahwa model tidak hanya akurat, tetapi juga konsisten dalam mengidentifikasi data positif (*malignant*). Sementara itu, Decision Tree C4.5 memiliki nilai akurasi sebesar 93,50% yang masih tergolong baik, namun lebih rendah dibandingkan Neural Network. Hal ini menunjukkan bahwa meskipun Decision Tree memiliki keunggulan dalam interpretasi model, performanya masih kalah dalam menangani kompleksitas pola data.

3.2. Analisis ROC Curve

Analisis *Receiver Operating Characteristic* (ROC) dilakukan untuk mengevaluasi kemampuan model dalam membedakan kelas *benign* dan *malignant* secara lebih komprehensif. Berbeda dengan metrik akurasi yang hanya menunjukkan ketepatan prediksi secara umum, kurva ROC menggambarkan hubungan antara True Positive Rate (TPR) dan False Positive Rate (FPR) pada berbagai threshold klasifikasi. Kurva ROC untuk kedua algoritma ditunjukkan pada Gambar 2. Berdasarkan grafik tersebut, terlihat bahwa kurva Neural Network lebih mendekati sudut kiri atas dibandingkan Decision Tree C4.5, yang menunjukkan kemampuan klasifikasi yang lebih baik dalam membedakan kelas positif dan negatif.



Gambar 3. Kurva ROC Perbandingan Decision Tree C4.5 dan Neural Network

Berdasarkan Gambar 3, kurva ROC Neural Network terlihat lebih mendekati sudut kiri atas dibandingkan Decision Tree C4.5, yang menunjukkan performa klasifikasi yang lebih baik. Hal ini sejalan dengan nilai AUC sebesar 0,989 yang termasuk dalam kategori *excellent*.

Tabel 9. Perbandingan Nilai AUC

Algoritma	Nilai AUC	Kategori
Decision Tree C4.5	0.945	Very Good
Neural Network	0.989	Excellent

Berdasarkan Tabel 9, algoritma Neural Network memiliki nilai AUC sebesar 0,989 yang termasuk dalam kategori *excellent*, sedangkan Decision Tree C4.5 memiliki nilai AUC sebesar 0,945 yang termasuk dalam kategori *very good*.



Nilai AUC yang lebih tinggi menunjukkan bahwa model memiliki kemampuan yang lebih baik dalam membedakan antara kelas positif (*malignant*) dan negatif (*benign*). Kurva ROC dibentuk berdasarkan dua komponen utama, yaitu:

True Positive Rate (TPR)

$$TPR = \frac{TP}{TP + FN}$$

$$TPR = \frac{TP}{TP + FN}$$

False Positive Rate (FPR)

$$FPR = \frac{FP}{FP + TN}$$

TPR (Recall) menunjukkan kemampuan model dalam mendeteksi data positif secara benar. FPR menunjukkan tingkat kesalahan model dalam mengklasifikasikan data negatif sebagai positif. Semakin tinggi nilai TPR dan semakin rendah nilai FPR, maka performa model semakin baik. Kurva ROC yang ideal adalah kurva yang mendekati titik (0,1), yang menunjukkan nilai TPR tinggi dan FPR rendah. Hasil analisis ROC menunjukkan bahwa Neural Network memiliki performa yang lebih unggul dibandingkan Decision Tree C4.5.

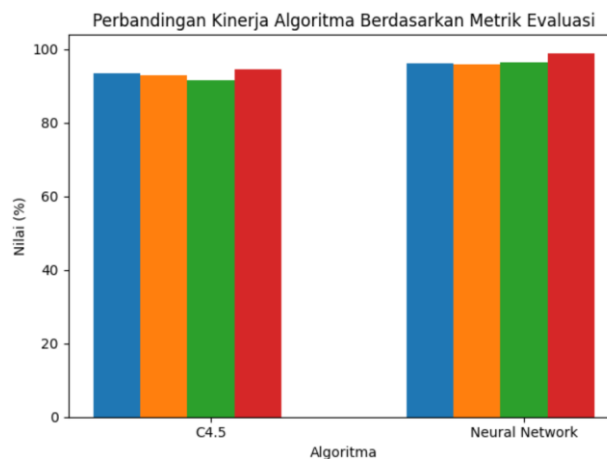
3.3. Analisis Perbandingan Algoritma

Analisis perbandingan algoritma dilakukan untuk mengevaluasi secara menyeluruh kinerja Decision Tree C4.5 dan Neural Network dalam mengklasifikasikan kanker payudara. Perbandingan ini didasarkan pada hasil evaluasi yang telah diperoleh, meliputi metrik *accuracy*, *precision*, *recall*, dan *Area Under Curve (AUC)*, serta mempertimbangkan aspek kompleksitas model dan interpretabilitas.

Tabel 10. Perbandingan Kinerja Algoritma

Aspek	Decision Tree C4.5	Neural Network	Aspek
Accuracy	93.50%	96.17%	Accuracy
Precision	92.80%	95.80%	Precision
Recall	91.60%	96.50%	Recall
AUC	0.945	0.989	AUC
Kemampuan Pola Interpretabilitas	Linear / sederhana	Non-linear / kompleks	Kemampuan Pola Interpretabilitas
Kompleksitas Model	Tinggi	Rendah	Kompleksitas Model

Tabel 10 menunjukkan bahwa Neural Network unggul pada seluruh metrik evaluasi dibandingkan Decision Tree C4.5. Hal ini mengindikasikan bahwa Neural Network memiliki kemampuan yang lebih baik dalam menangkap pola kompleks dalam data. Namun,



Gambar 4. Perbandingan Kinerja Algoritma Berdasarkan Metrik Evaluasi

Berdasarkan Gambar 4, terlihat bahwa algoritma Neural Network memiliki nilai yang lebih tinggi pada seluruh metrik evaluasi dibandingkan Decision Tree C4.5. Perbedaan paling signifikan terlihat pada nilai recall dan AUC, yang menunjukkan bahwa Neural Network lebih mampu mendeteksi data positif (*malignant*) secara akurat serta memiliki kemampuan diskriminasi yang lebih baik.

3.4. Analisis Performa Model

Perbedaan performa antara kedua algoritma dapat dijelaskan berdasarkan karakteristik masing-masing metode. Decision Tree C4.5 bekerja dengan membagi data berdasarkan atribut terbaik menggunakan konsep Information Gain, sehingga lebih efektif pada data dengan pola yang relatif sederhana. Sebaliknya, Neural Network menggunakan pendekatan



berbasis bobot dan fungsi aktivasi yang memungkinkan model mempelajari hubungan non-linear yang lebih kompleks. Secara matematis, Neural Network melakukan transformasi input menggunakan fungsi aktivasi sebagai berikut:

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right)$$

Model ini memungkinkan penyesuaian bobot secara iteratif sehingga dapat meminimalkan kesalahan prediksi. Neural Network memiliki performa yang lebih tinggi dibandingkan Decision Tree C4.5 pada seluruh metrik evaluasi. Keunggulan ini berkaitan dengan kemampuannya dalam menangkap pola kompleks dan hubungan non-linear yang tidak dapat ditangani secara optimal oleh metode berbasis aturan seperti Decision Tree. Namun demikian, dalam konteks aplikasi medis, interpretabilitas tetap menjadi faktor penting. Decision Tree memiliki keunggulan dalam hal transparansi model karena menghasilkan aturan yang mudah dipahami, sehingga lebih sesuai digunakan oleh tenaga medis dalam proses pengambilan keputusan. Oleh karena itu, pemilihan algoritma tidak hanya didasarkan pada tingkat akurasi, tetapi juga mempertimbangkan kebutuhan interpretasi dalam implementasi nyata. Berdasarkan perbandingan yang dilakukan, Neural Network merupakan algoritma yang paling optimal karena menunjukkan kinerja terbaik dalam aspek akurasi dan kemampuan klasifikasi.

4. KESIMPULAN

Penelitian ini berhasil membandingkan kinerja algoritma Decision Tree C4.5 dan Neural Network dalam klasifikasi kanker payudara menggunakan dataset Breast Cancer Wisconsin berbasis RapidMiner. Hasil evaluasi menunjukkan bahwa kedua algoritma memiliki performa yang baik, namun Neural Network secara konsisten memberikan hasil yang lebih unggul dibandingkan Decision Tree C4.5 pada seluruh metrik evaluasi. Neural Network memperoleh nilai akurasi sebesar 96,17%, precision 95,80%, recall 96,50%, serta AUC sebesar 0,989 yang termasuk dalam kategori excellent. Sementara itu, Decision Tree C4.5 memperoleh akurasi sebesar 93,50% dan AUC sebesar 0,945 yang termasuk dalam kategori very good. Analisis ROC Curve menunjukkan bahwa Neural Network memiliki kemampuan yang lebih baik dalam membedakan kelas benign dan malignant, ditunjukkan oleh kurva yang lebih mendekati sudut kiri atas serta nilai AUC yang lebih tinggi. Hal ini mengindikasikan bahwa Neural Network lebih efektif dalam menangani pola data yang kompleks dan non-linear. Meskipun demikian, Decision Tree C4.5 tetap memiliki keunggulan dalam hal interpretabilitas model, sehingga lebih mudah dipahami dan dijelaskan dalam konteks aplikasi medis. Oleh karena itu, pemilihan algoritma sebaiknya mempertimbangkan tidak hanya tingkat akurasi, tetapi juga kebutuhan transparansi model.

REFERENCES

- [1] A. F. Rahmadini, R. K. D.S, and T. Agustiani, "Edukasi Perilaku Pemeriksaan Payudara Sendiri (Sadari) Dalam Pencegahan Kanker Payudara Pada Remaja," *Jurnal Pemberdayaan dan Pendidikan Kesehatan (JPPK)*, vol. 1, no. 02, pp. 105–113, Jun. 2022, doi: 10.34305/jppk.v1i02.433.
- [2] A. Rizka, M. K. Akbar, and N. A. Putri, "Carcinoma Mammae Sinistra T4bN2M1 Metastasis Pleura," *AVERROUS: Jurnal Kedokteran dan Kesehatan Malikussaleh*, vol. 8, no. 1, pp. 23–31, Jul. 2022, doi: 10.29103/averrous.v8i1.7006.
- [3] A. Supriyanto, W. A. Kusuma, and H. Rahmawan, "Klasifikasi Kanker Tumor Payudara Menggunakan Arsitektur Inception-V3 Dan Algoritma Machine Learning," *JURNAL AI-AZHAR INDONESIA SERI SAINS DAN TEKNOLOGI*, vol. 7, no. 3, p. 187, Sep. 2022, doi: 10.36722/sst.v7i3.1284.
- [4] C. Sidrah Nadira, A. Rizka, and Z. Humaira, "Faktor Keterlambatan Pada Pasien Kanker Payudara Yang Berobat Di Rsumc Aceh Utara Tahun 2020 - 2021," *Jurnal Ilmiah Manusia Dan Kesehatan*, vol. 6, no. 1, pp. 88–99, Jan. 2023, doi: 10.31850/makes.v6i1.1942.
- [5] L. Schwartzberg *et al.*, "Impact of early detection on cancer curability: A modified Delphi panel study," *PLoS One*, vol. 17, no. 12, p. e0279227, Dec. 2022, doi: 10.1371/journal.pone.0279227.
- [6] M. Wojtara, E. Rana, T. Rahman, P. Khanna, and H. Singh, "Artificial intelligence in rare disease diagnosis and treatment," *Clin. Transl. Sci.*, vol. 16, no. 11, pp. 2106–2111, Nov. 2023, doi: 10.1111/cts.13619.
- [7] F. D. Telaumbanua, P. Hulu, T. Z. Nadeak, R. R. Lumbantong, and A. Dharma, "Penggunaan Machine Learning Di Bidang Kesehatan," *Jurnal Teknologi dan Ilmu Komputer Prima (JUTIKOMP)*, vol. 2, no. 2, Jan. 2020, doi: 10.34012/jutikomp.v2i2.657.
- [8] Cecep Wahyu Cahyana and Akhsin Nurlayli, "Analisis Performa Logistic Regression, Naïve Bayes, dan Random Forest sebagai Algoritma Pendeteksi Kanker Payudara," *INSERT : Information System and Emerging Technology Journal*, vol. 4, no. 1, pp. 51–64, Jun. 2023, doi: 10.23887/insert.v4i1.62362.
- [9] A. A. Lemij *et al.*, "Breast cancer in the older population: a global challenge—an epidemiological perspective," *Annals of Breast Surgery*, vol. 7, pp. 17–17, Jun. 2023, doi: 10.21037/abs-21-89.
- [10] R. Resmiati and T. Arifin, "Klasifikasi Pasien Kanker Payudara Menggunakan Metode Support Vector Machine dengan Backward Elimination," *SISTEMASI*, vol. 10, no. 2, p. 381, May 2021, doi: 10.32520/stmsi.v10i2.1238.
- [11] M. Mustapha, D. Ozsahin, I. Ozsahin, and B. Uzun, "Breast Cancer Screening Based on Supervised Learning and Multi-Criteria Decision-Making," *Diagnostics*, vol. 12, no. 6, p. 1326, May 2022, doi: 10.3390/diagnostics12061326.
- [12] N. R. Muntari and K. H. Hanif, "Klasifikasi Penyakit Kanker Payudara Menggunakan Perbandingan Algoritma Machine Learning," *Jurnal Ilmu Komputer dan Teknologi*, vol. 3, no. 1, pp. 1–6, May 2022, doi: 10.35960/ikomti.v3i1.766.
- [13] W. Gautama, "Breast Cancer in Indonesia in 2022: 30 Years of Marching in Place," *Indonesian Journal of Cancer*, vol. 16, no. 1, p. 1, Apr. 2022, doi: 10.33371/ijoc.v16i1.920.
- [14] R. Resmiati and T. Arifin, "Klasifikasi Pasien Kanker Payudara Menggunakan Metode Support Vector Machine dengan Backward Elimination," *SISTEMASI*, vol. 10, no. 2, p. 381, May 2021, doi: 10.32520/stmsi.v10i2.1238.



- [15] S. Hannan, I. Hami, R. K. Dey, and S. Das Gupta, "A Systematic Exploration of Key Candidate Genes and Pathways in the Biogenesis of Human Gastric Cancer: A Comprehensive Bioinformatics Investigation," *Journal of Translational Gastroenterology*, vol. 2, no. 1, pp. 9–20, Mar. 2024, doi: 10.14218/JTG.2023.00072.
- [16] N. Sakhare, Y. Rewatkar, J. Khalatkar, S. Uplapwar, N. Parate, and Y. Dubey, "Performance Evaluation of Predictive Models for Breast Cancer Classification," in *2022 International Conference on Emerging Trends in Engineering and Medical Sciences (ICETEMS)*, IEEE, Nov. 2022, pp. 312–316. doi: 10.1109/ICETEMS56252.2022.10093543.
- [17] R. Nurcahyo, A. Z. Fanani, A. Affandy, and M. I. Aziz, "Peningkatan Algoritma C4.5 Berbasis PSO Pada Penyakit Kanker Payudara," *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 7, no. 4, p. 1758, Oct. 2023, doi: 10.30865/mib.v7i4.6841.
- [18] A. Nanda and A. Jatain, "Analysis of Breast Cancer Detection Techniques Using RapidMiner," 2021, pp. 3–14. doi: 10.1007/978-981-15-4992-2_1.
- [19] F. M. Hana, "Klasifikasi Penderita Penyakit Diabetes Menggunakan Algoritma Decision Tree C4.5," *Jurnal SISKOM-KB (Sistem Komputer dan Kecerdasan Buatan)*, vol. 4, no. 1, pp. 32–39, Oct. 2020, doi: 10.47970/siskom-kb.v4i1.173.
- [20] R. Nurcahyo, A. Z. Fanani, A. Affandy, and M. I. Aziz, "Peningkatan Algoritma C4.5 Berbasis PSO Pada Penyakit Kanker Payudara," *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 7, no. 4, p. 1758, Oct. 2023, doi: 10.30865/mib.v7i4.6841.
- [21] V. Jaiswal, P. Saurabh, U. K. Lilhore, M. Pathak, S. Simaiya, and S. Dalal, "A breast cancer risk predication and classification model with ensemble learning and big data fusion," *Decision Analytics Journal*, vol. 8, p. 100298, Sep. 2023, doi: 10.1016/j.dajour.2023.100298.