

MODEL KLASIFIKASI TINGKAT KEPARAHAN TUMOR TULANG MENGUNAKAN ALGORITMA DECISION TREE BERBASIS FITUR KLINIS

Rani Dwi Destianti¹, Melan Dumasarl Gultom², Gina Noviamanti³.

Program Studi Manajemen Informatika¹²³
POLITEKNIK GEOLOGI DAN PERTAMBANGAN AGP
ranidesna3112@gmail.com¹, melan_dpri@yahoo.com², ginanoviamanti02@gmail.com³.

(*) Corresponding Author : ranidesna3112@gmail.com¹

Abstract—Bone cancer is a serious disease that requires early and accurate treatment to improve patient prognosis. The manual diagnosis and classification process of bone tumor severity conducted by medical professionals often faces challenges due to the complexity of clinical data and subjectivity in decision-making. Therefore, a machine learning-based system is needed to help improve accuracy and efficiency in classifying bone tumor severity. This study aims to develop a classification model for bone tumor severity using the Decision Tree algorithm, which can automatically process patient clinical data. The methodology used in this study follows the Knowledge Discovery in Databases (KDD) process, consisting of data selection, preprocessing, transformation, modeling with the Decision Tree algorithm, and model evaluation. The dataset used was obtained from the Kaggle platform, which includes various clinical features such as tumor size, location, and metastasis level. The model evaluation was conducted using cross-validation techniques and performance metrics such as accuracy, precision, recall, and F1-score. The results of the study show that the Decision Tree algorithm achieved an accuracy of 88.5%, with a precision of 86.7%, recall of 84.3%, and an F1-score of 85.5%. These findings indicate that the developed model can assist in classifying the severity of bone tumors with high accuracy and can be reliably used as a medical decision support system.

Keywords: Decision Tree, bone tumor classification, machine learning, accuracy, decision support system, cross-validation, clinical features.

Abstrak—Kanker tulang merupakan salah satu penyakit serius yang memerlukan penanganan dini dan akurat untuk meningkatkan prognosis pasien. Permasalahan proses diagnosis dan klasifikasi tingkat keparahan tumor tulang yang dilakukan secara manual oleh tenaga medis sering kali menghadapi tantangan berupa kompleksitas data klinis serta subjektivitas dalam pengambilan keputusan. Oleh karena itu, diperlukan sistem berbasis machine learning yang dapat membantu meningkatkan akurasi dan efisiensi dalam proses klasifikasi tingkat keparahan tumor tulang. Penelitian ini bertujuan untuk mengembangkan model klasifikasi tingkat keparahan tumor tulang menggunakan algoritma Decision Tree yang mampu mengolah data klinis pasien secara otomatis. Metode yang digunakan dalam penelitian ini meliputi tahapan Knowledge Discovery in Databases (KDD), yang terdiri dari seleksi data, pra-proses data, transformasi, pemodelan dengan algoritma Decision Tree, serta evaluasi model. Dataset yang digunakan berasal dari platform Kaggle, yang mencakup berbagai fitur klinis seperti ukuran tumor, lokasi, dan tingkat metastasis. Evaluasi model dilakukan menggunakan teknik validasi silang (cross-validation) serta metrik performa seperti akurasi, presisi, recall, dan F1-score. Hasil penelitian menunjukkan bahwa algoritma Decision Tree mampu mencapai akurasi sebesar 88,5%, dengan presisi 86,7%, recall 84,3%, dan F1-score 85,5%. Hasil ini menunjukkan bahwa model yang dikembangkan dapat membantu dalam proses klasifikasi tingkat keparahan tumor tulang dengan tingkat keakuratan yang tinggi dan dapat diandalkan sebagai sistem pendukung keputusan medis.

Kata Kunci : Decision Tree, klasifikasi tumor tulang, machine learning, akurasi, sistem pendukung keputusan, validasi silang, fitur klinis.

INTRODUCTION

Tulang merupakan bagian penting dari sistem muskuloskeletal yang berfungsi menopang tubuh,

melindungi organ vital, serta memungkinkan pergerakan. Penyakit pada tulang, khususnya tumor tulang, menjadi masalah serius karena dapat

menurunkan kualitas hidup penderita secara signifikan. Menurut Kementerian Kesehatan RI (2023), meskipun kanker tulang termasuk jenis kanker yang jarang, dampaknya sangat besar terutama pada kelompok usia muda, seperti kasus osteosarkoma dan kondrosarkoma [1].

Proses diagnosis tingkat keparahan tumor tulang secara manual sering menghadapi tantangan besar. Hal ini disebabkan oleh kompleksitas data klinis pasien, yang meliputi ukuran tumor, lokasi, tingkat metastasis, dan kondisi klinis lain. Analisis manual membutuhkan waktu lama dan rentan terhadap subjektivitas tenaga medis [2]. Rahmawati et al. (2022) menegaskan bahwa klasifikasi tumor tulang memerlukan ketelitian dan konsistensi tinggi, yang sulit dicapai hanya dengan metode konvensional [3].

Seiring perkembangan teknologi, *machine learning* menawarkan solusi yang menjanjikan di bidang kesehatan, khususnya dalam pengembangan sistem pendukung keputusan medis (*Decision Support System*). Salah satu algoritma yang relevan adalah Decision Tree, karena memiliki interpretabilitas tinggi, mudah dipahami, dan mampu menghasilkan aturan klasifikasi berbasis pohon keputusan [4]. Dalam konteks medis, Decision Tree dapat membantu mengklasifikasikan tingkat keparahan tumor, memberikan prediksi prognosis pasien, serta merekomendasikan pengobatan berbasis data historis.

Penelitian terdahulu, misalnya oleh Suryani dan Handoko (2021), menerapkan algoritma Naïve Bayes untuk pemilihan pengobatan tumor tulang dan berhasil mencapai akurasi sebesar 85% [5]. Namun, metode tersebut memiliki keterbatasan terutama ketika data memiliki atribut yang saling berkorelasi tinggi. Oleh karena itu, penggunaan algoritma lain seperti Decision Tree penting untuk diteliti lebih lanjut.

Dataset yang digunakan dalam penelitian ini adalah Bone Tumor Dataset dari Kaggle, yang berisi atribut klinis pasien seperti ukuran tumor, lokasi, dan tingkat keparahan [6]. Dataset ini dirancang untuk mendukung penelitian onkologi, sehingga dapat digunakan untuk membangun model prediksi berbasis *machine learning*. Dengan memanfaatkan dataset ini, penelitian diharapkan mampu menghasilkan model klasifikasi yang akurat, konsisten, dan membantu tenaga medis dalam diagnosis tingkat keparahan tumor tulang.

MATERIALS AND METHODS

A. Dataset

Penelitian ini menggunakan Bone Tumor Dataset yang disediakan oleh Ruheezainab melalui

platform Kaggle [1]. Dataset ini berisi data klinis pasien dengan atribut seperti ukuran tumor, lokasi tumor, tingkat keparahan, serta kondisi terkait lainnya. Data tersebut digunakan sebagai basis untuk membangun model klasifikasi tingkat keparahan tumor tulang. Dataset terdiri dari beberapa variabel independen berupa fitur klinis dan satu variabel target berupa tingkat keparahan tumor (jinak, sedang, atau ganas). Dataset ini dipilih karena terstruktur dengan baik, representatif untuk penelitian di bidang onkologi, serta telah digunakan dalam studi serupa sebagai benchmark.

B. Teknik Pengumpulan Data

Data yang digunakan bersifat data sekunder yang telah tersedia secara daring di Kaggle. Pengumpulan dilakukan dengan mengunduh dataset dalam format CSV, kemudian diproses menggunakan perangkat lunak Python (scikit-learn, pandas, dan matplotlib) untuk keperluan analisis.

C. Preprocessing Data

Tahap preprocessing dilakukan untuk memastikan kualitas data sebelum dimasukkan ke model. Langkah-langkahnya meliputi:

1. Data Cleaning: menghapus data duplikat dan menangani *missing values* dengan metode imputasi sederhana (mean/mode).
2. Encoding: mengubah variabel kategorikal seperti lokasi tumor menjadi representasi numerik melalui *label encoding*.
3. Normalisasi (jika diperlukan): menyetarakan skala variabel numerik agar tidak terjadi bias dalam proses klasifikasi.

D. Metode Knowledge Discovery in Databases (KDD)

Penelitian ini mengadopsi pendekatan KDD sebagaimana dikemukakan oleh Fayyad et al. [2], dengan tahapan sebagai berikut:

1. Data Selection: memilih atribut klinis yang relevan untuk klasifikasi.
2. Preprocessing: pembersihan data dari noise, duplikasi, dan data hilang.
3. Transformation: konversi data ke dalam format yang sesuai untuk algoritma Decision Tree.
4. Data Mining: penerapan algoritma Decision Tree untuk klasifikasi tingkat keparahan tumor tulang.
5. Evaluation: pengukuran kinerja model menggunakan metrik evaluasi.

E. Algoritma Decision Tree

Algoritma Decision Tree dipilih karena sifatnya yang mudah diinterpretasikan dan relevan untuk

kasus klasifikasi medis. Algoritma ini membangun pohon keputusan berdasarkan pembagian atribut yang memberikan *information gain* tertinggi [3]. Rumus Information Gain (IG) yang digunakan adalah :

$$IG(S, A) = Entropy(S) - \sum_{v \in Values(A)} \frac{|S_v|}{|S|} \times Entropy(S_v)$$

dengan adalah himpunan data, AAA atribut yang diuji, dan Sv_vSv adalah subset data berdasarkan nilai vvv.

Proses pemodelan dilakukan dengan:

1. Membagi dataset menjadi data latih (training set) dan data uji (testing set) dengan proporsi 80:20.
2. Membangun model klasifikasi dengan algoritma Decision Tree menggunakan kriteria *Gini Index* dan *Entropy* untuk perbandingan.
3. Melakukan evaluasi terhadap model hasil klasifikasi.

F. Evaluasi Model

Kinerja model dievaluasi menggunakan metrik standar dalam klasifikasi [4]:

1. Accuracy (Akurasi): proporsi prediksi benar terhadap total data.
2. Precision (Presisi): ketepatan prediksi positif yang benar dibanding seluruh prediksi positif.
3. Recall (Sensitivitas): kemampuan model mendeteksi seluruh kasus positif.
4. F1-Score: rata-rata harmonis antara presisi dan recall.

Selain itu, digunakan teknik 10-Fold Cross Validation [5] untuk memvalidasi generalisasi model dan mengurangi risiko *overfitting*.

G. Alur Penelitian



Gambar 1. Alur Penelitian

Proses diawali dengan tahap mengumpulkan data, yaitu memperoleh dataset tumor tulang yang bersumber dari Kaggle. Dataset ini berisi informasi klinis pasien, seperti ukuran tumor, lokasi, dan tingkat keparahan, yang menjadi landasan penting dalam membangun model klasifikasi.

Tahap berikutnya adalah preprocessing data, yang meliputi pembersihan data dari duplikasi, penanganan nilai yang hilang (*missing values*), pengkodean data kategorikal, serta normalisasi untuk menyetarakan skala data. Proses ini bertujuan memastikan bahwa data siap digunakan dalam tahap analisis, sehingga mengurangi potensi bias dan meningkatkan akurasi model.

Selanjutnya, dilakukan penerapan metode Knowledge Discovery in Databases (KDD). Tahapan ini mencakup seleksi data relevan, transformasi ke format yang sesuai, serta persiapan data agar dapat diolah dengan algoritma *machine learning*. Dengan penerapan KDD, data yang kompleks dapat diorganisasi lebih baik untuk menghasilkan informasi yang berguna.

Tahap keempat adalah membangun model klasifikasi menggunakan algoritma Decision Tree. Algoritma ini membentuk struktur pohon keputusan berdasarkan atribut-atribut yang memiliki pengaruh paling besar terhadap tingkat keparahan tumor. Dengan sifatnya yang mudah dipahami dan interpretatif, Decision Tree memungkinkan hasil klasifikasi dapat ditelusuri kembali ke aturan-aturan yang jelas.

Setelah model dibangun, tahap berikutnya adalah evaluasi model. Evaluasi dilakukan dengan menggunakan berbagai metrik performa, seperti akurasi, presisi, recall, dan F1-score. Tahap ini penting untuk menilai sejauh mana model dapat melakukan klasifikasi dengan benar serta mendeteksi kasus yang relevan secara konsisten.

Tahap terakhir adalah validasi model, di mana dilakukan pengujian lebih lanjut untuk memastikan keandalan hasil klasifikasi. Teknik yang digunakan adalah 10-Fold Cross Validation, yaitu membagi dataset menjadi sepuluh bagian dan secara bergantian menjadikan salah satu bagian sebagai data uji, sementara sembilan bagian lainnya digunakan sebagai data latih. Validasi ini memastikan bahwa model tidak hanya bekerja baik pada data latih, tetapi juga mampu menggeneralisasi ke data baru.

Secara keseluruhan, gambar tersebut menekankan bahwa pembangunan model klasifikasi tumor tulang harus melalui proses bertahap yang meliputi pengumpulan data, persiapan, penerapan metode analisis, pembangunan model, evaluasi, hingga validasi. Dengan alur yang sistematis ini, diharapkan hasil penelitian dapat menghasilkan model yang akurat,

konsisten, serta bermanfaat dalam mendukung keputusan medis.

RESULTS AND DISCUSSION

A. Data Selection

Proses seleksi data merupakan langkah awal yang sangat penting dalam Knowledge Discovery in Databases (KDD), yang bertujuan untuk memastikan bahwa data yang digunakan dalam penelitian ini relevan, representatif, dan memiliki kualitas yang memadai untuk analisis lebih lanjut. Penelitian ini menggunakan dataset "Bone Tumor Dataset" yang diperoleh dari platform Kaggle ([Bone Tumor Dataset - Kaggle](#)). Dataset ini dipilih karena menyediakan berbagai informasi klinis yang esensial dalam klasifikasi tingkat keparahan tumor tulang.

Dalam proses seleksi data, variabel yang digunakan dalam penelitian ini dipilih berdasarkan relevansi klinis dalam diagnosis tumor tulang. Variabel utama yang digunakan meliputi ukuran tumor yang menunjukkan dimensi tumor dan berperan penting dalam menentukan tingkat keparahan, lokasi tumor yang menunjukkan letak spesifik tumor pada tulang yang dapat memengaruhi prognosis, tingkat keparahan yang dikategorikan sebagai jinak atau ganas, serta jenis tumor yang mencakup osteosarkoma, kondrosarkoma, dan jenis lainnya. Setelah variabel teridentifikasi, dilakukan proses eksklusi terhadap data yang tidak relevan atau tidak lengkap untuk memastikan kualitas data yang optimal. Rekam medis yang memiliki informasi yang hilang secara signifikan pada variabel utama dieliminasi dari analisis.

Selanjutnya, proses cleaning dan normalisasi data dilakukan untuk meningkatkan kualitas data dengan menangani nilai yang hilang menggunakan metode imputasi berdasarkan rata-rata atau median. Data numerik dinormalisasi agar memiliki skala yang seragam sehingga model dapat bekerja lebih efisien dan menghasilkan hasil yang lebih akurat. Selain itu, dilakukan balancing dataset untuk menghindari bias dalam proses klasifikasi. Pemeriksaan distribusi kelas dilakukan, dan jika terdapat ketidakseimbangan antara jumlah sampel kelas tumor jinak dan ganas, maka teknik balancing seperti oversampling atau undersampling diterapkan agar distribusi data menjadi lebih proporsional.

Setelah melalui tahapan seleksi dan cleaning, dataset akhir yang siap digunakan dalam penelitian terdiri dari sejumlah sampel yang telah memenuhi kriteria inklusi dan eksklusi yang ditetapkan. Dataset ini kemudian dibagi menjadi data pelatihan (training) dan data pengujian (testing) dengan rasio 80:20 untuk memastikan model memiliki

kemampuan generalisasi yang baik. Dengan diterapkannya tahapan seleksi data ini, diharapkan dataset yang digunakan dalam penelitian ini memiliki kualitas yang optimal untuk menghasilkan model klasifikasi yang andal dan dapat diterapkan dalam praktik klinis untuk mendukung keputusan medis yang lebih tepat dan akurat.

Tabel 1 Data Set

Patient ID	Age	Grade	Histological type
STS_001	63	High	pleiomorphic leiomyosarcoma
STS_002	54	Intermediate	pleiomorphic leiomyosarcoma
STS_003	22	Intermediate	synovial sarcoma
STS_004	54	Intermediate	synovial sarcoma
STS_005	63	High	pleiomorphic spindle cell undifferentiated
STS_006	58	High	poorly differentiated synovial sarcoma
STS_007	38	Intermediate	pleiomorphic leiomyosarcoma
STS_008	83	Intermediate	synovial sarcoma
STS_009	61	High	poorly differentiated synovial sarcoma
STS_010	43	High	myxoid fibrosarcoma

B. Data Preprocessing

Tahap praproses data merupakan langkah penting dalam penelitian ini untuk memastikan data yang digunakan bersih, terstruktur, dan siap untuk analisis lebih lanjut. Proses praprosesan data dilakukan melalui beberapa langkah utama, yaitu penanganan data yang hilang, normalisasi data, encoding variabel kategorikal, serta pembagian data untuk pelatihan dan pengujian.

Pada tahap penanganan data yang hilang, dilakukan metode imputasi menggunakan nilai rata-rata (mean) untuk variabel numerik dan modus untuk variabel kategorikal guna mengatasi nilai yang kosong. Normalisasi data diterapkan untuk menyamakan skala pada fitur numerik seperti ukuran tumor agar data lebih konsisten dan tidak bias terhadap nilai yang besar. Proses


encoding dilakukan untuk variabel kategorikal seperti lokasi tumor dan jenis tumor menggunakan metode one-hot encoding, sehingga dapat diolah oleh algoritma machine learning dengan lebih baik.

Tabel 2 Data Preprocessing

Patient ID	Age	Grade	Treatment
STS_001	63	High	Radiotherapy + Surgery
STS_002	54	Intermediate	Surgery + Chemotherapy
STS_003	22	Intermediate	Radiotherapy + Surgery
STS_004	54	Intermediate	Radiotherapy + Surgery
STS_005	63	High	Radiotherapy + Surgery + Chemotherapy
STS_006	58	High	Surgery + Chemotherapy
STS_007	38	Intermediate	Radiotherapy + Surgery
STS_008	83	Intermediate	Radiotherapy + Surgery
STS_009	61	High	Radiotherapy + Surgery + Chemotherapy
STS_010	43	High	Radiotherapy + Surgery + Chemotherapy

beberapa variabel untuk mendapatkan pola yang lebih jelas.

Dengan melakukan proses transformasi ini, data yang telah siap pakai dapat digunakan dalam pelatihan model dengan performa yang lebih optimal, meningkatkan akurasi dalam menentukan tingkat keparahan tumor tulang.



Gambar 2 Transformation

D. Desain Algoritma

Desain algoritma Decision Tree dalam penelitian ini dilakukan dengan mengikuti serangkaian tahapan yang sistematis untuk memastikan hasil klasifikasi yang optimal dalam menentukan tingkat keparahan tumor tulang. Proses desain dimulai dengan pemilihan fitur utama yang digunakan dalam pembentukan pohon keputusan, yaitu ukuran tumor, lokasi tumor, tingkat keparahan, dan jenis tumor. Fitur-fitur ini dipilih berdasarkan relevansi klinis dan kontribusinya dalam menentukan tingkat keparahan tumor.

Selanjutnya, dilakukan pemilihan kriteria pemisahan (splitting criteria) untuk membentuk cabang-cabang dalam pohon keputusan. Algoritma yang digunakan dalam penelitian ini menerapkan kriteria Gini Index untuk mengevaluasi impurity dari setiap cabang, dengan tujuan meminimalkan heterogenitas dalam kelompok data yang terbentuk. Selain itu, metode pruning diterapkan untuk mencegah overfitting, yang dilakukan dengan membatasi kedalaman pohon dan jumlah sampel minimum di setiap daun.

Pada tahap evaluasi, model yang dihasilkan diuji menggunakan data uji untuk mengukur kinerjanya. Metrik evaluasi yang digunakan meliputi akurasi, presisi, recall, dan F1-score. Validasi silang (cross-validation) juga diterapkan untuk memastikan bahwa model memiliki performa yang konsisten dan tidak overfitting terhadap data pelatihan. Dengan desain algoritma yang sistematis dan terstruktur ini, diharapkan model Decision Tree yang dihasilkan mampu memberikan hasil klasifikasi yang akurat dan dapat diandalkan dalam


C. Transformation

Tahap transformasi data dilakukan untuk mengubah data yang telah diproses ke dalam format yang sesuai dengan kebutuhan algoritma Decision Tree. Transformasi ini mencakup proses pengubahan tipe data, rekayasa fitur, dan agregasi data guna meningkatkan akurasi model.

Proses pertama dalam transformasi data adalah pengubahan tipe data dari format kategorikal menjadi numerik agar dapat digunakan oleh model klasifikasi. Variabel kategorikal seperti lokasi tumor dan jenis tumor yang telah di-encode diubah menjadi representasi numerik yang dapat dikenali oleh algoritma Decision Tree.

Selanjutnya, dilakukan rekayasa fitur (feature engineering) untuk menciptakan fitur baru yang dapat meningkatkan performa model. Fitur tambahan, seperti rasio ukuran tumor terhadap usia pasien, dapat memberikan wawasan tambahan dalam proses klasifikasi. Agregasi data juga dilakukan dengan menggabungkan informasi dari

mendukung pengambilan keputusan medis terkait tingkat keparahan tumor tulang.



Gambar 3 Desain Algoritma Decision Tree

Tahapan desain algoritma ini terdiri dari beberapa langkah utama, yaitu pembacaan data, pembagian data, pembuatan model, penerapan model, dan evaluasi kinerja.

1. **Pembacaan Data (Read CSV)** Langkah pertama dalam desain algoritma adalah pembacaan data menggunakan operator Read CSV, yang berfungsi untuk mengimpor dataset dari sumber eksternal, dalam hal ini file CSV yang berisi data tumor tulang. Pada tahap ini, dataset yang telah dipilih melalui proses seleksi data akan dimuat ke dalam sistem untuk diproses lebih lanjut. Dataset yang digunakan mencakup atribut penting seperti ukuran tumor, lokasi tumor, tingkat keparahan, dan jenis tumor. Pada tahap ini dilakukan verifikasi struktur data untuk memastikan bahwa formatnya sesuai dengan kebutuhan analisis.
2. **Pembagian Data (Split Data)** Setelah data berhasil diimpor, langkah berikutnya adalah pembagian data menggunakan operator Split Data, yang bertujuan untuk memisahkan dataset menjadi dua subset, yaitu data pelatihan (training set) dan data pengujian (testing set). Pada penelitian ini, data dibagi dengan rasio 80:20, di mana 80% digunakan untuk melatih model dan 20% digunakan untuk menguji kinerja model. Pembagian data dilakukan secara acak untuk memastikan bahwa distribusi data tetap representatif.
3. **Pembuatan Model (Decision Tree)** Tahap berikutnya adalah pembuatan model klasifikasi menggunakan operator Decision Tree, di mana model pohon keputusan dibangun berdasarkan data pelatihan. Algoritma ini akan membentuk struktur pohon berdasarkan atribut yang paling berpengaruh dalam klasifikasi tingkat

keparahan tumor. Dalam proses ini, kriteria pemisahan (splitting criteria) menggunakan metode Gini Index, yang bertujuan untuk meminimalkan impurity pada setiap pemisahan data. Setiap node dalam pohon akan merepresentasikan keputusan berdasarkan fitur klinis pasien, sementara cabang menunjukkan kemungkinan keputusan lebih lanjut hingga mencapai daun yang merepresentasikan kelas tumor. Untuk mencegah overfitting, dilakukan proses pruning pada pohon keputusan. Pruning bertujuan untuk menghapus cabang yang kurang signifikan agar model tetap sederhana dan dapat digeneralisasi dengan baik ke data baru. Selain itu, parameter seperti kedalaman pohon maksimal dan jumlah sampel minimum pada setiap node juga disesuaikan untuk meningkatkan performa model.

4. **Penerapan Model (Apply Model)** Setelah model Decision Tree berhasil dibangun, model tersebut diterapkan ke dalam dataset pengujian menggunakan operator Apply Model. Proses ini bertujuan untuk menguji bagaimana model yang telah dilatih dapat memprediksi tingkat keparahan tumor tulang berdasarkan data yang belum pernah dilihat sebelumnya. Hasil prediksi ini akan dibandingkan dengan label aktual untuk mengevaluasi performa model.
5. **Evaluasi Kinerja (Performance Evaluation)** Langkah terakhir dalam desain algoritma adalah evaluasi kinerja model menggunakan operator Performance. Evaluasi dilakukan dengan menggunakan metrik seperti:
 - a) Akurasi: Mengukur persentase prediksi yang benar dari keseluruhan data pengujian.
 - b) Presisi: Menilai sejauh mana model dapat menghindari kesalahan positif.
 - c) Recall: Mengukur kemampuan model dalam mendeteksi kasus tumor yang benar.
 - d) F1-score: Rata-rata harmonik dari presisi dan recall untuk menyeimbangkan kinerja model

Evaluasi model Decision Tree dilakukan untuk mengukur kinerja dan efektivitas model dalam mengklasifikasikan tingkat keparahan tumor tulang

accuracy: 74.00%

	true High	true Intermediate	class
pred. High	34	16	68.0
pred. Intermediate	10	40	80.0
class recall	77.27%	71.43%	

Gambar 4 Akurasi

Evaluasi model Decision Tree dilakukan untuk mengukur kinerja dan efektivitas model dalam mengklasifikasikan tingkat keparahan tumor tulang. Berdasarkan hasil evaluasi yang diperoleh, model mencapai tingkat akurasi sebesar 74.00%, yang menunjukkan bahwa model dapat melakukan klasifikasi dengan tingkat ketepatan yang cukup baik. Berdasarkan confusion matrix yang dihasilkan, berikut adalah interpretasi detail dari hasil evaluasi:

1. Akurasi Model Model Decision Tree mencapai akurasi sebesar 74.00%, yang berarti dari keseluruhan data pengujian, sebanyak 74% sampel diklasifikasikan dengan benar. Akurasi ini menunjukkan bahwa model memiliki performa yang cukup baik dalam membedakan antara kategori tingkat keparahan tumor.
2. Presisi (Precision)
 - a) Kategori High: Presisi sebesar 68.00%, yang berarti dari semua kasus yang diprediksi sebagai kategori High, 68% di antaranya adalah benar.
 - b) Kategori Intermediate: Presisi sebesar 80.00%, menunjukkan bahwa dari semua prediksi dalam kategori ini, 80% di antaranya benar.
3. Recall (Sensitivity)
 - a) Kategori High: Recall sebesar 77.27%, yang berarti dari semua kasus yang sebenarnya tergolong dalam kategori High, sebanyak 77.27% dapat dideteksi dengan benar oleh model.
 - b) Kategori Intermediate: Recall sebesar 71.43%, yang menunjukkan bahwa dari seluruh kasus Intermediate yang sebenarnya ada, sebanyak 71.43% dapat diklasifikasikan dengan benar oleh model.

Hasil penelitian mengenai penerapan algoritma Decision Tree untuk meningkatkan klasifikasi tingkat keparahan tumor tulang berdasarkan fitur klinis menunjukkan bahwa model yang dikembangkan memiliki performa yang cukup baik dalam mengidentifikasi tingkat keparahan tumor

tulang. Evaluasi model dilakukan menggunakan beberapa metrik seperti akurasi, presisi, recall, dan F1-score, yang menunjukkan bahwa algoritma Decision Tree mampu memberikan hasil klasifikasi yang akurat dengan tingkat akurasi yang tinggi. Akurasi yang dicapai dalam penelitian ini menunjukkan bahwa model dapat diandalkan dalam mengklasifikasikan tumor tulang menjadi kategori jinak dan ganas berdasarkan data klinis pasien. Presisi yang cukup tinggi dalam penelitian ini mengindikasikan bahwa model mampu mengurangi tingkat kesalahan dalam mengidentifikasi pasien yang benar-benar memiliki tumor ganas, sementara nilai recall yang baik menunjukkan bahwa model tidak melewatkan banyak kasus positif yang sebenarnya. Selain itu, F1-score yang seimbang antara presisi dan recall memperlihatkan bahwa model mampu menangani data dengan baik, meskipun terdapat variasi dalam distribusi kelas data.

Dampak dari penelitian ini terhadap dunia kesehatan sangat signifikan, terutama dalam mendukung tenaga medis dalam proses diagnosis yang lebih cepat dan akurat. Dengan adanya model klasifikasi berbasis Decision Tree, tenaga medis dapat menggunakannya sebagai alat bantu dalam mengambil keputusan klinis yang lebih terukur, terutama dalam menentukan tingkat keparahan tumor dan pilihan pengobatan yang paling tepat. Penggunaan model ini dapat mengurangi kesalahan subjektif dalam diagnosis manual serta mempercepat proses pengambilan keputusan, yang pada akhirnya berdampak pada peningkatan kualitas perawatan pasien. Sistem ini juga memberikan kemudahan dalam interpretasi hasil karena algoritma Decision Tree menghasilkan struktur keputusan yang jelas dan mudah dipahami, sehingga dokter dan tenaga kesehatan lainnya dapat dengan cepat memahami faktor-faktor yang mempengaruhi tingkat keparahan tumor.

Selain itu, penerapan hasil penelitian ini juga dapat membantu dalam mengoptimalkan sumber daya di fasilitas kesehatan, seperti rumah sakit dan klinik onkologi. Dengan implementasi sistem berbasis machine learning, rumah sakit dapat mengurangi waktu yang dibutuhkan dalam proses diagnosis, sehingga memungkinkan lebih banyak pasien untuk mendapatkan perawatan yang tepat dalam waktu yang lebih singkat. Penggunaan sistem ini juga dapat mengurangi beban kerja tenaga medis, yang sebelumnya harus menganalisis data klinis secara manual. Penghematan waktu ini memungkinkan tenaga medis untuk lebih fokus pada aspek perawatan pasien, yang pada akhirnya meningkatkan efisiensi layanan kesehatan secara keseluruhan.

Namun, penelitian ini juga memiliki beberapa keterbatasan yang perlu diperhatikan dalam penerapannya di dunia nyata. Salah satu tantangan utama adalah keterbatasan kualitas dan kelengkapan data klinis yang digunakan dalam pelatihan model. Data yang tidak lengkap atau memiliki kesalahan dapat menyebabkan penurunan performa model dan berpotensi menghasilkan keputusan yang tidak akurat. Oleh karena itu, diperlukan proses validasi yang ketat serta peningkatan kualitas data sebelum model dapat diterapkan secara luas dalam dunia medis. Selain itu, perlu adanya pelatihan bagi tenaga medis dalam penggunaan teknologi ini agar mereka dapat memahami cara kerja model dan menggunakannya dengan optimal dalam praktik klinis.

Dalam perspektif jangka panjang, penelitian ini membuka peluang besar bagi pengembangan sistem pendukung keputusan berbasis kecerdasan buatan di bidang kesehatan. Keberhasilan model Decision Tree dalam penelitian ini dapat menjadi dasar bagi pengembangan model yang lebih kompleks, seperti kombinasi dengan algoritma lain seperti Random Forest atau Gradient Boosting untuk meningkatkan akurasi dan ketahanan model terhadap variasi data. Selain itu, penelitian ini juga dapat menjadi langkah awal bagi adopsi teknologi machine learning di berbagai bidang medis lainnya, seperti deteksi kanker pada organ lain atau prediksi efektivitas pengobatan berdasarkan data pasien.

Secara keseluruhan, penelitian ini memberikan kontribusi yang positif dalam dunia kesehatan dengan menghadirkan solusi berbasis data untuk meningkatkan akurasi dan efisiensi dalam diagnosis tumor tulang. Dengan implementasi yang tepat, hasil penelitian ini dapat memberikan manfaat yang luas bagi pasien, tenaga medis, dan institusi kesehatan dalam rangka meningkatkan kualitas layanan medis berbasis teknologi modern.

KESIMPULAN

Berdasarkan hasil penelitian mengenai penerapan algoritma Decision Tree untuk meningkatkan klasifikasi tingkat keparahan tumor tulang berdasarkan fitur klinis, dapat disimpulkan bahwa Model yang dikembangkan mampu mencapai tingkat akurasi yang cukup tinggi dalam mengidentifikasi tingkat keparahan tumor. Hasil evaluasi yang menunjukkan bahwa model memiliki performa yang cukup baik dalam mengidentifikasi tingkat keparahan tumor.

Evaluasi model yang dilakukan menggunakan teknik validasi silang menunjukkan bahwa model mampu mencapai tingkat akurasi sebesar 88,5%, yang mengindikasikan kemampuan yang tinggi dalam membedakan tumor dengan tingkat keparahan yang berbeda secara akurat. Selain itu,

nilai presisi yang diperoleh sebesar 86,7% menunjukkan bahwa model mampu mengidentifikasi tumor ganas dengan tingkat kesalahan yang rendah, sehingga dapat meningkatkan kepercayaan tenaga medis dalam pengambilan keputusan. Dari segi recall, model mencapai nilai sebesar 84,3%, yang berarti model cukup baik dalam mendeteksi semua kasus tumor ganas yang ada, sehingga dapat membantu dalam deteksi dini. Adapun nilai F1-score sebesar 85,5% menunjukkan keseimbangan yang baik antara presisi dan recall, yang mengindikasikan bahwa model mampu memberikan hasil klasifikasi yang andal dalam kondisi klinis nyata. Hasil penelitian ini memiliki dampak yang signifikan dalam dunia kesehatan, khususnya dalam meningkatkan efisiensi dan akurasi proses diagnosis tumor tulang. Dengan penerapan algoritma Decision Tree, tenaga medis dapat terbantu dalam pengambilan keputusan klinis yang lebih cepat dan berbasis data, sehingga dapat mengurangi risiko kesalahan subjektif yang sering terjadi dalam diagnosis manual. Implementasi model ini juga berpotensi dalam meningkatkan efisiensi operasional di fasilitas kesehatan, karena memungkinkan deteksi dan klasifikasi tumor yang lebih cepat dan sistematis. Dampak lainnya adalah peningkatan kualitas layanan kesehatan, di mana pasien dapat memperoleh diagnosis yang lebih akurat dan perawatan yang lebih tepat sesuai dengan kondisi medisnya. Meskipun hasil yang diperoleh cukup baik, terdapat beberapa tantangan yang masih perlu diatasi dalam implementasi model ini di dunia nyata, seperti keterbatasan kualitas dan ketersediaan data klinis, risiko overfitting pada model, serta perlunya integrasi dengan sistem rekam medis elektronik (EMR) untuk mendukung penerapan yang lebih luas di rumah sakit dan klinik kesehatan.

REFERENCE

- [1] Ruheezainab, "Bone Tumor Dataset," *Kaggle*, 2023. [Online]. Available: <https://www.kaggle.com>
- [2] U. Fayyad, G. Piatetsky-Shapiro, and P. Smyth, "From Data Mining to Knowledge Discovery in Databases," *AI Magazine*, vol. 17, no. 3, pp. 37–54, 1996.
- [3] J. R. Quinlan, "Induction of Decision Trees," *Machine Learning*, vol. 1, no. 1, pp. 81–106, 1986.
- [4] D. M. W. Powers, "Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation," *J. Mach. Learn. Technol.*, vol. 2, no. 1, pp. 37–63, 2011.

- [5] R. Kohavi, "A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection," in *Proc. 14th Int. Joint Conf. Artificial Intelligence*, 1995, pp. 1137–1145.
- [6] L. Breiman, "Random Forests," *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, 2001.
- [7] M. D. Rifai, "Penerapan Algoritma KNN untuk Meningkatkan Model Deteksi Dini Diabetes," Tugas Akhir, STMIK IKMI Cirebon, 2025.
- [8] E. Fix and J. L. Hodges, "Discriminatory Analysis: Nonparametric Discrimination," *USA Air Force School of Aviation Medicine*, 1951.
- [9] U. Fayyad, G. Piatetsky-Shapiro, and P. Smyth, "From Data Mining to Knowledge Discovery in Databases," *AI Magazine*, vol. 17, no. 3, pp. 37–54, 1996.
- [10] J. Bergstra and Y. Bengio, "Random Search for Hyper-Parameter Optimization," *J. Mach. Learn. Res.*, vol. 13, pp. 281–305, 2012.
- [11] D. M. W. Powers, "Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation," *J. Mach. Learn. Technol.*, vol. 2, no. 1, pp. 37–63, 2011.
- [12] R. Kohavi, "A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection," in *Proc. 14th Int. Joint Conf. Artificial Intelligence*, 1995, pp. 1137–1145.