



PREDIKSI IMPLAN GIGI MENGGUNAKAN ALGORITMA MACHINE LEARNING

Alisa Zebua¹,
Koko handoko²

¹Program Studi Teknik Informatika, Universitas Putera Batam

²Program Studi Teknik Informatika, Universitas Putera Batam

email: pb210210066@upbatam.ac.id

ABSTRACT

Advances in digital technologies, particularly artificial intelligence (AI), are transforming healthcare practices, including dental implant decision-making. This study introduces a machine learning model utilizing the Classification and Regression Tree (CART) algorithm to estimate dental implant candidacy, drawing on anonymized patient records from Ellisa Dental Clinic, Batam. The dataset comprises various demographic and clinical attributes such as age, sex, smoking patterns, bone condition, and the presence of chronic illnesses including diabetes, hypertension, and autoimmune disorders. The exploratory analysis reveals that factors like heavy smoking, systemic diseases, and jawbone integrity substantially affect implant suitability. The quality and consistency of the dataset support robust modeling. The proposed system is intended to function as a clinical decision aid, offering dentists evidence-based recommendations regarding patient eligibility. This work demonstrates the potential of predictive analytics to enhance decision accuracy and streamline dental care, contributing to the integration of AI into routine clinical workflows.

Keywords: Artificial intelligence; Dental implant; Decision tree; Eligibility prediction; Medical records.

PENDAHULUAN

Perkembangan teknologi digital, khususnya AI, telah mengubah layanan kesehatan, termasuk kedokteran gigi. Pemasangan implan gigi memerlukan evaluasi cermat, namun sering kali masih bergantung pada penilaian subjektif dokter. Penelitian sebelumnya menunjukkan bahwa algoritma Decision Tree (CART) efektif dalam menganalisis data medis dan menghasilkan prediksi yang akurat. Penelitian ini penting untuk menghadirkan sistem pendukung keputusan klinis yang

andal, terutama di klinik dengan pasien beragam. Dengan memanfaatkan data rekam medis seperti usia, jenis kelamin, kebiasaan merokok, kondisi tulang rahang, dan riwayat penyakit kronis, model prediktif diharapkan dapat menyaring pasien layak implan secara lebih tepat.

Machine Learning atau pembelajaran mesin merupakan cabang dari kecerdasan buatan yang terus berkembang, berfokus pada kemampuan sistem komputer untuk mengenali pola dan belajar dari data (Wardhana et al., 2023). Beberapa penelitian sebelumnya



telah menunjukkan potensi algoritma CART dalam klasifikasi medis, namun belum banyak diterapkan secara spesifik pada kasus implan gigi di Indonesia. Penelitian ini bertujuan untuk membangun model prediksi kelayakan implan menggunakan data dari Klinik Ellisa Dental di Batam, sebagai bentuk kontribusi terhadap digitalisasi layanan kesehatan gigi lokal. Rencana pemecahan masalah dilakukan melalui pendekatan machine learning, dimulai dari proses prapemrosesan data, pelatihan model, hingga evaluasi performa prediksi, guna memastikan validitas dan aplikabilitas model di lingkungan klinis.

KAJIAN TEORI

2.1 Artificial intelligence (AI)

Dengan pesatnya kemajuan teknologi, kecerdasan buatan (AI) kini berperan penting dalam berbagai aspek kehidupan. AI dirancang untuk meniru cara berpikir manusia dalam menyelesaikan tugas kompleks secara otomatis. Melalui algoritma pembelajaran mesin, AI mampu menganalisis data besar, mengenali pola, dan menghasilkan prediksi dengan akurasi tinggi. Teknologi ini banyak dimanfaatkan di sektor kesehatan, bisnis, pendidikan, dan manufaktur untuk meningkatkan efisiensi dan mempercepat proses kerja (Situmorang & Handoko, 2024).

Perkembangan AI dalam bidang kesehatan memberikan dampak besar, terutama dalam mendukung analisis medis secara akurat (Murdoch, 2021). Banyak institusi kesehatan mulai mengadopsinya karena AI dapat meringankan tugas tenaga medis, bahkan berpotensi menggantikan sebagian peran dokter (Trenggono & Bachtiar, 2023).

2.2 Machine learning

Keberhasilan penerapan machine learning sangat bergantung pada kualitas dan jumlah data yang tersedia. Semakin besar dan beragam data pelatihan, semakin tinggi pula akurasi dan kemampuan model dalam melakukan generalisasi terhadap data baru (Handoko, 2025). Machine learning, sebagai bagian dari kecerdasan buatan, berfungsi untuk mengolah data serta memprediksi hasil tanpa campur tangan langsung dari manusia. Tujuan utamanya adalah memberikan solusi otomatis terhadap suatu permasalahan berdasarkan pola yang telah dipelajari dari data historis. Fungsinya mencakup deskriptif (menjelaskan data masa lalu), prediktif (memprediksi kejadian mendatang), dan preskriptif (menyediakan rekomendasi atau solusi) (Danial & Setiawati, 2024).

2.3 Decesion tree

Algoritma Decision Tree adalah metode klasifikasi yang menggunakan struktur pohon, di mana setiap simpul mewakili atribut yang dianalisis, dan cabangnya menunjukkan hasil dari analisis tersebut. Proses ini membagi data berdasarkan atribut tertentu hingga menghasilkan keputusan pada bagian akhir pohon (leaf). Kelebihan utama dari algoritma ini adalah kemudahannya dalam dipahami dan ditafsirkan, baik untuk data bertipe kategorik maupun numerik (Wardhana et al., 2023).

Dalam bidang medis, algoritma ini menyerupai proses pengambilan keputusan oleh dokter dalam menilai gejala dan kondisi pasien guna menentukan tingkat risiko, seperti rendah, sedang, atau tinggi (Siddiqui et al., 2024). Hasil akhir berupa aturan klasifikasi dapat dimanfaatkan sebagai acuan dalam mengenali berbagai penyakit, termasuk



penyakit pada gigi dan mulut(Ula et al., 2022).

2.4 Objek penelitian

bjek penelitian ini adalah Klinik Gigi Ellisa di Batam, yang beroperasi sejak Mei 2024 dan menyediakan layanan gigi lengkap, termasuk implan. Klinik ini dipilih karena pelayanan profesional dan teknologi modern. Data pasien dianalisis dengan algoritma Decision Tree untuk membangun model prediksi kelayakan implan guna mendukung keputusan klinis secara efisien dan akurat..

2.5 Implan gigi

Implan gigi merupakan intervensi medis yang digunakan untuk menggantikan gigi yang hilang, umumnya berbentuk sekrup berbahan titanium yang ditanam ke dalam tulang rahang sebagai penopang mahkota gigi. Prosedur ini memberikan stabilitas serta tampilan estetik yang menyerupai gigi alami (Kartikasari Halim & Poedjiastoeti, 2024). Sebelum pelaksanaan prosedur, pasien perlu menjalani evaluasi menyeluruh terhadap kondisi kesehatan umum, termasuk kepadatan tulang, kebiasaan merokok, dan keberadaan penyakit sistemik seperti diabetes(Raphael & Ariesanti, 2025). Tahapan pemasangan implan meliputi pemeriksaan awal, perencanaan perawatan, penanaman implan, dan pemasangan mahkota gigi. Evaluasi secara menyeluruh diperlukan untuk memaksimalkan tingkat keberhasilan tindakan tersebut.

2.6 Software pendukung

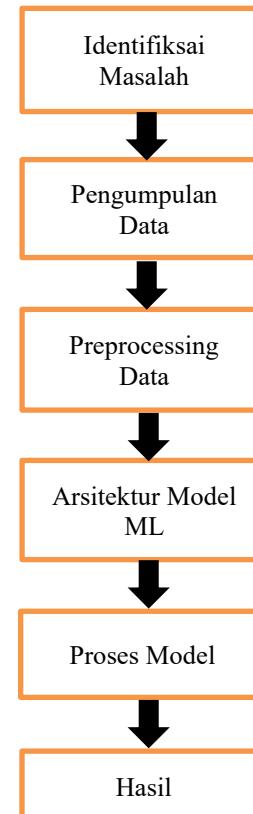
Penelitian ini menggunakan Anaconda Navigator sebagai lingkungan kerja dan Jupyter Notebook sebagai platform utama untuk analisis dan pemodelan. Jupyter mendukung integrasi kode, visualisasi, dan dokumentasi dalam satu antarmuka, serta umum digunakan di machine

learning karena kemampuannya menyajikan analisis secara konsisten dan efisien.(Asyrofi & Asyrofi, 2023)

METODE PENELITIAN

3.1 Desain Penelitian

Berikut ini adalah desain penelitian dari penelitian yang dilakukan:



Gambar 1 Desain Penelitian
(Sumber: Data Penelitian, 2025)

Penjelasan dari gambar di atas:

1. identifikasi Masalah

Langkah awal dalam penelitian ini adalah mengidentifikasi isu klinis yang relevan, yaitu bagaimana cara memprediksi tingkat



keberhasilan pemasangan implan gigi dengan mengandalkan informasi medis dari pasien. Permasalahan ini menjadi pijakan awal dalam penerapan teknologi machine learning untuk membantu proses pengambilan keputusan secara objektif di bidang kedokteran gigi.

2. Pengumpulan data

Data yang digunakan bersumber dari catatan medis pasien di Klinik Ellisa Dental. Informasi yang dihimpun mencakup usia, jenis kelamin, riwayat kesehatan seperti keberadaan penyakit sistemik (contohnya diabetes atau osteoporosis), kebiasaan merokok, kondisi tulang rahang, serta hasil akhir dari prosedur implant berhasil atau tidak yang akan menjadi target klasifikasi.

3. Preprosesing data

Sebelum membangun model prediktif, seluruh data mentah perlu melalui proses prapemrosesan. Tahap ini melibatkan pembersihan data dari duplikasi dan entri yang tidak lengkap, transformasi nilai numerik agar seragam, konversi data kategori (seperti jenis kelamin) ke dalam format yang bisa dikenali algoritma, serta pembagian data menjadi kelompok pelatihan dan pengujian

4. Arsitektur model *Machine Learning*

Model yang dipilih dalam studi ini adalah Decision Tree, sebuah metode klasifikasi yang menyusun data ke dalam struktur bercabang berdasarkan nilai-nilai fitur yang ada. Model ini terkenal karena kemudahannya dalam interpretasi dan kemampuannya menangani data kategorikal maupun numerik tanpa memerlukan asumsi distribusi data.

5. Proses model

Setelah data siap, proses pelatihan dilakukan dengan menggunakan dataset pelatihan. Tahapan ini mencakup pengembangan model awal, pengujian kinerja dengan validasi awal, serta

penyesuaian parameter agar hasil prediksi menjadi lebih akurat dan stabil. Penyetelan dilakukan untuk meningkatkan generalisasi model terhadap data yang belum pernah dilihat sebelumnya.

6. Hasil

Untuk mengukur kemampuan model dalam memprediksi keberhasilanimplan, digunakan data uji yang terpisah dari data pelatihan. Evaluasi dilakukan dengan menggunakan berbagai metrik performa seperti akurasi, presisi, recall, F1-score, serta confusion matrix. Hasil evaluasi ini memberikan gambaran sejauh mana model dapat bekerja secara efektif dalam skenario klinis yang nyata.

3.2 Proses Model Algoritma *Decision Tree*

Untuk memulai melakukan proses ini, tahapan pertama adalah:

a. Data Loading

Setelah memasukkan kumpulan data "Dataset_Implan_Gigi.csv" ke dalam pandas DataFrame, tampilkan informasi.

Dengan menggunakan pustaka pandas dengan encoding 'latin-1', program ini dapat membaca file CSV bernama Dataset_Implan_Gigi.csv. Itu juga dapat menampilkan isi awal file serta informasi strukturnya melalui df.head() dan df.info. Program ini memiliki blok try-except untuk memperbaiki berbagai kesalahan membaca file. Jika file tidak ditemukan, akan muncul pesan "Kesalahan: 'Tidak dapat memparse file CSV. Periksa format dan garis besar file.'" Jika file tidak ditemukan, akan muncul pesan "Kesalahan: 'Dataset_Implan_Gigi.csv' tidak ditemukan." Selain kesalahan ini, program akan menemukan dan mencetaknya. Metode ini tidak hanya



membuat program lebih aman tetapi juga memberi tahu orang tentang kemungkinan kegagalan pembacaan file data.

b. *Data Exploration*

Program ini menggunakan eksplorasi data statistik dan visual untuk memahami struktur dataset implan gigi. Pertama, program melihat tipe data dan menemukan nilai yang hilang. Kemudian, distribusi data numerik, seperti usia dan jumlah gigi yang hilang, ditampilkan dengan histogram dan plot box. Selanjutnya, program mengevaluasi nilai khusus untuk atribut kategorikal seperti jenis kelamin, status merokok, dan kondisi kesehatan, dan melihat bagaimana atribut ini berkorelasi dengan variabel target Layak Implant. Hasilnya memberikan gambaran yang lebih mendalam, yang membantu pemahaman awal data dan berfungsi sebagai dasar untuk pemodelan atau analisis lanjutan.

c. *Data Cleaning*

Pembersihan dan Praproses Data Penalaran: Menstandarisasi nilai, mengubah tipe data jika perlu, menangani outlier dalam kategori "Usia" dan "Jumlah Gigi Hilang", dan kemudian menikmati fitur kategoris. Tujuannya adalah untuk membuat nilai kategori konsisten (misalnya, membedakan nilai "pria" dari nilai "pria"), mengonversi data numerik ke tipe yang tepat, menangani outlier dengan winsorization, mengubah fitur kategori ke bentuk numerik dengan menggunakan encoding satu-hot, dan menghasilkan dataset terakhir yang siap untuk pelatihan model.

d. *Data Engineering*

Analisis korelasi antar fitur, pembuatan fitur polinomial, penyimpangan fitur numerik, dan pembuatan kerangka data akhir adalah semua bagian dari Rekayasa Fitur untuk Peningkatan Performa Model. Tujuan program Python adalah untuk melakukan prapemrosesan data sebelum digunakan dalam model pembelajaran mesin, terutama untuk kasus klasifikasi seperti memprediksi kelayakan implan gigi.

e. *Data Splitting*

Data dibagi oleh program menjadi tiga bagian utama (data splitting). Proses pelatihan dan evaluasi model pembelajaran mesin terdiri dari set pelatihan, validasi, dan tes.

Langkah Perhitungan Pembagian Dataset:

- Untuk dataset awal, Anda dapat menghitung jumlah total data dengan menggunakan hasil pembagian berikut: jumlah baris (data observasi): 237 (train)+30 (val)+30 (test)=297 data jumlah fitur (kolom) untuk X: 328 fitur Target y memiliki dua kolom, yang menunjukkan bahwa target telah dikodekan menjadi dua kelas satu-hot.

- Pembagian Data: Program membagi data menjadi tiga bagian:

- Set Pelatihan (80%) digunakan untuk melatih model, ukurannya $80\% \times 297 = 237.6 \Rightarrow 237$ data
- Set Temporary (20%) Sisanya (20%) disimpan sementara sebelum dibagi lagi untuk validasi dan pengujian, ukurannya temporary set adalah $297 - 237 = 60$ data
- Set Validasi dan Pengujian (masing-masing 10%) dibagi menjadi



50:50: Validasi: 30 data (50% dari 60)
Test: 30 data (50% dari 60)

f. *Model Training*

Dengan menggunakan integral dari kurva TPR versus FPR, nilai probabilitas (model.predict_proba(X_val)[:, 1]) dan label aktual (y_val) dihitung secara internal:

- TPR (True Positive Rate) = Recall
- FPR (False Positive Rate) = FP / (FP + TN)

AUC bernilai:

- 0.5 jika model acak (tidak bisa membedakan)
 - 1.0 jika model sempurna
- Jika : TP = 10, TN 12, FP = 4, FN = 6.

Maka:

- Accuracy = $(10 + 12) / (10 + 12 + 4 + 6) = 22 / 32 = 0.6875$
- Precision = $10 / (10 + 4) = 10 / 14 = 0.714$
- Recall = $10 / (10 + 6) = 10 / 16 = 0.625$
- F1 Score = $2 * (0.714 * 0.625) / (0.714 + 0.625) \approx 0.666$
- AUC dihitung dari probabilitas skor prediksi terhadap nilai aktual.

g. *Model Optimazation*

Dengan menggunakan GridSearchCV, optimalkan hiperparameter model Regresi Logistik, yang memiliki kinerja terbaik yang diidentifikasi pada langkah sebelumnya.

Nilai-nilai metrik adalah:

- Accuracy: 0.6

$$= \frac{TP + TN}{TP + TN + FP + FN} = \frac{9 + 15}{9 + 15 + 12 + 24} = \frac{24}{60} = 0.6$$

- Precision: 0.4286

$$= \frac{TP}{TP + FP} = \frac{9}{9 + 12} = \frac{9}{21} \approx 0.4286$$

- Recall: 0.2727

$$= \frac{TP}{TP + FN} = \frac{9}{9 + 24} = \frac{9}{33} \approx 0.2727$$

- F1-score: 0.3333

$$= 2 \times \frac{0.4286 \times 0.2727}{0.4286 + 0.2727} \approx 0.3333$$

- AUC: 0.3971

Dihitung dengan kurva ROC untuk membandingkan kemungkinan prediksi positif dengan label aktual.

Penjelasan terbaik untuk model ini menggunakan C = 10, penalty = l1, dan solver = liblinear. Karena recall dan AUC yang masih rendah, kinerjanya menurun. Teknik fitur, perimbangan data (jika kelas tidak seimbang), dan model berbasis pohon adalah hal-hal yang perlu dipelajari lebih lanjut.

h. *Model Evaluation*

Program ini membandingkan kinerja model klasifikasi (dalam hal ini, model regresi logistik, best_logreg) dengan set data uji. Menghitung berbagai metrik performa, termasuk akurasi (akurasi), presisi (presisi), recall (sensibilitas), skor F1, dan AUC (Area Under Curve).

Maka:

$$\text{Accuracy} = (TP + TN) / \text{total} = (6 + 11) / 30 = 17 / 30 = 0.5667$$

$$\text{Precision} = TP / (TP + FP) = 6 / (6 + 9) = 6 / 15 = 0.4$$

$$\text{Recall} = TP / (TP + FN) = 6 / (6 + 4) = 6 / 10 = 0.6$$

$$\text{F1 Score} = 2 * (\text{Precision} * \text{Recall}) / (\text{Precision} + \text{Recall})$$

$$= 2 * (0.4 * 0.6) / (0.4 + 0.6) = 0.48$$

AUC = Mengukur kemampuan model membedakan kelas dengan nilai probabilitas prediksi. Nilai AUC 0.705 berarti model bisa membedakan kelas positif dan



negatif dengan performa di atas acak.

HASIL DAN PEMBAHASAN

Seperti yang ditunjukkan oleh hasil eksplorasi awal terhadap dataset Dataset_Implan_Gigiok.csv, dapat disimpulkan bahwa pustaka pandas dan encoding "latin-1" dapat digunakan untuk memuat data dengan sukses. Seperti yang ditunjukkan oleh struktur datanya, dataset terdiri dari berbagai fitur numerik, seperti usia dan jumlah gigi yang hilang, serta fitur kategorikal, seperti jenis kelamin, diabetes, status merokok, dan keberhasilanimplan. Data tampak lengkap (non-null) di setiap kolom, yang membuatnya siap untuk analisis lanjutan. Hasil peninjauan awal ini menunjukkan bahwa dataset dapat digunakan untuk analisis prediktif, terutama untuk memodelkan variabel yang mempengaruhi keberhasilan pemasanganimplan gigi. Model prediktif dapat dibuat untuk membantu klinis membuat keputusan, melihat data, dan membersihkannya jika diperlukan.

Untuk memastikan hasil prediksi yang akurat, data diproses melalui penyesuaian tipe data, penyelarasan nilai kategorikal, penanganan outlier dengan winsorisasi, dan konversi fitur kategorikal ke format numerik melalui one-hot encoding. Tahapan ini menjamin kestabilan analisis dan kesiapan data untuk model machine learning.

ini, dataset harus bersih, terorganisir, dan siap untuk digunakan secara efektif dan efisien untuk analisis atau pengembangan model pembelajaran mesin, terlihat pada hasil program:

No	Usia	Jumlah Gigi Hilang	Gigi Nego	Abd	Acin	Adipa	Adrian	Agatha	Alina	Afira	Tita	Lokasi Gigi Hilang	Lokasi Gigi Hilang Atas	Lokasi Gigi Hilang Bawah	Lokasi Gigi Hilang Kiri	Lokasi Gigi Hilang Pada	Fraktur atau Trauma Ya / Ma
0	1	48	4	False	False	False	False	False	False	False	..	False	False	False	True	False	False
1	2	70	8	False	False	False	False	False	False	False	..	False	False	False	False	False	False
2	3	54	6	False	False	False	False	False	False	False	..	False	False	False	True	False	False
3	4	37	5	False	False	False	False	False	False	False	..	False	True	False	False	True	False
4	5	29	3	False	False	False	False	False	True	False	..	False	False	False	False	False	True

5 rows × 33 columns

Gambar 2 Data Cleaning and Preprocessing

(Sumber: Data Penelitian, 2025)

Program ini bertujuan untuk membagi dataset menjadi tiga bagian: delapan puluh persen data pelatihan, sepuluh persen data validasi, dan sepuluh persen data pengujian, menurut diskusi data splitting dengan fungsi train_test_split dari scikit-learn. Sebelum data dibagi secara berurutan, fitur (X) dan target (y) dipisahkan terlebih dahulu untuk memastikan model dapat dilatih, divalidasi, dan diuji secara optimal. Pembagian ini sangat penting untuk mencegah overfitting dan memastikan bahwa kinerja model dapat dievaluasi secara wajar pada data yang belum pernah dilihat sebelumnya, seperti yang ditunjukkan oleh hasil program:

```
x_train shape: (237, 328)
y_train shape: (237, 2)
x_val shape: (30, 328)
y_val shape: (30, 2)
x_test shape: (30, 328)
y_test shape: (30, 2)
```

Gambar 3 Hasil data splitting

(Sumber: Data Penelitian, 2025)

Hasil diskusi menunjukkan bahwa SVM menunjukkan keseimbangan terbaik untuk mendeteksi kelas positif dan memiliki skor F1 tertinggi, meskipun akurasinya biasa saja. Logistic Regression tidak sensitif terhadap kelas positif, meskipun lebih



akurat. Random Forest dan Gradient Boosting tidak cocok untuk data ini karena kinerja recall dan F1-nya yang buruk. Hasil program menunjukkan bahwa semua model memiliki AUC rendah, yang menunjukkan bahwa prediktifnya masih lemah untuk membedakan kelas:

```
Logistic Regression metrics: {'accuracy': 0.6, 'precision': 0.4285714285714285,
'recall': 0.2727272727272727, 'f1_score': 0.3333333333333333, 'auc': np.float64(0.42105263157894735)}
SVM metrics: {'accuracy': 0.5333333333333333, 'precision': 0.38461538461538464,
'recall': 0.4285714285714285, 'f1_score': 0.41666666666666667, 'auc': np.float64(0.4976076555023924)}
Random Forest metrics: {'accuracy': 0.5666666666666667, 'precision': 0.3333333333333333,
'recall': 0.18181818181818182, 'f1_score': 0.2352941764705882, 'au_c': np.float64(0.4425837320574163)}
Gradient Boosting metrics: {'accuracy': 0.4666666666666667, 'precision': 0.2727272727272727,
'recall': 0.2727272727272727, 'f1_score': 0.2727272727272727, 'au_c': np.float64(0.387559886124402)}
```

Gambar 4 Hasil Model Training
(Sumber: Data Penelitian, 2025)

Pembagian data menggunakan fungsi `train_test_split` dari pustaka scikit-learn bertujuan untuk memisahkan dataset menjadi tiga bagian, yaitu 80% untuk data pelatihan, 10% untuk data validasi, dan 10% untuk data pengujian. Sebelum proses pembagian dilakukan, data terlebih dahulu dipisahkan antara fitur (X) dan target (y). Langkah ini sangat krusial agar model dapat dilatih, divalidasi, dan diuji secara efektif. Hal ini tercermin dari hasil program yang menunjukkan proses pembagian berjalan sesuai tujuan.

```
X_train shape: (237, 328)
y_train shape: (237, 2)
X_val shape: (30, 328)
y_val shape: (30, 2)
X_test shape: (30, 328)
y_test shape: (30, 2)
```

Gambar 5 Model Optimization
(Sumber: Data Penelitian, 2025)

Evaluasi model dilakukan dengan membandingkan metrik kinerja pada data validasi dan data pengujian untuk menilai kemampuan prediktif model terhadap data yang belum pernah dilihat. Analisis ini membantu mengidentifikasi potensi overfitting atau underfitting, sebagaimana ditunjukkan pada hasil program.

Test Set Performance Metrics:

Accuracy: 0.5666666666666667

Precision: 0.4

Recall: 0.6

F1 Score: 0.48

AUC: 0.7050000000000001

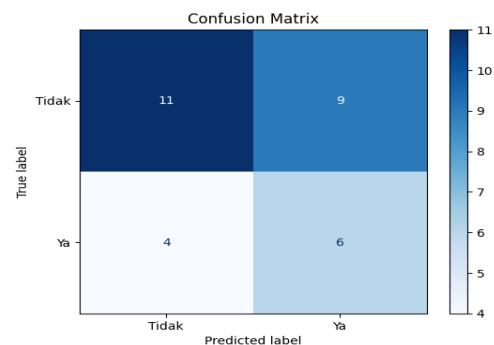
Gambar 6 Model Evaluation

(Sumber: Data Penelitian, 2025)

Dari hasil dan pembahasan, disimpulkan bahwa dataset tidak mengandung nilai yang hilang. Pada tahap rekayasa fitur, variabel "Usia" dan "Jumlah Gigi Hilang" dikembangkan menggunakan fitur polinomial (derajat 2), dan seluruh fitur numerik distandardisasi.

Dalam perbandingan model, regresi logistik awal menunjukkan performa terbaik dengan akurasi 0,6 dan AUC tertinggi dibanding SVM, Random Forest, dan Gradient Boosting.

Penyetelan hiperparameter pada regresi logistik menghasilkan model optimal dengan parameter {C: 100, penalti: l1, solver: liblinear}. Model ini memperoleh akurasi 0,57, presisi 0,40, recall 0,60, F1-score 0,48, dan AUC 0,71 pada data uji, sebagaimana terlihat pada hasil matriks evaluasi.



Gambar 7 Confution Matrix

(Sumber: Data Penelitian, 2025)

**SIMPULAN**

Pada penelitian yang sudah dilakukan terdapat beberapa kesimpulan diantaranya yaitu:

1. Kehilangan gigi bisa terjadi akibat trauma, penyakit gusi, karies parah, kebiasaan buruk, atau kondisi medis tertentu. Kerusakan ini memengaruhi jaringan penyanga dan tulang rahang. Kelayakan pemasangan implan dinilai melalui pemeriksaan klinis, pencitraan CBCT, serta riwayat medis. Implan hanya diberikan jika tulang rahang sehat dan bebas dari gangguan sistemik. Evaluasi menyeluruh diperlukan untuk memastikan integrasi implan berjalan sukses.
2. Model prediksi menggunakan data klinis pasien untuk mengelompokkan mereka ke dalam kategori "layak" atau "tidak layak" menerimaimplan. Evaluasi model dilakukan dengan metrik seperti akurasi, presisi, recall, dan F1-score. Algoritma Decision Tree dipilih karena mudah dipahami, namun perlu penyesuaian parameter agar hasilnya optimal dan tidak overfitting. Dengan data yang tepat, model ini efektif membantu prediksi kelayakanimplan.
3. Klinik Ellisa Dental Care mempermudah prosedurimplan gigi dengan layanan terpadu, termasuk konsultasi menyeluruh, pemeriksaan CBCT, serta edukasi seputar prosedur, perawatan pascaimplan, dan risikonya. Untuk menunjang kenyamanan pasien, klinik juga menyediakan opsi pembayaran fleksibel seperti cicilan dan paket layanan.

DAFTAR PUSTAKA

- Asyrofi, R. R., & Asyrofi, R. (2023). IMPLEMENTASI APLIKASI JUPYTER NOTEBOOK SEBAGAI ANALISIS KRETERIA PLAGIASI DENGAN TEKNIK SIMANTIK. *JIP/ (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 8(2), 627–637.
<https://doi.org/10.29100/jipi.v8i2.3699>
- Daniel, N. H., & Setiawati, D. (2024). CONVOLUTIONAL NEURAL NETWORK (CNN) BASED ON ARTIFICIAL INTELLIGENCE IN PERIODONTAL DISEASES DIAGNOSIS. *Interdental Jurnal Kedokteran Gigi (IJKG)*, 20(1), 139–148.
<https://doi.org/10.46862/interdental.v20i1.8641>
- Handoko, K. (2025). ANALISIS PERBANDINGAN KINERJA ALGORITMA MACHINE LEARNING BERBASIS FEATURE SELECTION DALAM DETEKSI SERANGAN BOTNET. *JURNAL COMASIE*, 12(02).
- Kartikasari Halim, A., & Poedjiastoeti, W. (2024). Penatalaksanaan Pemasangan Dental Implant pada kasus Kehilangan Gigi Posterior Tunggal. *Jurnal Kedokteran Gigi Terpadu*, 6(1), 39–41.
<https://doi.org/10.25105/jkgt.v6i1.20830>
- Murdoch, B. (2021). Privacy and artificial intelligence: challenges for protecting health information in a new era. *BMC Medical Ethics*, 22(1).



- <https://doi.org/10.1186/s12910-021-00687-3>
- Raphael, A., & Ariesanti, Y. (2025). Perawatan Implan Gigi pada Kasus Kehilangan Satu Gigi Posterior secara Subcrestal. *Jurnal Kedokteran Gigi Terpadu*, 6(2), 1–5.
<https://doi.org/10.25105/jkgt.v6i2.22355>
- Siddiqui, E. F., Ahmed, T., & Nayak, S. K. (2024). A decision tree approach for enhancing real-time response in exigent healthcare unit using edge computing. *Measurement: Sensors*, 32, 100979.
<https://doi.org/10.1016/j.measen.2023.100979>
- Situmorang, J., & Handoko, K. (2024). IMPLEMENTASI ARTIFICIAL INTELLIGENCE DALAM APLIKASI CHATBOT SEBAGAI HELPDESK OBJEK WISATA PANTAI DI-BATAM DENGAN METODE FORWARD CHAINING. *JURNAL COMASIE*, 10(03).
- Trenggono, P. H., & Bachtiar, A. (2023). *PERAN ARTIFICIAL INTELLIGENCE DALAM PELAYANAN KESEHATAN : A SYSTEMATIC REVIEW*. 7, 444–451.
<http://journal.universitaspahlawan.ac.id/index.php/ners>
- Ula, M., Anjani, F. T. T., Ulva, A. F., Sahputra, I., & Pratama, A. (2022). APPLICATION OF MACHINE LEARNING WITH THE BINARY DECISION TREE MODEL IN DETERMINING THE CLASSIFICATION OF DENTAL DISEASE. *JOURNAL OF INFORMATICS AND TELECOMMUNICATION ENGINEERING*, 6(1), 170–179.
<https://doi.org/10.31289/jite.v6i1.7341>
- Wardhana, R. G., Wang, G., & Sibuea, F. (2023). PENERAPAN MACHINE LEARNING DALAM PREDIKSI TINGKAT KASUS PENYAKIT DI INDONESIA. In *Journal of Information System Management (JOISM) e-ISSN* (Vol. 5, Issue 1).



Penulis pertama, Alisa Zebua, merupakan mahasiswa Prodi teknik informatika Universitas Putera Batam.



Penulis kedua, Koko Handoko, S.Kom., M.Kom., merupakan Dosen Prodi Teknik informatika di Universitas Putera Batam.