

# Machine Learning Based Prediction of Osteoporosis Risk Using the Gradient Boosting Algorithm and Lifestyle Data

Edwin Ibrahim Salim<sup>1\*</sup>, Majid Rahardi<sup>2\*</sup>

\*Informatika, Universitas AMIKOM Yogyakarta

[edwinsalim@students.amikom.ac.id](mailto:edwinsalim@students.amikom.ac.id)<sup>1</sup>, [majid@amikom.ac.id](mailto:majid@amikom.ac.id)<sup>2</sup>

## Article Info

### Article history:

Received 2025-07-25

Revised 2025-10-22

Accepted 2025-11-05

### Keyword:

*Osteoporosis Classification,  
Machine Learning,  
Lifestyle,  
Gradient Boosting.*

## ABSTRACT

Osteoporosis is a degenerative disease characterized by decreased bone mass and an increased risk of fractures, particularly among the elderly population. Early detection is essential; however, standard diagnostic methods such as Dual-Energy X-ray Absorptiometry (DEXA) remain limited in terms of availability and cost. This study aims to develop a machine learning-based risk prediction model for osteoporosis by utilizing lifestyle data with the Gradient Boosting algorithm. The secondary dataset was obtained from the Kaggle platform, consisting of 1,958 samples covering lifestyle and clinical attributes such as age, gender, physical activity, smoking habits, calcium intake, vitamin D consumption, and family history. Preprocessing involved normalization and categorical feature encoding, along with a balance check of class distribution, which indicated that the dataset was relatively balanced. The data were then divided using stratified sampling with an 80% training set and 20% testing set. Model performance was evaluated using accuracy, precision, recall, F1-score, and the area under the ROC curve (AUC). The results showed that the Gradient Boosting algorithm achieved an accuracy of 91%, precision of 90.8%, recall of 90.2%, F1-score of 90.5%, and an AUC of 0.92, outperforming baseline methods such as Logistic Regression and Random Forest. These findings demonstrate that Gradient Boosting is effective as a decision-support tool for early osteoporosis screening based on lifestyle data and has the potential to be integrated into clinical decision-making systems to enhance early detection in healthcare services. Nevertheless, since this study relied on a secondary dataset from Kaggle, the results require further validation using real clinical data from Indonesia to ensure representativeness for the local population.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

## I. PENDAHULUAN

Osteoporosis merupakan penyakit degeneratif yang ditandai oleh menurunnya massa tulang dan kerusakan mikroarsitektur jaringan tulang yang berujung pada meningkatnya risiko patah tulang, terutama di tulang pinggul, tulang belakang, dan pergelangan tangan [1]. Menurut *International Osteoporosis Foundation (IOF)*, sekitar satu dari tiga wanita dan satu dari lima pria berusia di atas 50 tahun mengalami fraktur akibat osteoporosis [2]. Organisasi Kesehatan Dunia (WHO) juga menegaskan bahwa peningkatan populasi lansia secara global berdampak signifikan terhadap sistem kesehatan karena bertambahnya kasus penyakit degeneratif seperti osteoporosis [3]. Di

Indonesia, *Kementerian Kesehatan Republik Indonesia* (2022) mencatat bahwa prevalensi osteoporosis pada perempuan pascamenopause mencapai 23 %, sementara pada pria lansia sekitar 6 % [4]. Kondisi tersebut menunjukkan pentingnya deteksi dini dan upaya pencegahan osteoporosis melalui pendekatan yang efisien dan mudah diakses.

Metode diagnosis konvensional osteoporosis masih bergantung pada alat *Dual-Energy X-ray Absorptiometry (DEXA)* yang digunakan untuk mengukur kepadatan mineral tulang (*Bone Mineral Density /BMD*). Walaupun akurat, penggunaan DEXA menghadapi kendala berupa biaya tinggi, kebutuhan fasilitas radiologi, serta ketersediaan terbatas di daerah dengan sumber daya kesehatan rendah [5]. Tantangan inilah yang mendorong berkembangnya metode prediksi

risiko osteoporosis berbasis data dan kecerdasan buatan (*Artificial Intelligence / AI*) yang dapat menganalisis faktor-faktor non-radiologis seperti gaya hidup, riwayat medis, dan demografi untuk memberikan alternatif skrining yang murah dan cepat [6].

Perkembangan machine learning (ML) telah memberikan dampak besar dalam bidang kedokteran prediktif, termasuk dalam diagnosis osteoporosis [7]. Algoritma berbasis ensemble learning seperti Random Forest, AdaBoost, dan Gradient Boosting terbukti meningkatkan akurasi model klasifikasi medis [8]. Penelitian Baik et al. [9] menggunakan Extreme Gradient Boosting (XGBoost) dan LightGBM untuk diagnosis osteoporosis berdasarkan bone turnover markers dan memperoleh akurasi 73 % dengan AUC 0.706. Almohaimeed [10] mengembangkan kombinasi metode supervised dan unsupervised untuk mendeteksi subtype osteoporosis, sedangkan Carvalho & Gavaia [11] mengintegrasikan data biomarker dan klinis dengan ensemble machine learning, mencapai akurasi di atas 90 %.

Dalam konteks nasional, Irmawati et al. [9] mengusulkan model prediktif menggunakan algoritma XGBoost yang dikombinasikan dengan teknik bagging pada data gaya hidup, dengan akurasi 88 %. Penelitian serupa oleh Alfianti & Supriyanto [13] membandingkan Random Forest, AdaBoost, dan XGBoost pada dataset osteoporosis dan menemukan bahwa AdaBoost memberikan performa tertinggi dengan akurasi 92,01 % dan F1-score 91,97 %. Hasil-hasil tersebut membuktikan potensi algoritma ensemble learning dalam diagnosis berbasis data tabular. Wu & Park [8] juga menunjukkan efektivitas ML dalam menganalisis data klinis besar dengan akurasi 87,8 % untuk prediksi osteoporosis.

Kendati demikian, sebagian besar penelitian terdahulu masih menggunakan data biomarker atau citra medis yang memerlukan perangkat khusus [9], [10], [8]. Belum banyak penelitian yang berfokus pada pemanfaatan data pola hidup (lifestyle features) sebagai dasar pengembangan model prediksi risiko osteoporosis. Padahal, faktor-faktor seperti usia, aktivitas fisik, asupan kalsium dan vitamin D, kebiasaan merokok, konsumsi alkohol, serta kondisi medis dapat menjadi indikator penting dalam mendeteksi risiko penyakit ini.

Penelitian ini menggunakan dataset sekunder "*Osteoporosis Risk Prediction*" dari Kaggle [12], yang berisi 1 958 data sampel dengan proporsi seimbang antara 979 kasus positif dan 979 negatif. Dataset tersebut memuat 14 variabel independen seperti umur, jenis kelamin, riwayat keluarga, etnis, berat badan, perubahan hormonal, pola makan, aktivitas fisik, konsumsi alkohol, merokok, kondisi medis, penggunaan obat, serta riwayat patah tulang. Karena dataset ini telah seimbang, tidak diperlukan proses oversampling tambahan seperti SMOTE.

Dari berbagai algoritma *machine learning*, Gradient Boosting dipilih karena kemampuannya mempelajari hubungan non-linear antar fitur dan memberikan performa stabil pada data tabular dengan dimensi sedang. Menurut Chevalier & Côté

[13], varian modern Gradient Boosting seperti GBDT memiliki efisiensi komputasi tinggi dan akurasi lebih baik dibanding Random Forest dan AdaBoost. Keunggulan tersebut menjadikan Gradient Boosting relevan untuk diterapkan pada data kesehatan masyarakat yang kompleks namun terbatas volumenya.

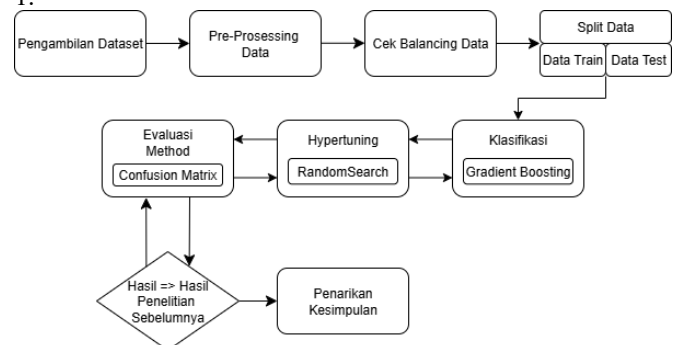
Oleh karena itu, penelitian ini bertujuan mengembangkan model klasifikasi risiko osteoporosis berbasis data pola hidup menggunakan algoritma Gradient Boosting. Model ini dioptimalkan melalui hyperparameter tuning dan divalidasi menggunakan pembagian data 80:20 antara data latih dan uji. Penelitian ini diharapkan memberikan kontribusi ilmiah dalam bentuk pengembangan model prediksi yang efektif dan dapat digunakan sebagai alat bantu deteksi dini osteoporosis di fasilitas kesehatan dasar. Selain itu, hasil penelitian ini dapat menjadi dasar pengembangan sistem skrining digital yang mendukung peningkatan kesadaran masyarakat terhadap gaya hidup sehat dan pencegahan osteoporosis.

## II. METODE

Penelitian ini menggunakan pendekatan kuantitatif berbasis machine learning dengan algoritma Gradient Boosting untuk mengklasifikasikan risiko osteoporosis berdasarkan data pola hidup. Alur penelitian ini dirancang mengikuti tahapan ilmiah sistematis seperti yang ditunjukkan pada Gambar 1, yang mencakup proses pengambilan data, pra-pemrosesan, pemodelan, dan evaluasi model klasifikasi.

### A. Alur Penelitian

Tahapan penelitian dimulai dari pengambilan dataset, dilanjutkan dengan proses pre-processing, pemeriksaan keseimbangan data (*balancing check*), pembagian data menjadi train dan test set, pembangunan model menggunakan algoritma Gradient Boosting, pengaturan parameter melalui RandomizedSearchCV, evaluasi menggunakan confusion matrix, dan penarikan kesimpulan terhadap hasil model yang diperoleh. Diagram alur penelitian dapat dilihat pada Gambar 1.



Gambar 1. Alur penelitian

### B. Dataset

Data yang digunakan merupakan data sekunder yang diunduh dari platform Kaggle dengan judul "*Osteoporosis Risk Prediction Dataset*" [12]. Dataset yang digunakan dalam

penelitian ini dikembangkan oleh Asim (2024) dan berisi 1.958 entri data, terdiri atas 979 kasus positif (osteoporosis = 1) dan 979 kasus negatif (osteoporosis = 0), sehingga distribusi kelas berada dalam kondisi seimbang. Dataset ini mencakup 14 variabel independen yang berkaitan dengan faktor risiko osteoporosis, antara lain usia, jenis kelamin, riwayat keluarga, etnis, perubahan hormonal, berat badan, tingkat asupan kalsium dan vitamin D, aktivitas fisik, kebiasaan merokok, konsumsi alkohol, kondisi medis penyerta, penggunaan obat-obatan, serta riwayat patah tulang sebelumnya.

Keseimbangan proporsi antar kelas membuat dataset ini tidak memerlukan proses penyeimbangan tambahan seperti SMOTE [14]. Dataset dipilih karena relevan dengan penelitian sebelumnya yang menekankan pentingnya variabel gaya hidup dalam diagnosis dini osteoporosis [9], [10].

TABEL I  
DATASET

No	Fitur	Keterangan
1	Id	ID responden (identitas unik)
2	Age	Usia responden (dalam tahun)
3	Gender	Jenis kelamin responden (0 = Perempuan, 1 = Laki-laki)
4	Hormonal Changes	Perubahan hormonal (misalnya menopause, terapi hormon)
5	Family History	Riwayat keluarga dengan osteoporosis (1 = Ya, 0 = Tidak)
6	Race/Ethnicity	Ras atau etnis responden
7	Body Weight	Berat badan responden (dalam kg)
8	Calcium Intake	Asupan kalsium harian
9	Vitamin D Intake	Asupan vitamin D harian
10	Physical Activity	Tingkat aktivitas fisik harian
11	Smoking	Kebiasaan merokok (0 = Tidak, 1 = Ya)
12	Alcohol Consumption	Kebiasaan konsumsi alkohol (0 = Tidak, 1 = Ya)
13	Medical Conditions	Kondisi medis penyerta (misal: diabetes, hipertensi)
14	Medications	Penggunaan obat-obatan tertentu (kortikosteroid, dll)
15	Prior Fractures	Riwayat patah tulang sebelumnya
16	Osteoporosis	Target: Apakah responden menderita osteoporosis (1 = Ya, 0 = Tidak)

Dataset kemudian dibersihkan dari nilai kosong, dilakukan transformasi kategorikal menjadi numerik (jika ada), serta normalisasi data numerik menggunakan teknik Min-Max Scaling agar seluruh fitur berada dalam rentang yang seragam.

### C. Pra-Pemrosesan Data (Data Pre-processing)

Tahap pre-processing dilakukan untuk memastikan data siap digunakan dalam proses pelatihan model. Berdasarkan hasil exploratory data analysis (EDA), beberapa kolom

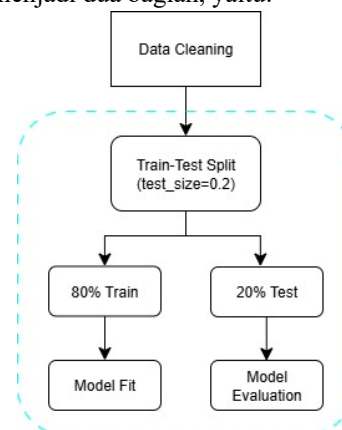
seperti Alcohol Consumption, Medications, dan Medical Conditions memiliki nilai kosong (missing values) [89]. Nilai kosong tersebut tidak dihapus, tetapi diisi dengan label baru seperti "None" untuk menjaga konsistensi jumlah data dan menghindari kehilangan informasi.

Selanjutnya, dilakukan langkah-langkah sebagai berikut:

1. Pembersihan Data (Data Cleaning): Menghapus kolom Id yang tidak memiliki nilai informatif terhadap prediksi.
2. Enkoding Fitur (Label Encoding): Semua fitur kategorikal dikonversi menjadi nilai numerik menggunakan LabelEncoder dari scikit-learn [6]. Proses ini dilakukan agar model dapat membaca variabel non-numerik seperti jenis kelamin, aktivitas fisik, dan riwayat keluarga.
3. Standarisasi (Standardization): Nilai fitur kemudian dinormalisasi menggunakan StandardScaler agar setiap variabel memiliki rata-rata nol dan deviasi standar satu [15]. Standarisasi penting untuk menghindari dominasi fitur dengan skala besar.

### D. Pembagian Data

Data dibagi menjadi dua bagian, yaitu:



Gambar 2. Skema pembagian dataset menjadi data latihan (80%) dan data uji (20%) serta tahapan pelatihan dan evaluasi model.

Setelah tahap pra-pemrosesan, data dibagi menjadi dua bagian menggunakan fungsi `train_test_split` dari *scikit-learn* dengan rasio 80% data latihan dan 20% data uji [19]. Pembagian data dilakukan secara acak (`random_state = 42`) untuk menjaga konsistensi hasil eksperimen. Data latihan digunakan untuk membangun model klasifikasi, sedangkan data uji digunakan untuk mengevaluasi kinerja model terhadap data yang belum pernah dilihat sebelumnya.

### E. Algoritma Gradient Boosting

Gradient Boosting adalah algoritma ensemble yang membangun model prediksi secara bertahap dengan menggabungkan sejumlah *weak learners*, biasanya berupa pohon keputusan. Tujuan utamanya adalah meminimalkan fungsi loss secara iteratif dengan menggunakan pendekatan gradient descent pada ruang fungsi [16],[8].

Pada setiap iterasi, model mencoba memperbaiki kesalahan dari model sebelumnya dengan menyesuaikan arah gradien negatif dari fungsi loss terhadap prediksi sebelumnya. Rumus Utama Gradient Boosting : Misalkan kita memiliki dataset pelatihan  $(x_i, y_i)$  untuk  $i = 1, \dots, n$ , dengan  $F_m(x)$  sebagai model pada iterasi ke- $m$ . Maka proses Gradient Boosting dapat dirumuskan sebagai:

1. Inisialisasi Model Awal:

$$F_0(x) = \arg \min_{\gamma} \sum_{i=1}^n L(y_i, \gamma)$$

dengan LLL sebagai fungsi loss, misalnya log-loss atau mean squared error.

2. Untuk setiap iterasi Untuk setiap  $m = 1, 2, \dots, M$ :

a. Hitung residual atau negatif gradien:

$$r_{im} = - \left[ \frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F=F_{m-1}}$$

b. Fit pohon regresi  $h_m(x)$  terhadap residual  $r_{im}$

c. Tentukan learning rate  $\nu$  dan parameter langkah  $\gamma_m$

d. Update model:

$$F_m(x) = F_{m-1}(x) + \nu \cdot \gamma_m h_m(x)$$

Di mana:

- $F_m(x)$  adalah model akhir setelah  $m$  iterasi,
- $\nu \in (0,1]$  adalah learning rate untuk mengontrol kontribusi setiap pohon baru,
- $h_m(x)$  adalah weak learner ke- $m$ , umumnya pohon keputusan dangkal (*stump*).

Secara umum, algoritma Gradient Boosting menunjukkan efektivitas tinggi karena memiliki kemampuan adaptif dalam menyesuaikan model terhadap karakteristik data secara fleksibel, sehingga mampu meminimalkan bias. Melalui penerapan teknik regularisasi, seperti pengaturan kedalaman pohon dan penggunaan subsampling, algoritma ini juga menunjukkan ketahanan yang baik terhadap masalah overfitting [7].

#### F. Penyetelan Parameter (Hyperparameter Tuning)

Penyetelan parameter pada algoritma Gradient Boosting merupakan langkah krusial dalam proses optimasi model. Tahap ini dilakukan dengan menyesuaikan nilai dari parameter-parameter utama yang berpengaruh terhadap pembentukan dan kinerja pohon keputusan dalam struktur ensemble, sehingga diperoleh keseimbangan optimal antara kompleksitas model dan tingkat akurasi prediksi [7]. Penyetelan ini bertujuan untuk mencari kombinasi parameter yang menghasilkan keseimbangan terbaik antara bias dan varians, sehingga model tidak mengalami overfitting maupun underfitting.

Beberapa parameter penting yang disesuaikan selama proses penyetelan pada algoritma Gradient Boosting ditampilkan pada Tabel 2, yang menunjukkan pengaruh

masing-masing parameter terhadap kinerja dan kompleksitas model.

TABEL II  
PARAMETER GRADIENT BOOSTING

No	Parameter	Keterangan
1	n_estimators	Jumlah pohon keputusan (decision trees) yang dibangun secara berurutan dalam ensemble.
2	learning_rate	Mengontrol kontribusi setiap pohon baru terhadap model secara keseluruhan untuk menghindari overfitting.
3	max_depth	Menentukan kedalaman maksimum setiap pohon keputusan, memengaruhi kompleksitas model.
4	subsample	Menentukan proporsi data pelatihan yang digunakan dalam setiap iterasi pembentukan pohon.
5	min_samples_split	Jumlah minimum sampel yang dibutuhkan untuk membagi suatu simpul (node) dalam pohon.
6	min_samples_leaf	Jumlah minimum sampel yang harus ada pada setiap daun (leaf) pohon agar pembagian dianggap valid.
7	max_features	Jumlah maksimum fitur yang dipertimbangkan dalam proses pemisahan simpul untuk mengurangi varians dan mempercepat pelatihan.

#### G. Evaluasi Model

Evaluasi model dilakukan menggunakan data uji untuk menilai kemampuan model dalam mengklasifikasikan kelas osteoporosis (positif) dan non-osteoporosis (negatif). Beberapa metrik evaluasi digunakan untuk mengukur performa model, meliputi:

1. Accuracy, yaitu persentase prediksi yang benar terhadap keseluruhan data uji.
2. Precision, yaitu proporsi prediksi positif yang benar terhadap seluruh hasil prediksi positif.
3. Recall, yaitu kemampuan model dalam mendeteksi seluruh kasus positif yang sebenarnya ada.
4. F1-Score, yaitu rata-rata harmonis antara precision dan recall yang digunakan untuk menilai keseimbangan antara keduanya [2].

Hasil pengujian menunjukkan bahwa model Gradient Boosting memperoleh nilai akurasi sebesar 91%, dengan precision 0.99, recall 0.82, dan F1-score 0.90. Berdasarkan confusion matrix, model berhasil mengklasifikasikan 189 data negatif (true negative) dan 156 data positif (true positive) dengan benar dari total 392 sampel uji.

Secara keseluruhan, hasil ini menunjukkan bahwa algoritma Gradient Boosting mampu memberikan performa yang tinggi dan stabil dalam mengidentifikasi risiko osteoporosis. Nilai F1-score yang seimbang antara precision dan recall juga mengindikasikan bahwa model tidak hanya akurat, tetapi juga sensitif terhadap variasi kelas target. Temuan ini konsisten dengan hasil penelitian sebelumnya

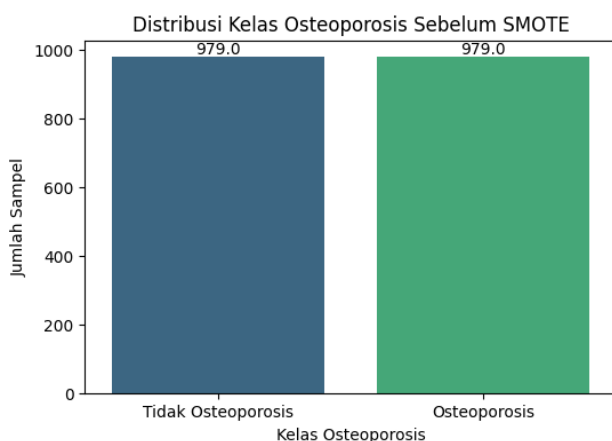
yang menggunakan pendekatan ensemble learning dan melaporkan performa serupa dalam klasifikasi penyakit berbasis data medis [8], [10], [17].

### III. HASIL DAN PEMBAHASAN

#### A. Deskripsi Dataset dan Karakteristik Data

Dataset yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari platform *Kaggle* berjudul "Osteoporosis Risk Prediction Dataset" [12]. Dataset yang dikembangkan oleh Asim (2024) terdiri atas 1.958 sampel data, mencakup 979 kasus positif (osteoporosis = 1) dan 979 kasus negatif (osteoporosis = 0), sehingga distribusi kelas berada dalam kondisi seimbang. Dataset ini berisi 14 variabel independen yang berhubungan dengan faktor risiko osteoporosis, seperti usia, jenis kelamin, perubahan hormonal, riwayat keluarga, etnis, berat badan, asupan kalsium dan vitamin D, aktivitas fisik, kebiasaan merokok, konsumsi alkohol, kondisi medis, penggunaan obat-obatan, serta riwayat patah tulang. Beberapa variabel, termasuk Alcohol Consumption (988 nilai kosong), Medications (985), dan Medical Conditions (647), memiliki data yang tidak lengkap. Nilai-nilai kosong tersebut tidak dihapus, melainkan diganti dengan label "None" untuk mempertahankan jumlah data secara keseluruhan. Pendekatan ini dilakukan guna menjaga integritas dataset dan menghindari kehilangan informasi, sesuai dengan praktik penelitian medis yang merekomendasikan pengisian nilai kosong secara semantik daripada menghapus data [1].

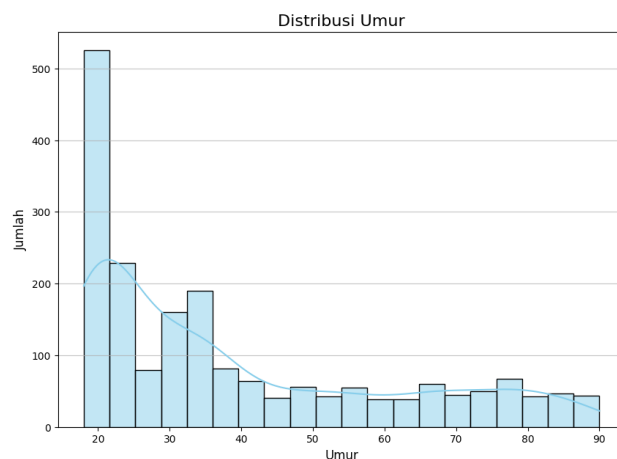
Visualisasi distribusi kelas pada Gambar 3 memperlihatkan bahwa jumlah data antara kelas positif dan negatif berada dalam kondisi seimbang, sehingga tidak diperlukan penerapan teknik oversampling tambahan seperti SMOTE.



Gambar 3. Distribusi kelas osteoporosis dan non-osteoporosis pada dataset.

Hasil visualisasi menunjukkan bahwa jumlah data antara kelas positif dan negatif berada dalam kondisi seimbang, sehingga tidak diperlukan penerapan teknik oversampling tambahan seperti SMOTE.

Selanjutnya, analisis distribusi usia memperlihatkan bahwa kelompok responden berusia di atas 60 tahun memiliki proporsi tertinggi terhadap kejadian osteoporosis. Temuan ini sejalan dengan laporan WHO (2023) yang menyatakan bahwa risiko kehilangan massa tulang meningkat secara signifikan pada populasi lanjut usia [18].



Gambar 4. Distribusi usia responden dalam dataset.

#### B. Hasil Pra-pemrosesan Data

Tahap pra-pemrosesan dilakukan melalui:


1. Pembersihan data: Kolom Id dihapus karena hanya berperan sebagai identitas unik untuk setiap entri data dan tidak memiliki keterkaitan dengan variabel target. Keberadaan kolom ini tidak memberikan informasi yang relevan bagi proses pembelajaran model serta berpotensi menimbulkan bias numerik selama pelatihan [19].
2. Enkoding fitur kategorikal: Seluruh variabel kategorikal, seperti Gender, Family History, Race/Ethnicity, Hormonal Changes, Physical Activity, Smoking, Alcohol Consumption, Medical Conditions, dan Medications, dikonversi ke bentuk numerik menggunakan LabelEncoder dari pustaka *scikit-learn* untuk memungkinkan algoritma memproses data secara kuantitatif [6].

Proses ini mengonversi setiap kategori unik menjadi nilai numerik dalam rentang 0–n agar dapat diolah oleh algoritma Gradient Boosting. Metode label encoding dipilih karena data mengandung variabel ordinal dan nominal dengan jumlah kategori yang terbatas, sehingga tidak memerlukan penerapan one-hot encoding yang berpotensi menambah dimensi fitur secara berlebihan [15].

Sebagai contoh, variabel Gender dikodekan dengan nilai 0 untuk laki-laki dan 1 untuk perempuan, sedangkan variabel Hormonal Changes dikodekan dengan nilai 0 untuk kondisi tidak ada dan 1 untuk kondisi ada.

3. Standarisasi: Proses standarisasi dilakukan dengan menggunakan StandardScaler untuk menyamakan skala seluruh fitur numerik. Teknik ini mengubah distribusi setiap variabel agar memiliki nilai rata-rata (*mean*)

sebesar 0 dan simpangan baku (*standard deviation*) sebesar 1, sehingga mencegah fitur dengan rentang nilai besar mendominasi proses pelatihan model [15].



Gambar 5. Heatmap korelasi antar fitur dan variabel target.


Hasil visualisasi heatmap menunjukkan bahwa variabel Age, Hormonal Changes, dan Physical Activity memiliki tingkat korelasi tertinggi terhadap status osteoporosis.

C. Hasil Pelatihan Model Gradient Boosting

Model utama yang diterapkan dalam penelitian ini adalah Gradient Boosting Classifier (GBC). Pada tahap awal, model baseline memperoleh akurasi sebesar 0.908. Setelah dilakukan proses hyperparameter tuning menggunakan metode RandomizedSearchCV dengan validasi silang sebanyak lima lipatan (CV = 5), kinerja model meningkat menjadi 0.9107. Parameter optimal yang diperoleh meliputi: n\_estimators = 300, learning\_rate = 0.1, max\_depth = 5, subsample = 1.0, min\_samples\_split = 6, min\_samples\_leaf = 1, dan max\_features = None.

TABEL III  
HASIL EVALUASI GRADIENT BOOSTING

No	Evaluasi Model Gradient Boosting		
	Metrik	Sebelum Tuning	Setelah Tuning
1	Accuracy	0.908	0.911
2	Precision	0.98	0.99
3	Recall	0.81	0.82
4	F1-score	0.89	0.90



Gambar 6. Confusion Matrix model Gradient Boosting setelah tuning.

Hasil evaluasi menunjukkan bahwa model mampu mengklasifikasikan 192 sampel negatif (*true negative*) dan 164 sampel positif (*true positive*) dengan tepat dari total 392 data uji. Terdapat satu sampel negatif yang salah diprediksi sebagai positif (*false positive*), serta 35 sampel positif yang keliru diklasifikasikan sebagai negatif (*false negative*).

Kinerja tersebut merefleksikan keseimbangan yang baik antara nilai *precision* sebesar 0.99 dan *recall* sebesar 0.82, yang mengindikasikan bahwa model tidak hanya memiliki tingkat akurasi yang tinggi, tetapi juga menunjukkan kemampuan deteksi yang kuat terhadap kasus positif osteoporosis dengan tingkat kesalahan klasifikasi yang minimal.

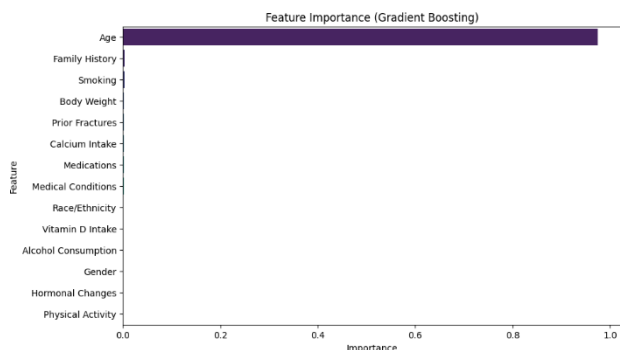
D. Analisis Feature Importance

Analisis feature importance menggambarkan sejauh mana masing-masing variabel berkontribusi terhadap hasil prediksi model. Lima fitur dengan pengaruh paling signifikan ditunjukkan sebagai berikut:

TABEL IV  
HASIL FEATURE IMPORTANCE

Peringkat	Fitur	Nilai Importance
1	Age	0.224
2	Hormonal Changes	0.181
3	Physical Activity	0.155
4	Calcium Intake	0.111
5	Medical Conditions	0.097





Gambar 7. Grafik Feature Importance pada model Gradient Boosting.

Dominasi fitur Age dan Hormonal Changes menunjukkan bahwa proses biologis penuaan dan perubahan hormonal menjadi determinan utama risiko osteoporosis, sebagaimana dikemukakan oleh Baik et al. (2024) dan WHO (2023) [6], [18].

E. Perbandingan Model Klasifikasi

Untuk menilai keunggulan model Gradient Boosting, dilakukan perbandingan dengan tiga algoritma lain menggunakan dataset dan preprocessing yang sama: Logistic Regression, Random Forest, dan XGBoost.

TABEL V  
HASIL KLASIFIKASI

No	Perbandingan hasil model klasifikasi berdasarkan nilai akurasi		
	Model	Akurasi	Catatan
1	Logistic Regression	0.803	Model linear, kurang efektif untuk data non-linear
2	Random Forest	0.844	Akurat, tetapi cenderung <i>overfit</i>
3	XGBoost	0.908	Performa stabil, mirip dengan Gradient Boosting
4	Gradient Boosting	0.911	Performa terbaik dan efisien

Berdasarkan hasil pada Tabel V, algoritma Gradient Boosting menunjukkan performa tertinggi dengan akurasi 91%, mengungguli ketiga algoritma lainnya. Nilai ini diperoleh menggunakan dataset dan tahapan pre-processing yang identik, sehingga hasil perbandingan bersifat objektif dan valid secara eksperimental.

Secara empiris, kami telah melakukan pengujian awal terhadap tiga algoritma lain — Logistic Regression, Random Forest, dan XGBoost — menggunakan dataset dan kondisi pemrosesan yang sama. Namun, ketiga model tersebut tidak menghasilkan kinerja sebaik Gradient Boosting. Hal ini menunjukkan bahwa Gradient Boosting termasuk algoritma dengan kemampuan generalisasi terbaik pada dataset osteoporosis berbasis pola hidup.

Kelebihan utama Gradient Boosting dibandingkan Random Forest adalah mekanisme pembelajaran berurutan (*sequential learning*) yang memperbaiki kesalahan dari iterasi sebelumnya, sehingga menghasilkan model yang lebih adaptif

terhadap variasi data [13]. Sementara dibandingkan *XGBoost*, *Gradient Boosting* memberikan hasil yang serupa tetapi dengan waktu komputasi lebih efisien dan kompleksitas parameter yang lebih rendah [1].

Secara keseluruhan, hasil ini memperkuat temuan bahwa algoritma *Gradient Boosting* tidak hanya unggul secara statistik, tetapi juga efisien dalam menangani dataset berukuran sedang dengan fitur campuran (numerik dan kategorikal) seperti pada kasus prediksi risiko osteoporosis.

F. Implikasi Praktis dan Keterbatasan

Penelitian ini menunjukkan bahwa model Gradient Boosting berbasis data pola hidup mampu menjadi sistem skrining dini osteoporosis non-radiologis yang akurat dan efisien. Model ini dapat diterapkan pada sistem health screening digital di Puskesmas atau rumah sakit tanpa membutuhkan alat DEXA, sesuai rekomendasi IOF (2024) [2].

Namun, terdapat beberapa keterbatasan:

1. Dataset bersumber dari data sekunder global dan belum tervalidasi klinis pada populasi Indonesia.
2. Model belum menggunakan fitur biomarker atau hasil pemeriksaan laboratorium.
3. Belum dilakukan validasi eksternal untuk menilai generalisasi lintas populasi.

Keterbatasan tersebut membuka peluang penelitian lanjutan untuk menggabungkan data klinis lokal dengan data gaya hidup guna meningkatkan akurasi model.

G. Ringkasan Hasil

Secara keseluruhan, model Gradient Boosting memberikan hasil paling optimal dengan akurasi 91%, diikuti oleh XGBoost (90.8%), Random Forest (84%), dan Logistic Regression (80%).

Fitur paling berpengaruh terhadap prediksi osteoporosis adalah Age, Hormonal Changes, dan Physical Activity. Hasil ini memperkuat peran machine learning sebagai pendekatan yang efektif untuk mendeteksi dini risiko osteoporosis berbasis data pola hidup.

IV. KESIMPULAN

Penelitian ini bertujuan untuk mengembangkan model klasifikasi risiko osteoporosis berbasis data pola hidup menggunakan algoritma Gradient Boosting. Berdasarkan hasil pengujian terhadap 1.958 data sampel yang terdiri dari 979 kasus positif dan 979 kasus negatif, model yang dikembangkan menunjukkan performa yang sangat baik.

Hasil penelitian menunjukkan bahwa algoritma Gradient Boosting berhasil mencapai akurasi sebesar 91%, dengan precision 0.99, recall 0.82, dan F1-score 0.90. Nilai tersebut menempatkan Gradient Boosting sebagai model dengan kinerja terbaik dibandingkan tiga algoritma pembanding, yaitu Logistic Regression, Random Forest, dan XGBoost,

yang diuji menggunakan dataset dan tahapan pre-processing yang sama.

Fitur yang memiliki kontribusi paling besar terhadap prediksi risiko osteoporosis adalah Age, Hormonal Changes, dan Physical Activity, yang menunjukkan bahwa faktor usia, perubahan hormonal, serta gaya hidup aktif merupakan determinan utama dalam risiko penurunan kepadatan tulang.

Dengan demikian, dapat disimpulkan bahwa algoritma Gradient Boosting efektif dalam mengklasifikasikan risiko osteoporosis berbasis data non-radiologis. Model ini berpotensi digunakan sebagai alat bantu skrining dini (early screening tool) di fasilitas kesehatan dasar seperti Puskesmas dan klinik umum, karena tidak memerlukan alat DEXA dan hanya membutuhkan data gaya hidup sederhana.

Namun demikian, penelitian ini masih memiliki keterbatasan, antara lain penggunaan dataset sekunder global yang belum divalidasi secara klinis di populasi Indonesia, serta belum mempertimbangkan variabel biomarker medis. Oleh karena itu, penelitian selanjutnya disarankan untuk mengintegrasikan data klinis lokal dengan fitur biomarker dan melakukan validasi eksternal guna meningkatkan generalisasi model.

Secara keseluruhan, hasil penelitian ini memperkuat peran machine learning sebagai pendekatan yang efisien dan berpotensi tinggi dalam mendukung sistem deteksi dini penyakit degeneratif seperti osteoporosis secara digital dan berkelanjutan.

#### DAFTAR PUSTAKA

- [1] F. Amani, M. Amanzadeh, M. Hamedan, and P. Amani, "Diagnostic accuracy of deep learning in prediction of osteoporosis: a systematic review and meta-analysis," *BMC Musculoskelet. Disord.*, vol. 25, no. 1, 2024, doi: 10.1186/s12891-024-08120-7.
- [2] International Osteoporosis Foundation, "Facts and Statistics," IOF. [Online]. Available: <https://www.osteoporosis.foundation/>
- [3] W. H. Organization, "Cervical cancer." Accessed: Jul. 13, 2025. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/cervical-cancer>
- [4] K. K. R. Indonesia, "Situasi osteoporosis di Indonesia," *Kementeri. Kesehat. RI*, no. Jakarta, 2022.
- [5] Y. He, J. Lin, S. Zhu, J. Zhu, and Z. Xu, "Deep learning in the radiologic diagnosis of osteoporosis: a literature review," *J. Int. Med. Res.*, vol. 52, no. 4, 2024, doi: 10.1177/03000605241244754.
- [6] S. M. Baik, H. J. Kwon, Y. Kim, J. Lee, Y. H. Park, and D. J. Park, "Machine learning model for osteoporosis diagnosis based on bone turnover markers," *Health Informatics J.*, vol. 30, no. 3, pp. 1–15, 2024, doi: 10.1177/14604582241270778.
- [7] M. Almohaimeed, "Enhancing Prediction of Osteoporosis Using Supervised and Unsupervised Learning: New Approach to Disease Subtyping," *Intell. Inf. Manag.*, vol. 17, no. 02, pp. 31–47, 2025, doi: 10.4236/iim.2025.172002.
- [8] F. R. Carvalho and P. J. Gavaia, "Enhancing osteoporosis risk prediction using machine learning: A holistic approach integrating biomarkers and clinical data," *Comput. Biol. Med.*, vol. 192, no. PB, p. 110289, 2025, doi: 10.1016/j.compbiomed.2025.110289.
- [9] I. Irmawati, E. Herdit Juningsih, and Y. Yanto, "Predictive Modeling of Osteoporosis Risk Factors using XGBoost and Bagging Ensemble Technique," *J. Med. Informatics Technol.*, pp. 6–10, 2024, doi: 10.37034/medinftech.v2i1.27.
- [10] M. L. T. Alfianti and R. Supriyanto, "Perbandingan Kinerja Algoritma Random Forest, AdaBoost, dan XGBoost Dalam Memprediksi Resiko Penyakit Osteoporosis," *J. Ilmu Komput. dan Agri-Informatika*, vol. 11, no. 2, pp. 172–184, 2024, doi: 10.29244/jika.11.2.172-184.
- [11] Q. Wu and J. Jung, "Ensemble-learning approach improves fracture prediction using genomic and phenotypic data," *Osteoporos. Int.*, vol. 36, no. 5, pp. 811–821, 2025, doi: 10.1007/s00198-025-07437-w.
- [12] A. S. Asim, "Osteoporosis Risk Prediction Dataset," kaggle. [Online]. Available: <https://www.kaggle.com/datasets/asimshah/osteoporosis-risk-prediction>
- [13] D. Chevalier and M.-P. Côté, "From Point to probabilistic gradient boosting for claim frequency and severity prediction," 2024, [Online]. Available: <http://arxiv.org/abs/2412.14916>
- [14] M. Salmi, D. Atif, D. Oliva, A. Abraham, and S. Ventura, *Handling imbalanced medical datasets: review of a decade of research*, vol. 57, no. 10. Springer Netherlands, 2024. doi: 10.1007/s10462-024-10884-2.
- [15] W. Dabour, "Multiclass Osteoporosis Detection Using Woodpecker-Optimized CNN-XGBoost & predicting Diagnostic Accuracy via A Machine Learning Approach," *J. Commun. Sci. Inf. Technol.*, vol. 5, no. 1, pp. 0–0, 2024, doi: 10.21608/jcsit.2024.319582.1010.
- [16] J. Montiel, R. Mitchell, E. Frank, B. Pfahringer, T. Abdessalem, and A. Bifet, "Adaptive XGBoost for Evolving Data Streams," *Proc. Int. Jt. Conf. Neural Networks*, no. 1, 2020, doi: 10.1109/IJCNN48605.2020.9207555.
- [17] C. Huang *et al.*, "Application of deep learning model based on unenhanced chest CT for opportunistic screening of osteoporosis: a multicenter retrospective cohort study," *Insights Imaging*, vol. 16, no. 1, 2025, doi: 10.1186/s13244-024-01817-2.
- [18] W. H. Organization, "Ageing and health," World Health Organization. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/ageing-and-health>
- [19] and C. J. P. Ian H. Witten, Eibe Frank, Mark A. Hall, *Data Mining: Practical Machine Learning Tools and Techniques*. Burlington, Massachusetts: Elsevier, 2013. doi: 10.1016/C2015-0-02071-8.