

Perbandingan Kinerja Algoritma Random Forest, AdaBoost, dan XGBoost dalam Memprediksi Risiko Penyakit Osteoporosis

Comparison of the Performance of Random Forest, AdaBoost, and XGBoost Algorithms in Predicting the Risk of Osteoporosis Disease

MAY LINDA TRI ALFIANTI^{1*}, RADEN SUPRIYANTO¹

Abstrak

Penyakit tulang yang disebut osteoporosis ditandai oleh berkurangnya massa tulang dan meningkatnya kerapuhan, yang meningkatkan kemungkinan patah tulang terutama pada pinggul, tulang belakang, dan pergelangan tangan. Penyakit ini dapat dialami oleh perempuan dan laki-laki, khususnya usia tua. Penyakit ini umumnya tidak menimbulkan gejala pada tahap awal, sehingga prediksi dini sangat penting untuk pencegahan dan penanganan. Tujuan dari penelitian ini adalah untuk membandingkan kinerja tiga algoritma pembelajaran mesin, yaitu *random forest*, *AdaBoost*, dan *XGBoost*, dalam memprediksi risiko osteoporosis. Dataset yang digunakan berjumlah 1781 data dengan tiga skema pembagian data 80:20, 70:30, dan 60:40. Pada algoritma *random forest*, skema 80:20 memberikan hasil terbaik dengan akurasi 87.11%, dan presisi 89.09%. Sementara itu, algoritma *AdaBoost* menunjukkan performa terbaik pada skema 60:40 dengan akurasi 92.01% dan presisi 93.13%. Algoritma *XGBoost* menunjukkan hasil terbaik pada skema 80:20 dengan akurasi 90.20% dan presisi 90.77%. Hasil penelitian menunjukkan bahwa algoritma *AdaBoost* memiliki kinerja terbaik di antara ketiga algoritma yang diuji. Setelah itu, dilakukan implementasi model prediksi risiko osteoporosis ke dalam website, yang memungkinkan pengguna melakukan prediksi berdasarkan 14 variabel: umur, jenis kelamin, riwayat keluarga, etnis, penggunaan obat, riwayat patah tulang, perubahan hormonal, asupan vitamin D, asupan kalsium, berat badan, aktivitas fisik, konsumsi alkohol, merokok, dan kondisi medis.

Kata Kunci: AdaBoost, osteoporosis, pembelajaran mesin, prediksi resiko. random forest, XG-Boost.

Abstract

The bone disease known as osteoporosis is characterized by a decrease in bone mass and an increase in fragility, which raises the likelihood of fractures, particularly in the hips, spine, and wrists. Osteoporosis affects both men and women, especially in old age. This disease generally does not cause symptoms in the early stages, highlighting the importance of early prediction for effective prevention and management. This research aims to compare the performance of three machine learning algorithms, namely random forest, AdaBoost, and XGBoost, in predicting the risk of osteoporosis. The dataset consists of 1781 data points with three data splitting schemes: 80:20, 70:30, and 60:40. In the random forest algorithm, the 80:20 scheme yields the best results with an accuracy of 87.11% and a precision of 89.09%. Meanwhile, the AdaBoost algorithm shows the best performance in the 60:40 scheme with an accuracy of 92.01% and a precision of 93.13%. The XGBoost algorithm demonstrates the best results in the 80:20 scheme with an accuracy of 90.20% and a precision of 90.77%. The research findings indicate that the AdaBoost algorithm performs best among the three tested algorithms. Furthermore, the osteoporosis risk prediction model was implemented into the website, allowing users to make predictions based on 14 variables: age, gender, family history, ethnicity, medication use, history of fractures, hormonal changes, vitamin D intake, calcium intake, weight, physical activity, alcohol consumption, smoking, and medical conditions.

Keywords: AdaBoost, machine learning, osteoporosis, random forest, risk prediction, XGBoost.

¹ Jurusan Informatika, Fakultas Teknologi Industri, Universitas Gunadarma;

* Penulis Korespondensi: maylindatrialfi@gmail.com

PENDAHULUAN

Penyakit osteoporosis atau tulang keropos merupakan penyakit tulang yang ditandai oleh berkurangnya massa tulang dan meningkatnya kerapuhan, dan dapat menyerang pria maupun wanita, terutama seiring bertambahnya usia. Kondisi ini meningkatkan risiko patah tulang, khususnya di area pinggul, tulang belakang, dan pergelangan tangan. Usia tua, jenis kelamin perempuan, merokok, aktivitas fisik yang kurang dan konsumsi minuman keras atau alkohol adalah beberapa faktor risiko osteoporosis (Wicaksono dan Maulana 2020).

Berdasarkan data dari *International Osteoporosis Foundation*, osteoporosis menyebabkan satu dari tiga wanita dan satu dari lima pria di atas usia 50 tahun mengalami patah tulang karena kondisi tersebut. Penyakit ini menyerang sekitar 6.3% pria berusia di atas 50 tahun dan 21.2% wanita pada rentang usia yang sama secara global. Berdasarkan populasi pria dan wanita di dunia, hal ini menunjukkan bahwa sekitar 500 juta pria dan wanita di seluruh dunia mungkin terkena dampaknya (IOF 2024). Osteoporosis dapat dicegah dengan mengubah faktor risiko yang dapat dimodifikasi, seperti pola makan, gaya hidup, status penyakit, dan pengobatan. Selain itu, ada juga faktor risiko yang tidak bisa diubah untuk osteoporosis, seperti usia, jenis kelamin, ukuran tubuh, dan genetik.

Pada tahap awal, osteoporosis sering kali tidak menimbulkan gejala atau tanda spesifik, sehingga dapat berdampak serius seperti patah tulang, penurunan kualitas hidup, bahkan kematian (Kementerian Republik Indonesia 2022). Dampak serius yang dimiliki oleh penyakit osteoporosis membuat prediksi dini serta identifikasi risiko yang berkaitan dengan osteoporosis menjadi langkah yang sangat penting untuk pencegahan dan penanganan yang tepat kepada individu yang berisiko tinggi (Humaryanto 2023). Oleh karena itu, pengembangan model yang dapat memprediksi risiko osteoporosis menjadi sangat penting untuk mencegah dan menangani penyakit ini.

Seiring dengan pesatnya perkembangan teknologi, penggunaan algoritma pembelajaran mesin telah menjadi semakin umum dalam pengembangan model prediktif untuk berbagai kondisi kesehatan, termasuk osteoporosis. Pembelajaran mesin atau *machine learning* merupakan cabang ilmu yang termasuk dalam bidang kecerdasan buatan di mana mesin atau komputer dapat mempelajari data yang ada dan mengubahnya menjadi informasi serta keputusan (Tholib 2023). Dengan kemampuan menganalisis data dan menemukan pola yang mungkin tidak terlihat manusia, *machine learning* dapat membantu dalam mendiagnosis dini penyakit osteoporosis dan menentukan rencana perawatan yang lebih efektif.

Machine learning terbagi menjadi tiga metode yaitu *supervised learning*, *unsupervised learning*, dan *reinforcement learning*. Klasifikasi adalah salah satu pendekatan dari metode *supervised learning* yang dimana pada metode ini pemberian kelas pada dataset dibutuhkan untuk melihat tingkat akurasi kinerjanya serta mempelajari hubungan dan ketergantungan antar data. Algoritma klasifikasi dapat membantu untuk mengidentifikasi apakah seseorang memiliki risiko penyakit atau tidak secara cepat dan akurat (Putra *et al.* 2024). Algoritma seperti *random forest*, *AdaBoost*, dan *XGBoost* menjadi pilihan karena kemampuan mereka untuk menangani berbagai jenis data, menangani masalah klasifikasi, dan kemampuan untuk menangani *overfitting* (Jan Melvin Ayu Soraya 2023).

Pada penelitian sebelumnya yang dilakukan oleh Xuangao Wu dan Sunmin Park (2023) mengenai prediksi risiko osteoporosis menghasilkan model *random forest* memiliki akurasi sebesar 86.83% dan model *XGBoost* memiliki akurasi sebesar 87.8%. Penelitian lain mengenai skrining osteoporosis menggunakan pembelajaran mesin oleh Albuquerque *et al.* (2023) menunjukkan bahwa model *random forest* memiliki akurasi tertinggi sebesar 89.40%, diikuti oleh model *XGBoost* sebesar 87.51%, dan terakhir model *AdaBoost* sebesar 84.02%.


Penelitian lain yang membahas penggunaan model *XGBoost*, *random forest*, *AdaBoost* dalam memprediksi kelulusan siswa pada mata pelajaran matematika oleh Selly *et al.* (2023) menghasilkan bahwa metode *XGBoost* mempunyai skor akurasi, presisi, *recall*, dan *F1 Score*

yang lebih tinggi dibanding dengan algoritma *random forest* dan *AdaBoost*. Pada *XGBoost* akurasi bernilai 90.88%, presisi bernilai 85.76%, *recall* bernilai 86.92%, dan *F1 Score* bernilai 86.24%.

Pada penelitian ini, dilakukan prediksi risiko osteoporosis dengan membandingkan kinerja dari model *random forest*, *Adaboost*, dan *XGBoost* berdasarkan nilai metrik *confusion matrix* tertinggi dari ketiga model.

METODE

Tahapan dari penelitian yang dilakukan dapat dilihat pada Gambar 1. Tahapan penelitian terdiri dari perencanaan, analisis, perancangan, implementasi, dan uji coba.



Gambar 1 Metode penelitian

Perencanaan

Pada tahap ini, dilakukan penelitian pustaka untuk mengumpulkan data dan informasi yang dibutuhkan. Proses penelitian pustaka mencakup pencarian, peninjauan, dan pemeriksaan penelitian yang dilakukan dari berbagai sumber, termasuk buku, jurnal ilmiah, artikel, dan publikasi lain yang relevan.

Analisis

Osteoporosis sering kali tidak menimbulkan gejala dan biasanya baru terdeteksi setelah terjadi fraktur akibat jatuh atau cedera. Meskipun bisa terjadi pada siapa saja, osteoporosis lebih umum terjadi pada wanita setelah menopause karena penurunan kadar hormon estrogen yang berperan penting dalam menjaga kepadatan tulang.

Berbagai faktor dapat menyebabkan osteoporosis seperti yang disebutkan dalam jurnal *Internal and Emergency Medicine* 2019, osteoporosis dibagi menjadi tiga kategori. Pertama, osteoporosis remaja, yang disebabkan oleh mutasi genetik atau faktor eksternal seperti leukemia, imobilisasi panjang, atau penggunaan obat-obatan seperti antiepilepsi dan glukokortikoid. Kedua, osteoporosis pascamenopause, yang umum terjadi pada wanita setelah menopause akibat penurunan estrogen yang mempercepat kehilangan massa tulang, dengan faktor risiko seperti usia, riwayat keluarga, kurangnya kalsium, merokok, dan konsumsi alkohol. Ketiga, osteoporosis pada pria, dengan faktor risiko seperti riwayat keluarga, berat badan rendah, kurangnya kalsium, merokok, dan konsumsi alkohol.

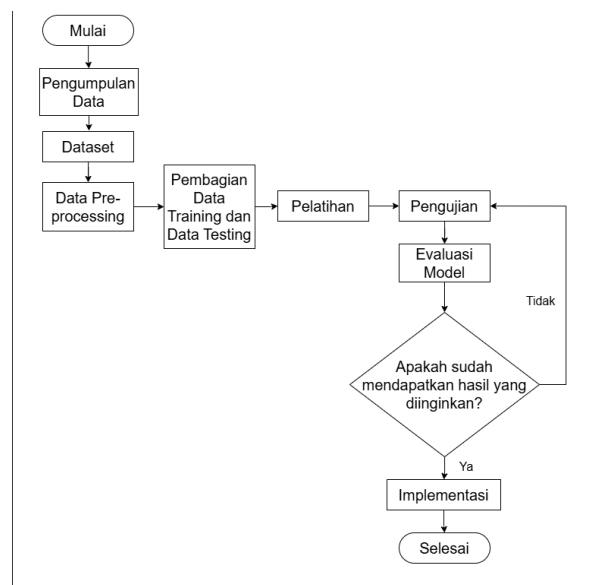
Dalam mendiagnosis dan memprediksi risiko osteoporosis secara efektif, pemilihan algoritma dan evaluasi metrik yang tepat sangat penting, terutama ketika mempertimbangkan berbagai faktor risiko yang mempengaruhi perkembangan penyakit ini. Algoritma seperti *random forest*, *AdaBoost*, dan *XGBoost* dipilih karena kemampuannya dalam menangani

data yang tidak seimbang dan kompleks. *Random forest*, terdiri dari kumpulan *decision trees* yang bekerja bersama untuk menghasilkan prediksi. *AdaBoost*, memiliki kemampuan untuk mengoptimalkan kesalahan model sebelumnya dan memberikan hasil yang lebih akurat dalam deteksi kasus-kasus yang sulit diprediksi. *XGBoost*, sangat efisien dalam memproses data besar dan menangani hubungan non-linear antar fitur dan sering kali menghasilkan kinerja yang lebih baik dalam prediksi.

Dalam mengevaluasi kinerja masing-masing model, digunakan metrik seperti akurasi, presisi, *recall*, dan *F1-score* untuk memberikan gambaran yang lebih komprehensif tentang kemampuan model dalam memprediksi risiko osteoporosis. Akurasi mengukur persentase prediksi yang benar dari keseluruhan data. Namun, karena dataset yang digunakan mungkin tidak seimbang, akurasi saja tidak cukup untuk menilai seberapa baik model bekerja dalam mendeteksi kasus osteoporosis. Oleh karena itu, presisi dan *recall* menjadi sangat penting. Presisi mengindikasikan seberapa banyak dari prediksi positif kasus osteoporosis yang benar-benar sesuai dengan kondisi sebenarnya, sementara *recall* mengukur seberapa banyak kasus osteoporosis yang terdeteksi dari keseluruhan kasus yang ada. *F1-score* merupakan rata-rata harmonis antara presisi dan *recall*, memberikan satu metrik yang mencerminkan keseimbangan antara keduanya, yang sangat berguna terutama dalam situasi di mana ada ketidakseimbangan kelas.

Perancangan

Pada tahap ini, dilakukan penyusunan desain mengenai penerapan algoritma yang digunakan, termasuk pembuatan *flowchart* untuk memvisualisasikan alur penerapan algoritma yang direncanakan. Gambar 2 menunjukkan *flowchart* yang menggambarkan desain penerapan algoritma dalam program.



Gambar 2 Flowchart perancangan program

Berdasarkan Gambar 2, program yang dibangun mengikuti alur yang ditunjukkan oleh *flowchart* tersebut. Tahap awal yaitu pengumpulan data yang digunakan, kemudian dilakukan proses data *pre-processing*, yaitu tahap pembersihan dan transformasi data untuk memastikan kualitas data yang optimal sebelum melanjutkan ke proses berikutnya. Tahapan selanjutnya adalah melakukan pembagian data menjadi dua bagian, yaitu data *training* dan data *testing*, di mana data *training* digunakan untuk melatih model, sementara data *testing* digunakan untuk menguji kinerja model. Pembagian data ini dilakukan sebanyak tiga kali yaitu 80:20, 70:30, dan 60:40. Tahap berikutnya adalah pelatihan model, di mana model dilatih menggunakan data *training* untuk mempelajari pola-pola dalam dataset. Setelah pelatihan selesai, dilakukan

pengujian model menggunakan data *testing* untuk menilai kinerja model. Hasil pengujian kemudian dievaluasi pada tahap evaluasi model guna menentukan apakah model sudah mencapai hasil yang diinginkan. Evaluasi model yang dilakukan mencakup akurasi, presisi, *recall*, dan *F1 score*. Jika hasil evaluasi belum memadai, proses kembali ke tahap pelatihan dan pengujian untuk penyempurnaan model. Namun, jika hasil yang diinginkan sudah tercapai, model kemudian diimplementasikan. Hasil evaluasi ini kemudian digunakan untuk menentukan algoritma terbaik untuk implementasi lebih lanjut.

Implementasi

Pada tahap ini diuraikan proses pembangunan program berdasarkan rancangan yang telah dibuat pada tahap perancangan.

1. Pengumpulan Data

Proses pengumpulan data untuk penelitian ini dilakukan dengan mengunduh dataset dari situs www.kaggle.com yaitu dataset "*Osteoporosis Risk Prediction*". Dataset tersebut awalnya terdiri atas 1958 data, setelah dilakukan proses *data preprocessing*, jumlah data yang digunakan dalam penelitian ini menjadi 1781.

2. Dataset

Dataset adalah kumpulan data yang bisa digunakan sebagai bahan percobaan penelitian (Yuliska dan Syaliman 2020). Variabel dalam penelitian ini terdiri dari 15 variabel, yaitu 14 variabel independen yang mencakup berbagai faktor yang mungkin berpengaruh terhadap hasil penelitian dan 1 variabel dependen yang berfungsi sebagai indikator untuk menentukan apakah seseorang menderita osteoporosis. Daftar variabel penelitian dapat dilihat pada Tabel 1.

Tabel 1 Variabel penelitian

No	Variabel	Tipe	Value
1	Umur	Integer	18-90
2	Jenis Kelamin	Object	Laki-laki Perempuan
3	Perubahan Hormonal	Object	Normal Postmenopausal
4	Riwayat Keluarga	Object	Ya Tidak
5	Etnisitas	Object	Afrika-Amerika Asia Kaukasia
6	Berat Badan	Object	Normal Underweight
7	Asupan Kalsium	Object	Rendah Sedang
8	Asupan Vitamin D	Object	Rendah Sedang
9	Aktifitas Fisik	Object	Aktif Kurang Aktif
10	Merokok	Object	Ya Tidak
11	Konsumsi Alkohol	Object	Ya Tidak
12	Kondisi Medis	Object	Hipertiroidisme Arthritis Rheumatoid Tidak Ada
13	Penggunaan Obat	Object	Steroid Tidak Ada
14	Riwayat Patah Tulang	Object	Ya Tidak
15	Osteoporosis	integer	0 1

3. Data Preprocessing

Data *preprocessing* adalah langkah untuk membersihkan dan menyiapkan data agar siap digunakan dalam model *machine learning* (Ardiansyah 2024). Tujuan dari tahap ini adalah menyiapkan data yang akan diproses agar siap untuk dilakukan pemodelan.

a. Data Cleaning

Data *cleaning* adalah proses menganalisis kualitas data dengan cara memperbaiki, memodifikasi, atau menghapus data yang dianggap tidak relevan, tidak lengkap, tidak akurat, atau memiliki format data atau file yang tidak sesuai di dalamnya untuk menghasilkan data berkualitas tinggi (Darwis *et al.* 2021). Pada proses pembersihan data ini, dilakukan tiga langkah utama. Pertama, baris yang memiliki nilai kosong pada tiga kolom dihapus karena dianggap sebagai kesalahan dalam pengisian data. Kedua, nilai null pada data tertentu diisi dengan string “No” untuk menggantikan kekosongan. Ketiga, kolom id dihapus karena fungsinya dapat digantikan oleh indeks yang sudah tersedia pada *dataframe*.

b. Data Duplikat

Data yang ada pada dataset terkadang memiliki data yang duplikat sehingga penting untuk mengidentifikasi dan menghapus data yang duplikat. Pada dataset ini terdapat enam baris duplikat yang ditangani dengan cara menghapus baris-baris tersebut.

c. Pengkodean Fitur

Pengkodean fitur adalah perubahan nilai pada kolom kategorikal menjadi nilai numerik (Yazid *et al.* 2024). Tahap ini menggunakan dua metode utama yaitu, *label encoding* dan *one-hot encoding*. *Label encoding* diterapkan pada kolom-kolom biner yang hanya memiliki dua nilai unik, seperti *Yes* dan *No* dengan *Yes* diubah menjadi 1 dan *No* diubah menjadi 0. *One-hot encoding* digunakan untuk kolom-kolom yang memiliki lebih dari dua nilai unik, seperti *race/ethnicity* dan *medical conditions*. *One-hot encoding* adalah metode pengkodean yang mengubah kategori menjadi vektor biner, dimana setiap kategori unik dalam kolom tersebut diwakili oleh kolom baru.

d. Skala Fitur

Skala fitur adalah skala nilai dari setiap fitur yang disesuaikan agar memiliki distribusi yang serupa (Maulana *et al.* 2023). Hal ini bertujuan untuk menyelaraskan berbagai fitur pada skala yang seragam. Proses penskalaan dilakukan dengan menggunakan *StandardScaler*, yang mengubah nilai fitur sehingga memiliki *mean* 0 dan standar deviasi 1. Hal ini membuat data menjadi lebih mudah dianalisis dan memungkinkan model prediksi bekerja lebih efektif.

4. Pembagian Data *Training* dan Data *Testing*

Pada tahap ini, dataset dibagi menjadi dua bagian yaitu data *training* dan data *testing*. Data *training* digunakan untuk pembelajaran model yang memungkinkan algoritma mempelajari pola dan hubungan dalam data, sedangkan data *testing* digunakan untuk menilai kinerja model terhadap data yang belum pernah diproses sebelumnya. Pembagian data pada penelitian dilakukan sebanyak tiga kali yaitu 80:20, 70:30, dan 60:40. Dengan menerapkan tiga skenario pembagian yang berbeda, penelitian ini bertujuan untuk mengevaluasi bagaimana perubahan dalam proporsi data *training* dan data *testing* mempengaruhi performa model.

5. Pelatihan Model

Pada tahap pelatihan, model dilatih menggunakan data *training* yang sudah disiapkan sebelumnya. Tujuan dari tahap pelatihan adalah memungkinkan model pembelajaran mesin mengidentifikasi pola dan hubungan antara fitur-fitur dalam dataset dengan target osteoporosis.

6. Pengujian Model

Pada tahap pengujian, model yang telah selesai proses pelatihan selanjutnya dilakukan proses evaluasi menggunakan data *testing*. Data *testing* digunakan untuk menilai kemampuan model dalam membuat prediksi berdasarkan data yang sebelumnya tidak pernah dilihat. Model

menghasilkan *performance measurement* yang berbeda, sehingga terlihat model mana yang memiliki kinerja terbaik.

7. Evaluasi

Tahap ini dilakukan berbagai evaluasi menggunakan metrik *confussion matrix*. *Confusion matrix* adalah tabel yang digunakan untuk menunjukkan kinerja model klasifikasi dengan membandingkan prediksi model terhadap nilai data sebenarnya (Putra *et al.* 2024). Dengan menggunakan *confusion matrix*, berbagai *performance metrics* dapat dihitung seperti akurasi, presisi, *recall*, dan *F1 Score* untuk mengevaluasi efektivitas model yang telah dibuat.

a. Akurasi

Akurasi adalah rasio antara jumlah sampel yang diklasifikasikan dengan benar (*true positives* dan *true negatives*) dibandingkan dengan jumlah total sampel dalam data (Ravly Andryan *et al.* 2022). Rumus akurasi dapat ditunjukkan oleh Persamaan 1.

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (1)$$

b. Presisi

Presisi adalah perbandingan antara jumlah prediksi positif yang benar dibandingkan dengan total hasil prediksi positif keseluruhan (Clara *et al.* 2021). Rumus precision dapat ditunjukkan oleh Persamaan 2.

$$\text{Presisi} = \frac{TP + TN}{TP + FP} \times 100\% \quad (2)$$

c. Recall

Recall adalah presentase prediksi benar positif dari populasi (Undamayanti *et al.* 2022). Rumus *recall* ditunjukkan oleh Persamaan 3.

$$\text{Recall} = \frac{TP}{TP + FN} \times 100\% \quad (3)$$

d. F1 Score

F1-Score merupakan kombinasi presisi dan *recall* yang digunakan untuk menilai kemampuan suatu algoritma dalam mengklasifikasikan kelas minoritas (Fadel *et al.* 2024). Rumus *f1-score* dapat ditunjukkan oleh Persamaan 4.

$$\text{F1 Score} = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \times 100\% \quad (4)$$

8. Perancangan Implementasi Prediksi

Pada tahap implementasi, model yang telah diuji dan dievaluasi kemudian diintegrasikan ke dalam sistem prediksi yang lebih besar. Proses ini melibatkan pembuatan antarmuka pengguna yang memungkinkan pengguna untuk memasukkan data baru dan mendapatkan hasil prediksi secara *real time*.

HASIL DAN PEMBAHASAN

Data Preprocessing

Sebelum dilakukan proses pembelajaran mesin, dataset dibersihkan terlebih dahulu yang meliputi data *cleaning*, data duplikat, pengkodean fitur, dan skala fitur. Langkah-langkah ini bertujuan untuk mengoptimalkan data dan mengurangi distorsi pada hasil model yang dapat terjadi karena ada data yang tidak akurat (Sumarna *et al.* 2024). Dengan dataset yang bersih dan terstruktur dengan baik, model lebih mampu menghasilkan prediksi yang akurat. Dataset awal ditunjukkan pada Gambar 3. Gambar 4 menunjukkan hasil data setelah dilakukan *preprocessing*.

Age	Gender	Hormonal Changes	Family History	Race/Ethnicity	Body Weight	Calcium Intake	Vitamin D Intake	Physical Activity	Smoking	Alcohol Consumption	Medical Conditions	Medications	Prior Fractures	Osteoporosis
69	Female	Normal	Yes	Asian	Underweight	Low	Sufficient	Sedentary	Yes	Moderate	Rheumatoid Arthritis	Corticosteroids	Yes	1
32	Female	Normal	Yes	Asian	Underweight	Low	Sufficient	Sedentary	No	NaN	NaN	NaN	Yes	1
89	Female	Postmenopausal	No	Caucasian	Normal	Adequate	Sufficient	Active	No	Moderate	Hyperthyroidism	Corticosteroids	No	1
78	Female	Normal	No	Caucasian	Underweight	Adequate	Insufficient	Sedentary	Yes	NaN	Rheumatoid Arthritis	Corticosteroids	No	1
38	Male	Postmenopausal	Yes	African American	Normal	Low	Sufficient	Active	Yes	NaN	Rheumatoid Arthritis	NaN	Yes	1
--	--	--	--	--	--	--	--	--	--	--	--	--	--	--
19	Female	Normal	Yes	African American	Normal	Adequate	Sufficient	Sedentary	Yes	Moderate	Rheumatoid Arthritis	NaN	Yes	0
23	Female	Postmenopausal	Yes	Caucasian	Underweight	Low	Insufficient	Active	No	NaN	NaN	Corticosteroids	No	0
34	Female	Postmenopausal	No	African American	Underweight	Low	Sufficient	Sedentary	No	NaN	Hyperthyroidism	NaN	No	0
25	Male	Postmenopausal	No	African American	Normal	Low	Insufficient	Sedentary	Yes	NaN	Rheumatoid Arthritis	Corticosteroids	Yes	0
26	Female	Postmenopausal	No	African American	Underweight	Adequate	Sufficient	Sedentary	Yes	NaN	Rheumatoid Arthritis	Corticosteroids	No	0

Gambar 3 Data risiko osteoporosis sebelum *preprocessing*

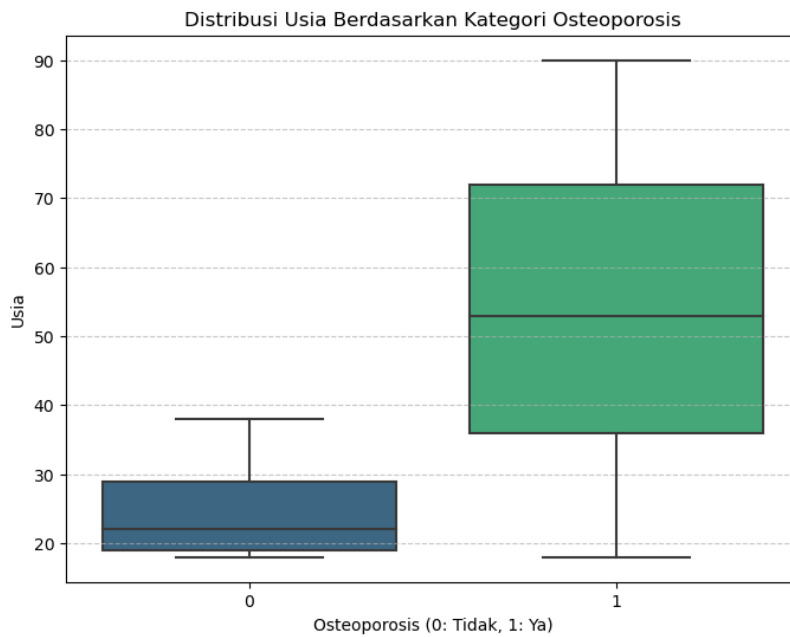
Age	Gender	Hormonal Changes	Family History	Body Weight	Calcium Intake	Vitamin D Intake	Physical Activity	Smoking	Alcohol Consumption	Medications	Prior Fractures	Osteoporosis
1.390285	-1.012984	-1.002808	1.022118	1.047687	0.962022	0.959863	1.042987	0.997200	0.91965	-0.915502	1.003934	1
2.325693	-1.012984	0.997200	-0.978361	-0.954484	-1.039477	0.959863	-0.958785	-1.002808	0.91965	-0.915502	-0.996082	1
1.811218	-1.012984	-1.002808	-0.978361	1.047687	-1.039477	-1.041816	1.042987	0.997200	-1.08737	-0.915502	-0.996082	1
-0.059597	0.987183	0.997200	1.022118	-0.954484	0.962022	0.959863	-0.958785	0.997200	-1.08737	1.092297	1.003934	1
0.080714	0.987183	-1.002808	1.022118	-0.954484	0.962022	0.959863	-0.958785	0.997200	0.91965	-0.915502	1.003934	1
-0.901465	0.987183	0.997200	1.022118	1.047687	-1.039477	0.959863	1.042987	-1.002808	-1.08737	1.092297	-0.996082	1
-0.012827	0.987183	0.997200	1.022118	-0.954484	-1.039477	0.959863	1.042987	-1.002808	-1.08737	-0.915502	1.003934	1
1.437055	0.987183	0.997200	-0.978361	1.047687	0.962022	0.959863	-0.958785	0.997200	-1.08737	-0.915502	-0.996082	1
-0.948235	-1.012984	-1.002808	-0.978361	-0.954484	0.962022	0.959863	-0.958785	0.997200	0.91965	-0.915502	1.003934	1
0.735499	-1.012984	-1.002808	1.022118	1.047687	-1.039477	0.959863	1.042987	-1.002808	0.91965	-0.915502	-0.996082	1
Race/Ethnicity_African American	Race/Ethnicity_Asian	Race/Ethnicity_Caucasian	Medical Conditions_Hyperthyroidism	Medical Conditions_No	Medical Conditions_Rheumatoid Arthritis							
-0.731043	1.449438	-0.700573	-0.781447	-0.601755	1.347867							
-0.731043	-0.689923	1.427403	1.279677	-0.601755	-0.741913							
-0.731043	-0.689923	1.427403	-0.781447	-0.601755	1.347867							
1.367909	-0.689923	-0.700573	-0.781447	-0.601755	1.347867							
-0.731043	-0.689923	1.427403	-0.781447	-0.601755	1.347867							
1.367909	-0.689923	-0.700573	-0.781447	-0.601755	1.347867							
-0.731043	1.449438	-0.700573	-0.781447	-0.601755	1.347867							
-0.731043	1.449438	-0.700573	-0.781447	-0.601755	1.347867							
1.367909	-0.689923	-0.700573	-0.781447	1.661807	-0.741913							
-0.731043	-0.689923	1.427403	-0.781447	-0.601755	1.347867							

Gambar 4 Data risiko osteoporosis setelah *processing*

Gambar 4 adalah hasil setelah dilakukan data *preprocessing*. Data yang telah diproses ini kemudian siap digunakan dalam tahap selanjutnya untuk pelatihan dan pengujian model pembelajaran mesin.


Visualisasi Data

Pada tahap ini dilakukan visualisasi data untuk memahami pola distribusi variabel yang relevan dalam analisis osteoporosis. Visualisasi ini mencakup distribusi usia berdasarkan kategori osteoporosis serta hubungan antar variabel menggunakan peta korelasi. Gambar 5 menunjukkan visualisasi mengenai distribusi usia berdasarkan kategori osteoporosis.



Gambar 5 Visualisasi distribusi usia

Gambar 5 menunjukkan *boxplot* distribusi usia berdasarkan status osteoporosis. Pada kategori osteoporosis = 0 (Tidak), mayoritas individu memiliki rentang usia antara 20 hingga 30 tahun dengan distribusi yang relatif sempit. Tidak ditemukan individu di atas usia 40 tahun dalam kelompok ini, dan median usia berada di sekitar 25 tahun, menegaskan bahwa kelompok ini didominasi oleh usia muda. Sebaliknya, pada kategori osteoporosis = 1 (Ya), rentang usia individu jauh lebih luas, yaitu antara 30 hingga 80 tahun, dengan median usia sekitar 50 tahun. Hal ini menunjukkan bahwa osteoporosis lebih banyak dialami oleh individu yang berusia lanjut. Selain itu, rentang usia yang lebih tinggi pada kelompok ini memperlihatkan bahwa risiko osteoporosis meningkat secara signifikan seiring bertambahnya usia. Gambar 6 menunjukkan visualisasi dari korelasi antara variabel.



Gambar 6 Korelasi antara variabel

Berdasarkan hasil yang terlihat, variabel *hormonal changes* memiliki korelasi tertinggi terhadap osteoporosis (0.69), menunjukkan bahwa fitur ini sangat relevan dalam menentukan target. Selain itu, variabel seperti *medical conditions* dan *race/ethnicity* juga memiliki korelasi signifikan. Sementara itu, beberapa variabel lain, seperti *physical activity*, *calcium intake*, dan *alcohol consumption* menunjukkan korelasi yang lebih lemah terhadap osteoporosis.

Meskipun tingkat korelasi antar variabel berbeda-beda, semua variabel masih dapat dianggap relevan. Menghapus variabel dengan korelasi rendah dapat memengaruhi performa prediksi, tetapi tidak selalu meningkatkan akurasi secara signifikan. Oleh karena itu, mempertahankan ke-14 variabel dapat memastikan bahwa model menangkap semua informasi penting. Variabel dengan korelasi tinggi, seperti *hormonal changes* dan *age* memberikan kontribusi langsung, sementara variabel dengan korelasi rendah tetap memiliki potensi untuk memberikan informasi yang berharga dalam pola non-linear yang sering terjadi dalam algoritma *machine learning* seperti *AdaBoost*, *Random Forest*, atau *XGBoost*.

Hasil Evaluasi

Tahap ini dilakukan proses pelatihan dan pengujian model pembelajaran mesin. Hasil evaluasi dari model yang telah dilatih dan diuji melibatkan beberapa metrik kinerja seperti akurasi, presisi, *recall*, dan *F1 score*.

Evaluasi ini bertujuan untuk menilai performa model yang telah dibuat dan menentukan model mana yang memiliki performa terbaik dalam memprediksi risiko osteoporosis. Dalam penelitian ini, klasifikasi digunakan untuk menentukan apakah seorang pasien berisiko terkena osteoporosis atau tidak. Metrik yang digunakan memberikan gambaran yang komprehensif mengenai kemampuan model dalam mengidentifikasi kasus positif dan negatif secara akurat. Parameter yang digunakan dalam evaluasi ini adalah *average= 'weighted'*. Dengan menggunakan parameter ini skor untuk setiap kelas dihitung secara individual, lalu diambil rata-ratanya dengan memberikan bobot berdasarkan proporsi jumlah sampel di setiap kelas terhadap total sampel. Pendekatan ini sangat berguna untuk menghindari bias yang mungkin terjadi akibat dominasi kelas mayoritas. Hasil evaluasi ditunjukkan pada Tabel 2.

Tabel 2 Hasil evaluasi

Model	Skema	Accuracy		Precision		Recall		F1-Score	
		Latih	Uji	Latih	Uji	Latih	Uji	Latih	Uji
Random Forest	80:20	99.86%	87.11%	99.86%	89.09%	99.86%	87.11%	99.86%	86.96%
	70:30	99.84%	86.54%	99.84%	88.20%	99.84%	86.54%	99.84%	86.38%
	60:40	99.91%	85.83%	99.91%	87.83%	99.91%	85.83%	99.91%	85.68%
AdaBoost	80:20	90.94%	91.04%	92.35%	92.41%	90.94%	91.04%	90.88%	90.97%
	70:30	90.69%	91.96%	92.18%	93.07%	90.69%	91.96%	90.63%	91.90%
	60:40	90.17%	92.01%	91.79%	93.13%	90.17%	92.01%	90.08%	91.97%
XGBoost	80:20	99.86%	90.20%	99.86%	90.77%	99.86%	90.20%	99.86%	90.17%
	70:30	99.84%	89.35%	99.84%	89.54%	99.84%	89.35%	99.84%	89.33%
	60:40	99.91%	90.04%	99.91%	90.36%	99.91%	90.04%	99.91%	90.03%

Berdasarkan hasil evaluasi yang ditunjukkan pada Tabel 2, prediksi terbaik pada algoritma *random forest* dengan skema 80:20 menunjukkan nilai akurasi 87.11%, presisi 89.09%, *recall* 87.11%, dan *F1 score* 86.96%. Pada algoritma *AdaBoost* hasil prediksi terbaik terdapat pada skema 60:40 dengan nilai akurasi 92.01%, precision 93.13%, *recall* 92.01%, dan *F1 score* 91.97%. Algoritma *XGBoost* memiliki prediksi terbaik pada skema 80:20 dengan nilai akurasi 90.20%, presisi 90.77%, *recall* 90.20%, dan *F1 score* 90.17%.

Dengan demikian, algoritma *Adaboost* memiliki hasil terbaik dan lebih akurat dalam memprediksi risiko penyakit osteoporosis. Dibandingkan antara algoritma *random forest* dan *XGBoost*, nilai metrik yang dihasilkan oleh algoritma *AdaBoost* menunjukkan performa

yang unggul dengan selisih nilai yang kecil antara data latih dan uji. *Random forest* dan *XGBoost*, meskipun menunjukkan kinerja yang sangat baik pada data *training*, namun mengalami penurunan performa yang lebih signifikan ketika diuji dengan data *testing*. Hal ini mengindikasikan bahwa algoritma *AdaBoost* tidak hanya unggul dalam pelatihan tetapi juga lebih andal dalam menghasilkan prediksi pada data yang sebelumnya belum pernah dilihat.

Implementasi

Setelah didapat algoritma yang memiliki performa terbaik, langkah selanjutnya adalah mengimplementasikan model ini ke dalam bentuk *website*. Model prediksi yang telah diintegrasikan ke dalam sistem akan memproses data yang diberikan dan memberikan hasil prediksi dalam waktu singkat serta mudah digunakan oleh pengguna. Gambar 7 menunjukkan tampilan awal *website* sebelum digunakan. Gambar 8 menunjukkan tampilan *website* dengan hasil memiliki risiko osteoporosis. Gambar 9 menunjukkan tampilan *website* dengan hasil tidak memiliki risiko osteoporosis.

The screenshot shows a web browser window with the URL <https://prediksiresikoosteoporosis.streamlit.app>. The page title is "Prediksi Resiko Osteoporosis". The form contains the following fields:

Field	Value
Umur	0
Riwayat Patah Tulang Sebelumnya	Ya
Asupan Vitamin D	Rendah
Jenis Kelamin	Laki-laki
Perubahan Hormonal	Normal
Aktivitas Fisik	Aktif
Riwayat Keluarga	Ya
Berat Badan	Normal
Merokok	Ya
Ras/Etnis	Afrika-Amerika
Asupan Kalsium	Rendah
Konsumsi Alkohol	Ya
Pengobatan	Penggunaan steroid
Kondisi Medis	Hipertiroidisme

A "Prediksi" button is located at the bottom left of the form.

Gambar 7 Tampilan halaman sebelum digunakan

The screenshot shows the same web browser window with the URL <https://prediksiresikoosteoporosis.streamlit.app>. The page title is "Prediksi Resiko Osteoporosis". The form contains the following fields:

Field	Value
Umur	67
Riwayat Patah Tulang Sebelumnya	Ya
Asupan Vitamin D	Rendah
Jenis Kelamin	Laki-laki
Perubahan Hormonal	Normal
Aktivitas Fisik	Kurang Aktif
Riwayat Keluarga	Ya
Berat Badan	Underweight
Merokok	Ya
Ras/Etnis	Asia
Asupan Kalsium	Rendah
Konsumsi Alkohol	Ya
Pengobatan	Tidak
Kondisi Medis	Tidak Ada

A "Prediksi" button is located at the bottom left of the form. Below the form, the prediction result is displayed: "Prediksi: Anda memiliki risiko osteoporosis".

Gambar 8 Tampilan saat digunakan dan menghasilkan prediksi memiliki risiko osteoporosis

Gambar 9 Tampilan saat digunakan dan menghasilkan prediksi tidak memiliki risiko osteoporosis

SIMPULAN

Dalam penelitian ini, telah berhasil dirancang dan diimplementasikan sebuah model klasifikasi untuk memprediksi risiko penyakit osteoporosis dengan menggunakan *random forest*, *AdaBoost*, dan *XgBoost*. Penerapan model dilakukan dalam 3 skema rasio pengujian yaitu 80:20, 70:30, dan 60:40. Prediksi risiko osteoporosis berdasarkan 14 variabel yaitu umur, jenis kelamin, riwayat keluarga, etnis, penggunaan obat, riwayat patah tulang, perubahan hormonal, berat badan, asupan kalsium, asupan vitamin D, aktivitas fisik, merokok, konsumsi alkohol, dan kondisi medis.

Algoritma *AdaBoost* dengan skema 60:40 memiliki hasil terbaik dengan nilai akurasi 92.01%, presisi 93.13%, *recall* 92.01%, dan *F1 score* 91.97%. Algoritma *AdaBoost* ini juga memiliki selisih nilai yang kecil antara data latih dan data uji dibandingkan dengan algoritma *random forest* dan algoritma *XGBoost*, sehingga algoritma *AdaBoost* dengan skema 60:40 diimplementasikan ke dalam *website*.

Penelitian selanjutnya dapat dikembangkan lagi dengan cara meningkatkan pemberian pengalaman pengguna melalui penjelasan mendetail mengenai faktor risiko yang paling berkontribusi terhadap prediksi, dengan demikian aplikasi ini tidak sekedar berfungsi sebagai alat prediksi, tetapi juga sebagai alat edukasi yang membantu meningkatkan kesadaran pengguna tentang kesehatan tulang dan tindakan pencegahan yang dapat mereka ambil.

DAFTAR PUSTAKA

- Albuquerque GA, Carvalho DDA, Cruz AS, Santos JPQ, Machado GM, Gendriz IS, Fernandes FRS, Barbalho IMP, Santos MM, Teixeira CAD, Henriques JMO, Gil P, Neto ADD, Campos ALPS, Lima JG, Paiva JC, Morais AHF, Lima TS, Valentim RAM. 2023. Osteoporosis Screening Using Machine Learning and Electromagnetic Waves. *Scientific Reports*. 13(1).
- Ardiansyah RE. 2024. Sistem Pakar Deteksi Dini Penyakit Akibat Gigitan Nyamuk Menggunakan *Machine Learning*. *Jurnal Multidisiplin Saintek*. 3(10).
- Clara S, Laksmi PD, Habsi R, Al Friscila LE, Chamidah N. 2021. Implementasi Seleksi Fitur pada Algoritma Klasifikasi *Machine Learning* untuk Prediksi Penghasilan pada *Adult Income Dataset*. *Senamika*. 2(1).
- Darwis D, Siskawati N, Abidin Z. 2021. Penerapan Algoritma *Naive Bayes* untuk Analisis Sentimen *Review Data Twitter BMKG Nasional*. *Jurnal Tekno Kompak*. 15(1).

- Fadel M, Kanasfi K, Arifin Z, Triyono G. 2024. Application of Ensemble Method for Employee Turnover Predictions in Financial Services Company. *Jurnal Teknik Informatika (JUTIF)*. 5(3):767–775.
- Humaryanto. 2023. *Deteksi Dini Osteoporosis Pasca Menopause*.
- IOF. 2024. *Epidemiology of osteoporosis and fragility fractures*.
- Jan MASD. 2023. Analisis Perbandingan Algoritma XGBoost dan Algoritma Random Forest *Ensemble Learning* pada Klasifikasi Keputusan Kredit. *JURRIMIPA: Jurnal Riset Rumpun Matematika dan Ilmu Pengetahuan Alam*. 2(2):87–103.
- Kementerian Republik Indonesia. 2022. Situasi Osteoporosis di Indonesia. Tim Promkes RSST-RSUP Dr. Soeradji Tirtonegoro Klaten.
- Maulana H, Ramadhan T, Pertiwi A, Defanka GA, Sari AP. 2023. *Clustering RFM (Recency, Frequency, Monetary) Publisher Gim Menggunakan Algoritma K-Means*. *Prosiding Santika*. 3.
- Putra RF, Mukhlis IR, Datya AI, Pipin SJ, Reba F, Al-Husaini M, Judijanto L. 2024. *Algoritma Pembelajaran Mesin: Dasar, Teknik, dan Aplikasi*. PT. Sonpedia Publishing Indonesia.
- Ravly AM, Fajri M, Sulistyowati N. 2022. Komparasi Kinerja Algoritma XGBoost Dan Algoritma Support Vector Machine (SVM) untuk Diagnosa Penyakit Kanker Payudara. *Jurnal Informatika dan Komputer*. 6(1):1–5.
- Wicaksono DS, Maulana RY. 2020. Manfaat Ekstrak Dandelion dalam Mencegah Osteoporosis. *Jurnal Penelitian Perawat Profesional*. 2(2):155–162.
- Selly AAK, Arman HAZ, Zubir E, Fauzan IF. 2023. Prediksi Kelulusan Siswa pada Mata Pelajaran Matematika menggunakan *Educational Data Mining*. *Jurnal Riset Pembelajaran Matematika Sekolah*. 7.
- Sumarna S, Sartini S, Pangesti WE, Suryadithia R, Riyanto V. 2024. Decision Tree Optimization in Heart Failure Diagnostics: a Particle Swarm Optimization Approach. *Jurnal Teknik Informatika (JUTIF)*. 5(3):739–746.
- Tholib, A. 2023. *Buku Refrensi Implementasi Algoritma Machine Learning Berbasis Web dengan Framework Streamlit*.
- Undamayanti E, Iman HT, Kaniawulan, I. 2022. Analisis Sentimen Menggunakan Metode Naive Bayes Berbasis Particle Swarm Optimization Terhadap Pelaksanaan Program Merdeka Belajar Kampus Merdeka. *Jurnal Sains Komputer dan Informatika (J-SAKTI)*. 6(2).
- Wu X, Park S. 2023. a Prediction Model for Osteoporosis Risk Using a Machine-Learning Approach and Its Validation in a Large Cohort. *Journal of Korean Medical Science*. 38(21).
- Yazid M, Sani DA, Anggadimas NM. 2024. Sistem Rekomendasi Penerima Bantuan Sosial APBD Menggunakan Metode Support Vector Machine. *ILKOMNIKA: Journal of Computer Science and Applied Informatics*. 6(1):54–61.
- Yuliska Y, Syaliman KU. 2020. *Literatur Review Terhadap Metode, Aplikasi dan Dataset Peringkasan Dokumen Teks Otomatis untuk Teks Berbahasa Indonesia*. *IT Journal Research and Development*. 5(1):19–31.