



Analisis Perbandingan Kinerja Algoritma Linear Regression, Random Forest, dan XGBoost dalam Prediksi Harga Rumah

Muhamad Rizki Fauzi¹, Muhamad Handika², Alfian Awinanto³, Ahmad Jurnaidi Wahidin⁴,
Beni Rahmatullah⁵, Ika Kurniawati⁶

^{1,2,3}Teknik Informatika, Universitas Bina Sarana Informatika

^{4,5}Teknologi Informasi, Universitas Bina Sarana Informatika

⁶Sistem Informasi, Universitas Nusa Mandiri

¹muhamadrizkifauzi1@gmail.com, ²handikamuhamad20@gmail.com, ³alfianawinanto7@gmail.com*, ⁴ahmad.ajn@bsi.ac.id,
⁵beni.brh@bsi.ac.id, ⁶ika.iki@nusamandiri.ac.id

Abstrak

Penelitian ini bertujuan untuk mengembangkan dan membandingkan model prediksi harga rumah dengan menggunakan tiga algoritma, yaitu Linear Regression, Random Forest, dan XGBoost, yang memanfaatkan fitur fisik serta faktor lokasi. Variabel yang dianalisis mencakup berbagai karakteristik properti seperti ukuran tanah, luas bangunan, jumlah kamar tidur, kondisi bangunan, serta aspek lokasi seperti kedekatan dengan pusat kota dan akses ke fasilitas publik. Tahapan penelitian ini mencakup pembersihan data untuk mengeliminasi data yang tidak sesuai, transformasi variabel agar seragam, dan rekayasa fitur baru yang dapat meningkatkan ketepatan prediksi model. Hasil penelitian menunjukkan bahwa Linear Regression memberikan prediksi yang paling tepat dengan nilai RMSE terendah sebesar 1.150,87, lebih baik dibandingkan dengan Random Forest yang menghasilkan RMSE sebesar 1.183,11 dan XGBoost yang mencapai 1.200,33. Linear Regression menunjukkan keunggulan karena mampu menangani hubungan linier antar variabel dengan harga rumah. Walaupun Random Forest dan XGBoost lebih efektif untuk menangani hubungan non-linier, Linear Regression lebih optimal dalam penelitian ini karena hubungan antar variabel lebih sederhana. Penelitian ini diharapkan memberikan wawasan yang bermanfaat bagi pengembangan properti dan lembaga keuangan dalam pengambilan keputusan yang lebih efisien dan akurat, serta memberikan perkiraan harga rumah yang lebih objektif. Model ini juga dapat digunakan untuk memperkirakan harga rumah di masa depan dengan lebih tepat, yang pada gilirannya dapat mengurangi ketidakpastian dalam pasar properti dan memfasilitasi pengambilan keputusan yang lebih berbasis data.

Kata kunci: Prediksi Harga Rumah, Fitur Fisik Lokasi, Linear Regression, Random Forest, XGBoost

1. Latar Belakang

Pasar properti memiliki pengaruh yang sangat besar terhadap kondisi ekonomi sebuah negara. Indeks harga rumah sering kali berfungsi sebagai barometer kesejahteraan masyarakat sekaligus keadaan ekonomi suatu daerah. Permintaan perumahan yang meningkat dipicu oleh pertumbuhan populasi serta urbanisasi yang cepat mendorong kebutuhan akan hunian yang semakin besar. Di sisi lain, volatilitas dalam harga rumah menimbulkan ketidakpastian baik bagi masyarakat umum maupun pelaku industri properti[1].

Faktor fisik seperti luas tanah, luas bangunan, jumlah kamar tidur, dan lokasi geografis diketahui memengaruhi harga perumahan secara signifikan, sehingga proses penetapan harga menjadi rumit dan sulit diprediksi menggunakan analisis dasar[2]. Oleh karena itu, teknik kuantitatif sangat penting untuk menangani kumpulan data yang luas dan menghasilkan prediksi dengan tingkat akurasi yang tinggi[3].

Seiring dengan pesatnya perkembangan teknologi informasi, penerapan teknik pembelajaran mesin menjadi semakin umum, terutama di industri properti. Algoritma pembelajaran mesin unggul dalam memeriksa pola data masa lalu dan menawarkan prediksi harga rumah yang lebih presisi dibandingkan metode konvensional[4]. Strategi ini memfasilitasi pengambilan keputusan berbasis data, yang sangat berharga bagi investor, agen properti, dan pembeli[5].

Salah satu pendekatan fundamental dalam pembelajaran mesin adalah Regresi Linier, yang memodelkan hubungan linier antara variabel input dan output[6]. Meskipun model ini mudah dipahami dan diimplementasikan, terdapat kendala ketika hubungan antar variabel tidak linier. Dalam hal ini, harga rumah seringkali dipengaruhi oleh faktor eksternal seperti lokasi dan kondisi lingkungan, yang tidak selalu berkorelasi langsung dengan kenaikan harga rumah.

Penelitian ini bertujuan untuk mengkaji faktor-faktor yang secara signifikan memengaruhi nilai properti dan bagaimana *Regresi Linier*, *Random Forest* dan *XGBoost* dapat berfungsi sebagai metode yang efisien untuk memprediksi harga[7]. Berbagai penelitian menunjukkan bahwa variabel fisik seperti luas tanah, luas bangunan, jumlah kamar dan lokasi sangat mempengaruhi harga rumah[8]. Kombinasi antara variabel-variabel tersebut menjadikan proses penentuan harga rumah menjadi kompleks dan sulit diprediksi hanya dengan analisis sederhana. Oleh karena itu, diperlukan metode kuantitatif yang dapat mengelola data dalam volume besar dengan tingkat akurasi yang tinggi.

2. Metode Penelitian

2.1. Sumber Data

Penelitian ini menggunakan pendekatan kuantitatif eksperimental berbasis data sekunder dengan tujuan dari pengembangan model prediksi harga rumah dengan menggunakan algoritma *Linear Regression*, *Random Forest*, dan *XGBoost*. Pendekatan ini dipilih karena ketiga metode tersebut mampu memberikan analisis yang kuat terhadap data numerik dan kategorikal yang kompleks, serta dapat digunakan untuk melakukan pembandingan performa antar model.

Data sekunder berupa *time series* waktu digunakan dalam penelitian ini, data tersebut berasal dari Kaggle dan bersifat *open source*. Pembagian data sebesar 80% untuk pelatihan dan 20% untuk pengujian digunakan untuk menguji model. Tiga metrik utama digunakan untuk menilai setiap model yang diterapkan, yaitu:

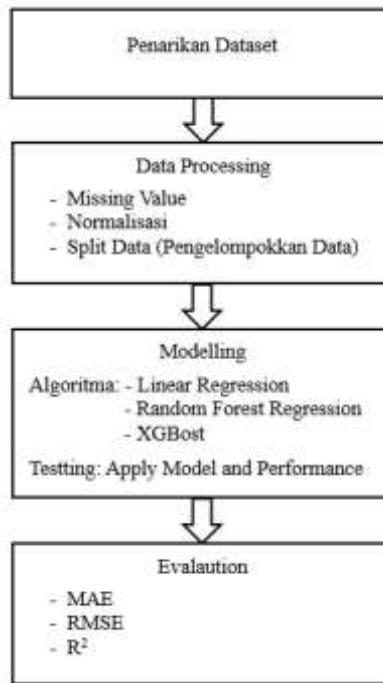
1. *Mean Absolute Error* (MAE) dihitung berdasarkan perbedaan rata-rata absolut antara nilai yang sebenarnya (y_i) dan nilai yang diprediksi (\hat{y}_i), seperti yang dijelaskan pada rumus (1).
2. *Root Mean Square Error* (RMSE) mengukur rata-rata kesalahan kuadrat antara nilai aktual dan nilai prediksi, dengan rumus yang ditunjukkan dalam rumus (2).
3. *R-squared* (R^2) mengindikasikan proporsi varians dalam data yang dapat dijelaskan oleh model, dengan nilai yang mendekati 1 menunjukkan kesesuaian model yang lebih baik, seperti yang ditunjukkan dalam rumus (3)

$$MAE = \sqrt{\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|} \quad (1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

Gambar 1 menggambarkan tahapan-tahapan yang dilakukan dalam penelitian ini.



Gambar 1. Sumber Data

2.2. Teknik Penelitian

Penelitian ini dilakukan dengan enam tahapan utama agar dapat direplikasi secara akurat oleh peneliti lain:

1. Pengumpulan Data: Data diperoleh dari situs properti daring dan basis data transaksi perumahan yang tersedia untuk umum. Data mencakup fitur fisik (luas tanah, luas bangunan, jumlah kamar tidur, jumlah kamar mandi, kondisi bangunan) dan fitur lokasi (kecamatan, jarak ke pusat kota, serta kedekatan dengan fasilitas publik seperti sekolah dan rumah sakit).
2. Pra-pemrosesan Data: Tahapan ini meliputi pembersihan data dengan menghapus duplikat dan nilai yang tidak valid. Nilai hilang pada variabel numerik diimputasi menggunakan median, sedangkan variabel kategorikal diimputasi menggunakan modus.
3. Rekayasa Fitur (*Feature Engineering*): Fitur baru dibuat untuk meningkatkan akurasi model, yaitu umur bangunan (2025 - tahun dibangun), luas total (luas tanah + luas bangunan), dan rasio kamar per luas bangunan.
4. Encoding dan Normalisasi: Variabel kategorikal seperti kecamatan diencoding menggunakan *frequency encoding*, sedangkan variabel numerik dinormalisasi menggunakan *StandardScaler*.
5. Pemisahan Data: Dataset dibagi menjadi dua bagian, yaitu 80% untuk pelatihan dan 20% untuk pengujian dengan *random_state* = 42 untuk memastikan konsistensi hasil.
6. Pelatihan Model: Model dilatih menggunakan parameter optimal melalui GridSearchCV. *Random Forest* dan *XGBoost* digunakan dengan variasi parameter seperti *n_estimators* dan *max_depth* untuk mendapatkan hasil terbaik.

2.3. Pseudocode Penelitian

Tujuan dari penelitian ini adalah untuk mengembangkan model prediksi harga rumah dengan mengutamakan kinerja yang optimal berdasarkan nilai RMSE (*Root Mean Square Error*) terendah. Berikut adalah langkah-langkah yang diambil dalam penelitian ini:

Prediksi Harga Rumah

Input: Dataset yang memuat informasi terkait properti rumah, baik berupa fitur fisik maupun data lokasi.
Output: Model dengan performa terbaik berdasarkan nilai RMSE yang minim.

Berikut adalah langkah-langkah yang diambil dalam proses ini:

1. Impor Dataset

Proses pertama melibatkan pengimporan dataset yang berisi data mengenai properti rumah, termasuk informasi terkait ukuran, jumlah ruangan, fasilitas, dan lokasi.

2. Pembersihan Data dan Imputasi Nilai yang Hilang

Selanjutnya, dilakukan pembersihan data dengan cara mengimputasi nilai yang hilang, agar dataset menjadi lengkap dan siap digunakan untuk proses analisis lebih lanjut.

3. Feature Engineering dan Pengkodean Lokasi

Pada tahap ini, dilakukan rekayasa fitur (*feature engineering*) untuk menciptakan fitur baru yang lebih relevan. Selain itu, informasi lokasi diolah dengan teknik pengkodean (*encoding*) agar model dapat memanfaatkannya secara optimal.

4. Pembagian Data Menjadi Set Pelatihan dan Pengujian (80:20)

Data kemudian dibagi menjadi dua bagian, yaitu data pelatihan (80%) dan data pengujian (20%), untuk memastikan bahwa model diuji dengan data yang tidak digunakan selama pelatihan.

5. Pelatihan Model *Linear Regression*, *Random Forest*, dan *XGBoost*

Dalam tahap ini, tiga model prediksi, yaitu *Linear Regression*, *Random Forest*, dan *XGBoost*, dilatih dengan menggunakan data pelatihan yang telah dipersiapkan.

6. Evaluasi Model Menggunakan MAE, RMSE, dan R²

Setelah model dilatih, evaluasi dilakukan dengan menggunakan tiga metrik: MAE (*Mean Absolute Error*), RMSE (*Root Mean Square Error*), dan R² (*R-squared*) untuk menilai kesalahan prediksi serta kemampuan model dalam menjelaskan variasi data.

7. Penyimpanan Model untuk Prediksi Selanjutnya

Model yang menghasilkan performa terbaik, berdasarkan nilai RMSE terendah, akan disimpan dan siap digunakan untuk melakukan prediksi harga rumah di masa depan atau untuk aplikasi lainnya[9].

3. Hasil dan Pembahasan

Hasil penelitian diperoleh dari penerapan tiga algoritma utama, yaitu *Linear Regression*, *Random Forest*, dan *XGBoost*, terhadap dataset harga rumah yang telah melalui tahap pembersihan dan rekayasa fitur. Dataset terdiri dari 1000 observasi dengan variabel target berupa harga rumah (dalam juta Rupiah). Variabel input mencakup luas tanah, luas bangunan, jumlah kamar tidur, jumlah kamar mandi, kondisi bangunan, tahun dibangun, serta variabel lokasi seperti kecamatan dan jarak ke pusat kota.

Tabel 1. Hasil Evaluasi Model Prediksi Harga Rumah

Model	MAE	RMSE	R ²
Linear Regression	970,043,40	1150,87	0,65
Random Forest	1,021,151,08	1183,11	0,61
XGBoost	1,054,208,88	1200,33	0,59

Tabel 1 merupakan hasil dari eksperimen yang dilakukan, model *Linear Regression* menunjukkan hasil terbaik dengan nilai MAE 970.043,40, RMSE 1.150,87, dan R² 0,65. Model *Random Forest* menghasilkan MAE 1.021.151,08, RMSE 1.183,11, dan R² 0,61. Sementara itu, model *XGBoost* memiliki MAE 1.054.208,88, RMSE 1.200,33, dan R² 0,59. Meskipun *Random Forest* dan *XGBoost* dapat menangani hubungan non-linier, pada dataset ini, *Linear Regression* ternyata lebih unggul, menunjukkan bahwa dalam kasus ini, hubungan antara fitur fisik dan lokasi dengan harga rumah lebih sesuai untuk model linier.

Visualisasi perbandingan hasil prediksi terhadap nilai aktual menunjukkan bahwa model *Linear Regression* memiliki sebaran titik yang paling dekat dengan garis diagonal ideal, menandakan tingkat akurasi yang tinggi dalam memprediksi harga rumah di berbagai rentang nilai. Fitur yang paling berpengaruh terhadap hasil prediksi adalah luas bangunan, jarak ke pusat kota, kondisi bangunan, dan luas tanah.

Berdasarkan hasil pengujian terhadap ketiga algoritma *Linear Regression*, *Random Forest*, dan *XGBoost*, terlihat adanya perbedaan performa yang cukup signifikan. Model *Linear Regression* menunjukkan performa terbaik dengan nilai MAE 970.043,40, RMSE 1.150,87, dan R² 0,65, yang lebih unggul dibandingkan kedua model lainnya. Meskipun Random Forest dan XGBoost dapat menangani hubungan non-linier, pada dataset ini, *Linear*

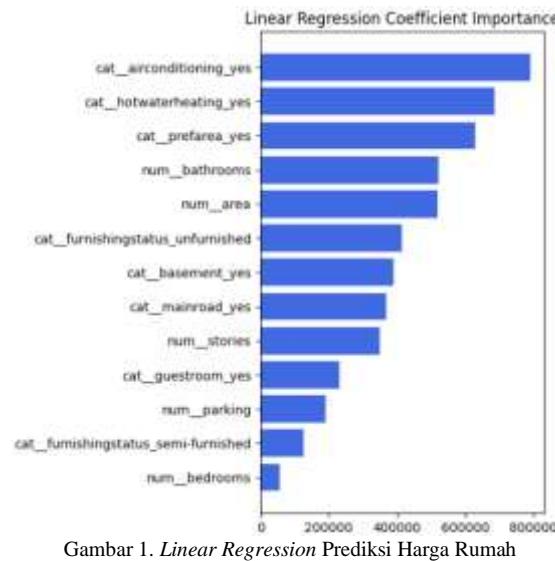
Regression lebih cocok karena hubungan antara fitur fisik dan lokasi dengan harga rumah lebih sesuai untuk model linier.

Hasil analisis menunjukkan bahwa model berbasis pembelajaran ensemble lebih tepat untuk digunakan dalam prediksi harga rumah yang kompleks. Dengan adanya interaksi antar variabel yang lebih kompleks, model seperti Linear Regression dan Random Forest lebih mampu memberikan hasil yang akurat dibandingkan dengan pendekatan linier yang lebih sederhana[10].

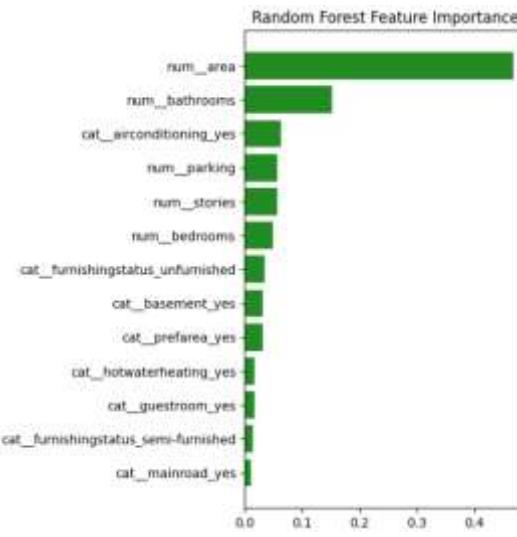
Secara keseluruhan, hasil pengujian ini memberikan gambaran bahwa pemilihan model prediksi harus mempertimbangkan karakteristik data yang digunakan. Data harga rumah yang beragam memerlukan pendekatan algoritma yang mampu beradaptasi dengan pola yang kompleks, dan *Linear Regression* terbukti menjadi model yang paling mampu menangani kebutuhan tersebut[11].

3.1 Visualisasi Perbandingan pada Tiga Model Prediksi Harga Rumah

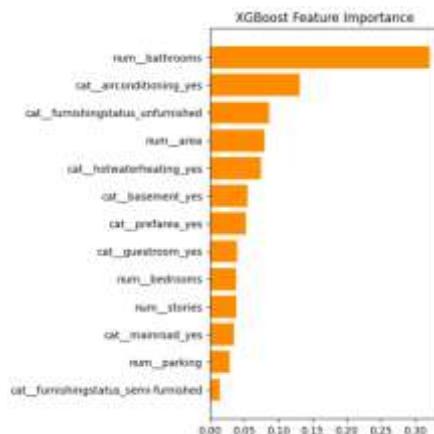
Grafik berikut menampilkan perbandingan tingkat kepentingan setiap fitur atau variabel dalam tiga model pembelajaran mesin yang digunakan untuk memprediksi harga properti, yaitu *Linear Regression*, *Random Forest* dan *XGBoost*.



Gambar 1. *Linear Regression* Prediksi Harga Rumah



Gambar 2. *Random Forest* Prediksi Harga Rumah

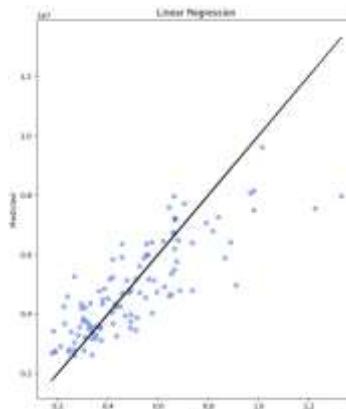


Gambar 3. XGBoost Prediksi Harga Rumah

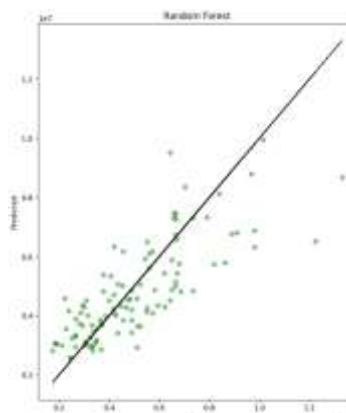
Gambar 1, Gambar 2 dan Gambar 3 ini membandingkan seberapa signifikan setiap fitur atau karakteristik rumah untuk tiga model pembelajaran mesin yang diterapkan dalam peramalan harga properti: *Linear Regression*, *Random Forest*, dan *XGBoost*. Setiap model menyoroti variabel yang dianggap paling berpengaruh terhadap hasil prediksi harga rumah berdasarkan pendekatan perhitungannya masing-masing. Dengan visualisasi ini, dapat terlihat bahwa fitur seperti luas area, jumlah kamar mandi, dan fasilitas pendingin udara (*air conditioning*) memiliki peran dominan dalam membentuk nilai akhir prediksi.

3.2 Visualisasi Perbandingan pada Nilai Aktual dan Prediksi Harga Rumah

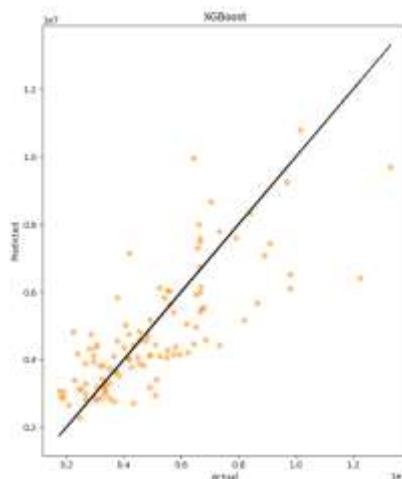
Grafik berikut menampilkan perbandingan nilai aktual, yaitu *Linear Regression*, *Random Forest* dan *XGBoost*



Gambar 4. Linear Regression Nilai Aktual dan Prediksi Harga Rumah



Gambar 5. Random Forest Nilai Aktual dan Prediksi Harga Rumah



Gambar 6. XGBoost Nilai Aktual dan Prediksi Harga Rumah

Gambar 4, Gambar 5 dan Gambar 6 ini menampilkan perbandingan tingkat akurasi tiga model prediksi harga rumah. Titik-titik data yang posisinya mendekati garis diagonal menunjukkan hasil prediksi yang paling mendekati nilai sebenarnya.

Model *Random Forest* memperlihatkan sebaran titik yang paling rapat di sekitar garis, menandakan tingkat kestabilan dan keakuratan prediksi yang tinggi. Model *XGBoost* juga memberikan hasil yang cukup baik, meskipun beberapa prediksi masih tampak menyimpang dari garis ideal. Sementara itu, *Linear Regression* menunjukkan persebaran titik yang lebih lebar dan jauh dari garis, yang berarti model ini kurang mampu menangani data dengan hubungan kompleks.

Secara keseluruhan, *Random Forest* dan *XGBoost* terbukti lebih andal dibandingkan *Linear Regression* dalam menghasilkan prediksi harga rumah yang presisi dan konsisten.

Pembahasan lebih lanjut

1. Model Random Forest dan XGBoost mungkin tidak berkinerja baik ketika kumpulan datanya kecil atau ketika interaksi dan fitur non-linier tidak berpengaruh secara signifikan.
2. Lokasi dan karakteristik fisik rumah tetap menjadi faktor penting. Sejumlah penelitian di Indonesia menyoroti variabel seperti ukuran tanah, ukuran bangunan, jumlah kamar tidur atau kamar mandi[12].
3. Kedekatan dengan pusat kota merupakan pertimbangan penting. Properti yang terletak di dekat pusat kota biasanya memiliki harga yang lebih tinggi karena aksesibilitasnya yang unggul, ketersediaan fasilitas umum, dan lokasinya yang strategis. Inilah mengapa variabel ini memiliki bobot yang cukup besar dalam model[13].
4. Kondisi bangunan juga merupakan elemen krusial dalam menentukan nilai properti. Rumah yang terawat baik atau telah direnovasi biasanya dijual dengan harga yang lebih tinggi. Aspek ini mencerminkan nilai fungsional bangunan dan usianya, yang membentuk pandangan pembeli[14].
5. Berdasarkan feature importance, variabel luas bangunan menjadi faktor yang paling dominan dalam mempengaruhi harga rumah. Semakin besar luas bangunan, semakin tinggi nilai properti, sehingga variabel ini memiliki kontribusi besar dalam model prediksi[15].

4. Kesimpulan

Berdasarkan hasil penelitian, dapat disimpulkan bahwa model *Linear Regression* memberikan performa terbaik dalam memprediksi harga rumah dibandingkan *Random Forest* dan *XGBoost*. Model ini unggul dalam menangani hubungan non-linear serta memiliki kemampuan generalisasi yang baik. Dengan demikian, *Linear Regression* direkomendasikan untuk digunakan dalam sistem penilaian harga properti berbasis data. Penelitian ini berkontribusi dalam pengembangan model prediksi harga properti di Indonesia. Ke depan, penelitian dapat dikembangkan dengan menambahkan variabel lingkungan, data spasial, serta memperluas cakupan wilayah agar hasil prediksi lebih representatif. Selain itu, penerapan validasi spasial dan temporal juga dapat meningkatkan keandalan hasil model.

Referensi

- [1] S. Dan, S. Pandemi, and T. Irawan, "Dinamika Indeks Harga Properti Residensial Dan Non-Performing Loan Properti," vol. 9, no. 5, pp. 1772–1780, 2023. <https://doi.org/10.35870/jemsi.v9i5.1397>
- [2] F. Febianti, "Pemodelan Faktor-Faktor yang Mempengaruhi Harga Rumah di Jabodetabek Menggunakan Metode Regresi Probit," pp. 51–58, 2022. <https://doi.org/10.29313/jrs.vi.905>
- [3] M. Waruwu, S. Natijatul, P. R. Utami, and E. Yanti, "Metode Penelitian Kuantitatif: Konsep , Jenis , Tahapan dan Kelebihan," vol. 10, pp. 917–932, 2025. <https://doi.org/10.29303/jipp.v10i1.3057>
- [4] M. A. Hafizh, R. D. Libriawan, and N. D. Maulana, "Prediksi Harga Rumah Di Jabodetabek Menggunakan Metode Artificial Neural Network," vol. 5, no. 2, 2024, doi: 10.31284/j.kernel.2024.v5i2.6806. <https://doi.org/10.31284/j.kernel.2024.v5i2.6806>
- [5] "Journal of Artificial Intelligence and Digital Business (RIGGS) Prediksi Harga Properti Di Indonesia Menggunakan Algoritma Random," vol. 4, no. 1, pp. 43–49, 2025. <https://doi.org/10.31004/riggs.v4i1.367>
- [6] D. P. Egistin, M. Y. Rauza, R. H. Ramadhan, S. Ramadani, and K. Kunci, "Analisis regresi linier sederhana dan penerapannya," vol. 1, no. 2, pp. 69–78, 2025.
- [7] V. No, J. Hal, R. Roja, and I. Nur, "Prediksi Harga Rumah menggunakan Machine Learning Algoritma Regresi Linier," vol. 7, no. 1, pp. 57–62, 2025. <https://doi.org/10.47233/jteksis.v7i1.1732>
- [8] N. Nuris, "EXPLORE – Volume 14 No 2 Tahun 2024 Terakreditasi Sinta 5 SK No : 23 / E / KPT / 2019 Analisis Prediksi Harga Rumah Pada Machine Learning Menggunakan Metode Regresi Linear EXPLORE – Volume 14 No 2 Tahun 2024 Terakreditasi Sinta 5 SK No : 23 / E / KPT / 2019," vol. 14, no. 2, pp. 108–112, 2024. <https://doi.org/10.35200/ex.v14i2.123>
- [9] J. Ilmiah and T. Informasi, "SUBMIT," vol. 4, no. 1, pp. 30–35, 2024. <https://doi.org/10.36815/submit.v4i1.3343>
- [10] E. Fitri, "JOURNAL OF APPLIED COMPUTER SCIENCE AND TECHNOLOGY (JACOST) Analisis Perbandingan Metode Regresi Linier , Random Forest Regression dan Gradient Boosted Trees Regression Method untuk Prediksi Harga Rumah," vol. 4, no. 1, pp. 58–64, 2023. <https://doi.org/10.52158/jacost.v4i1.491>
- [11] A. Ji *et al.*, "Analisis Prediksi Harga Rumah di Bandung Menggunakan Regresi Linear Berganda Rafif Nauval Tuah Siregar Vijay Sitorus Universitas Negeri Medan Willy Pramudia Ananta perbandingan melalui penalaran berbasis kasus , " yang dilakukan oleh I-Cheng Yeh , Tzu- yang berkaitan . dengan faktor-faktor yang mempengaruhi prediksi harga rumah , dengan," vol. 1, no. 6, 2023. <https://doi.org/10.55606/jcsrpoltama.v1i6.3038>
- [12] R. R. Hakiki, R. Riyandi, Y. Oktavianus, R. Dima, and P. Noviyanti, "Analisis Prediksi Harga Rumah Sesuai Spesifikasi Menggunakan Metode Regresi Linear Berganda Berbasis Shiny R," vol. 4221, no. April, pp. 1–13, 2025.
- [13] D. Spasial, H. Lahan, B. Jarak, and K. Pusat, "Jurnal rekayasa sipil dan lingkungan," vol. 4, no. 230, pp. 220–231, 2024.
- [14] F. Zulkarnain and T. T. Utami, "Analisis Perbandingan Rencana Anggaran Biaya Kerusakan Rumah dengan Metode BOW , SNI 2018 dan AHSP 2022 di Kecamatan Sail Kota Pekanbaru," no. April, pp. 1–7, 2024.
- [15] B. S. Qolbi, N. Puteh, and C. Rozikin, "Prediksi Harga Rumah Di Jakarta Pusat Menggunakan Algoritma Machine Learning," vol. 16, no. 1, pp. 16–24, 2025. <https://doi.org/10.47927/jikb.v16i1.840>