



Prediksi Harga Rumah Di Jakarta Pusat Menggunakan Algoritma Machine Learning

¹Muhammad Brillian Syifa Qolbi, ²Teuku Nurmansyah Puteh, ³Rivandi, ⁴Chaerur Rozikin
^{1,2,3,4}Universitas Singaperbangsa Karawang

Alamat Surat

Email: 2110631170076@student.unsika.ac.id*, 2110631170111@student.unsika.ac.id,
2110631170104@student.unsika.ac.id, chaerur.rozikin@staff.unsika.ac.id

Article History:

Diajukan: 22 Januari 2025; Direvisi: 18 Februari 2025; Accepted: 7 April 2025

ABSTRAK

Kebutuhan akan rumah sebagai tempat tinggal utama semakin meningkat di Indonesia akibat pertumbuhan penduduk yang pesat. Selain sebagai kebutuhan dasar, rumah juga dipandang sebagai investasi berharga dengan nilai yang dapat berubah seiring waktu. Keragaman informasi harga perumahan seringkali membingungkan masyarakat dalam memilih rumah yang sesuai dengan kebutuhan dan kemampuan mereka. Oleh karena itu, diperlukan pengembangan model yang dapat mensimulasikan harga berdasarkan preferensi dan kemampuan masyarakat. Data dikumpulkan menggunakan teknik *web scraping* dengan batasan berlokasi di Jakarta Pusat. Prediksi harga rumah dilakukan menggunakan algoritma Regresi Linear, Support Vector Machine (SVM), dan Random Forest (RF). Hasil prediksi menunjukkan bahwa luas tanah dan luas bangunan merupakan variabel dengan pengaruh terbesar terhadap harga rumah. Dari pengujian yang dilakukan, Random Forest menunjukkan performa terbaik dengan nilai *mean absolute error* (MAE) 3023,501, *root mean squared error* (RMSE) 7112,713, koefisien determinasi (R^2) 0,942, dan *mean absolute percentage error* (MAPE) 0,269.

Kata kunci: Harga Rumah, Prediksi, Random Forest, Regresi Linear, Support Vector Machine

ABSTRACT

The demand for housing in Indonesia is increasing due to rapid population growth. Besides being a basic need, houses are seen as valuable investments with fluctuating values. The diverse housing price information often confuses people in choosing suitable homes. Thus, a model to simulate prices based on preferences and capabilities is needed. Data was collected using web scraping, focusing on Central Jakarta. House prices were predicted using Linear Regression, Support Vector Machine (SVM), and Random Forest (RF) algorithms. Results showed that land and building area significantly impact house prices. Random Forest performed the best, with a mean absolute error (MAE) of 3023.501, root mean squared error (RMSE) of 7112.713, coefficient of determination (R^2) of 0.942, and mean absolute percentage error (MAPE) of 0.269.

Keywords: House Price, Prediction, Random Forest, Linear Regression, Support Vector Machine

1. PENDAHULUAN

Kebutuhan akan rumah atau tempat tinggal merupakan hal pokok bagi setiap individu, terutama di Indonesia yang mengalami pertumbuhan penduduk yang pesat. Hal ini membuat kesadaran akan pentingnya memiliki rumah semakin meningkat (Sari et al., 2022).

Seperti halnya investasi emas, rumah juga menjadi opsi investasi di masa depan karena nilainya yang dapat berubah-ubah seiring waktu dan meningkatnya permintaan akan rumah. Terutama jika lokasinya strategis, dekat dengan sekolah, perkantoran, pusat perbelanjaan, dan sarana transportasi yang mudah, hal ini akan memberikan dampak positif pada nilai rumah dengan cepat. (Athiyah et al., 2021).

Menurut sebuah penelitian (Wijaya et al., 2021) pertimbangan utama bagi generasi milenial dalam memulai kepemilikan rumah meliputi faktor keuangan dan lingkungan, hubungan keluarga dan faktor eksternal, kondisi fisik rumah, serta preferensi dan selera individu. Kendala finansial utama yang dihadapi oleh generasi milenial adalah kurangnya dukungan finansial dari keluarga atau orang terdekat, yang menyebabkan kekhawatiran dan keraguan dalam melakukan pembelian rumah.

Keragaman informasi harga perumahan seringkali membingungkan masyarakat dalam memilih rumah yang sesuai dengan kebutuhan dan kemampuan mereka, termasuk jenis, tipe, dan lokasi perumahan. Oleh karena itu, diperlukan pengembangan model yang dapat memprediksi harga rumah secara akurat.

Terdapat penelitian-penelitian terdahulu yang menggunakan pendekatan *machine learning* dalam mengatasi tantangan ini. Hadi et al. membandingkan 3 algoritma yaitu algoritma Random Forest Regression, Decision Tree, dan Polynomial Regression. Dalam penelitiannya, Random Forest memiliki hasil terbaik tingkat akurasi (R²) sebesar 86,54%, diikuti oleh model Decision Tree dengan tingkat akurasi sebesar 76,39%, lalu model Polynomial Regression dengan tingkat akurasi sebesar 78,13%.

Lestari et al. mengembangkan *website* prediksi dan rekomendasi harga rumah menggunakan algoritma Random Forest Regression dan Cosine Similarity dengan *content-based filtering*. Prosesnya mengikuti metode CRISP-DM. Prediksi menggunakan 75% data latih dan 25% data uji menghasilkan akurasi 85,29%, sementara evaluasi rekomendasi menunjukkan akurasi 89,99%. Pengujian inferensial menunjukkan *precision* 75%, *recall* 100%, dan akurasi 80% untuk prediksi, serta *precision* 78%, *recall* 100%, dan akurasi 80% untuk rekomendasi.

Haryanto et al. melakukan komparasi antara model *multiple linear regression* dengan Random Forest dengan 808 data latih dan 202 data uji. Berdasarkan hasil, model *multiple linear regression* memiliki akurasi 78,5% dan sebesar 81,6% bagi model Random Forest.

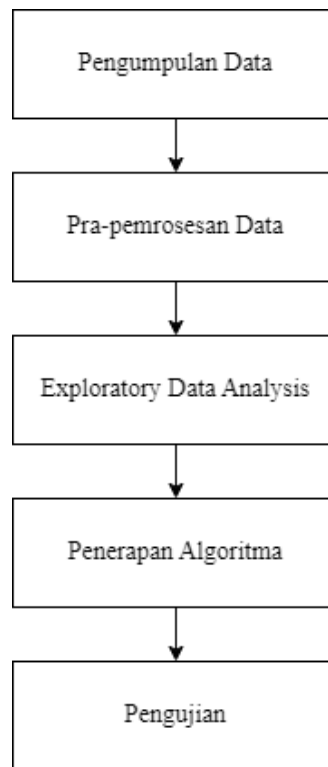
Rahayuningtyas et al. melakukan prediksi harga rumah menggunakan General Regression Neural Network. Model dievaluasi dengan 3 metrik dan memiliki hasil skor 58,72 untuk MSE, 7,66 skor RMSE dan skor 5,99 untuk MAE.

Saiful et al. melakukan studi dokumenter dan *web scraping* pada 2 *website* jual beli rumah terpercaya. *Scraping* dilakukan secara berkala disetiap harinya selama satu bulan hingga terkumpul data sebanyak 7355 sampel. Setelah dilakukan *pre-processing*, data tersisa 794 dan digunakan untuk melatih model regresi linear. Hasil evaluasi menunjukkan nilai R² sebesar 88,5% dan RMSE sebesar 259171,1

Berbagai pendekatan *machine learning* telah diimplementasikan untuk mengatasi tantangan ini. Terdapat tiga algoritma yang digunakan dalam penelitian ini yaitu Regresi Linear, Support Vector Machine (SVM), dan Random Forest (RF). Evaluasi dilakukan berdasarkan keakuratan dan besarnya eror antara nilai prediksi dengan nilai aktual dari masing-masing algoritma. Penelitian ini diharapkan dapat memberikan wawasan berharga dalam memilih algoritma yang paling sesuai dan membantu masyarakat membuat keputusan investasi perumahan yang lebih terinformasi.

2. METODE

Metode penelitian yang dilakukan secara berurutan meliputi pengumpulan data, pra-pemrosesan data, Exploratory Data Analysis, penerapan algoritma, dan pengujian. Tahapan-tahapan tersebut diilustrasikan melalui Gambar 1 dibawah.



Gambar 1. Tahap Metode Penelitian

2.1 Pengumpulan Data

Dalam penelitian ini, dilakukan pengumpulan data menggunakan teknik *web scraping* pada 3 *website* jual beli properti terpercaya dengan membatasi *scraping* untuk hanya mengambil data rumah yang berlokasi di Jakarta Pusat. *Scraping* dilakukan dalam interval tertentu untuk menghindari deteksi bot dan dilakukan selama dua hari.

2.2 Preprocessing

Tahapan *pre-processing* hingga evaluasi dilakukan menggunakan Google Colab. Google Colaboratory (Colab) merupakan layanan komputasi awan (*cloud computing*) yang disediakan secara gratis oleh Google. Layanan ini berfungsi sebagai lingkungan pengembangan terintegrasi untuk menulis, menjalankan, dan berbagi kode Python, serta memfasilitasi pemrosesan data dan implementasi *machine learning*. Fitur utama Google Colab adalah kemampuannya memberikan akses kepada sumber daya komputasi yang kuat, memungkinkan pengguna untuk memanfaatkan kinerja tinggi dalam menjalankan tugas-tugas komputasi intensif. Selain itu, Colab menawarkan antarmuka pengembangan yang ramah pengguna dan terintegrasi dengan alat-alat populer seperti Jupyter Notebook (Guntara, 2023). Pra-pemrosesan data (*data pre-processing*) merupakan tahapan awal dalam proses analisis data dan pembangunan model *machine learning*. Prosedur ini bertujuan untuk meningkatkan kualitas data masukan sehingga mampu menghasilkan performa model yang lebih optimal. Salah satu langkah penting dalam pra-pemrosesan data adalah proses pembersihan (*cleaning*), yang melibatkan perbaikan atau penghapusan data yang rusak, tidak konsisten, atau tidak relevan. Tahapan ini meliputi data tanpa *value*, data duplikasi, kesalahan tipe data, mengatasi outliers, dan normalisasi data.

2.3 Exploratory Data Analysis

Exploratory Data Analysis (EDA) adalah tahapan yang dilakukan untuk mengidentifikasi pola, menemukan data yang menyimpang (*outlier*), menguji hipotesis, serta menguji asumsi-asumsi yang ada. EDA mampu mendeteksi anomali dalam sebuah data, mengungkap hubungan antar variabel data, dan mengekstrak elemen-elemen penting dari data tersebut,

sehingga sangat bermanfaat untuk deteksi kesalahan sejak dini. Proses EDA ini sangat berguna dan memiliki peran penting dalam proses analisis statistik (Haryanto et al., 2023).

2.4 Regresi Linear

Algoritma prediksi pertama yang digunakan adalah Regresi Linear. Regresi Linear sendiri merupakan salah satu jenis model yang tekniknya bertujuan untuk menganalisis nilai taksiran variabel terikat berdasarkan nilai variabel bebas (Mikhael et al., 2022). Regresi Linear terbagi menjadi dua: regresi linear sederhana, yang melibatkan satu variabel terikat dan satu variabel bebas; serta regresi linear berganda, yang melibatkan satu variabel terikat dan dua atau lebih variabel bebas (Herwanto et al., 2019).

2.5 Support Vector Machine

Algoritma berikutnya yang akan dibahas adalah Support Vector Machine (SVM). SVM merupakan metode pembelajaran mesin yang dimanfaatkan untuk mengklasifikasikan dan meramalkan data. Cara kerja SVM adalah dengan menemukan bidang pembatas optimal yang memisahkan sekumpulan data menjadi dua kategori yang berbeda, konsep ini didasari oleh prinsip minimalisasi risiko struktural atau disebut SRM. Algoritma ini mampu mengatasi permasalahan linier maupun non-linier berkat penggunaan fungsi kernel, sehingga memungkinkan penerapannya dalam peramalan deret waktu (*time series*) (Kusumodestoni et al., 2019).

2.6 Random Forest

Algoritma terakhir yang diterapkan adalah algoritma Random Forest. Random Forest adalah metode klasifikasi yang membangun banyak pohon keputusan. Metode ini meningkatkan akurasi dengan menghasilkan simpul anak untuk setiap simpul induk secara acak. Random Forest adalah teknik pembelajaran mesin berbasis ensemble yang digunakan untuk tugas-tugas klasifikasi.. Pendekatan ini membangun sejumlah besar pohon keputusan secara paralel. Pada setiap node dalam pohon keputusan, pemilihan fitur dan titik pemisahan dilakukan secara acak dari subset fitur yang tersedia (Lestari et al., 2022). Pohon keputusan diawali dengan menghitung nilai entropi sebagai penentu tingkat ketidakhomogenan suatu atribut, serta nilai information gain. Rumus untuk menghitung entropi diberikan pada persamaan (1), sedangkan cara menghitung information gain dijabarkan dengan menggunakan persamaan (2) (Hadi et al., 2024).

$$Entropy(Y) = - \sum_i p(c|Y) \log 2p(c|Y) \quad (1)$$

Keterangan:

Y = Sekumpulan kasus

P(c|Y) = Perbandingan nilai-nilai Y yang termasuk dalam kategori c

$$Information\ Gain(Y, a) = Entropy(Y) - \sum_{v \in values(a)} \frac{|Y_v|}{|Y_a|} Entropy(Y_v) \quad (2)$$

Keterangan:

values(a) = Nilai yang mungkin dalam himpunan kasus a

Y_v = Bagian dari Y yang memiliki nilai v untuk kelas a.

Y_a = Semua nilai dalam Y yang cocok dengan a.

2.7 Pengujian

Akurasi suatu prediksi bergantung pada besarnya deviasi atau *error* yang terjadi antara data yang diprediksi dengan data aktual. Kesalahan dalam peramalan tidak hanya disebabkan oleh komponen *error*, tetapi juga ketidakmampuan model untuk mengidentifikasi elemen lain dalam rangkaian data yang memengaruhi besarnya penyimpangan dalam prediksi. Besarnya deviasi ini dapat disebabkan oleh adanya faktor *outlier* yang signifikan, di mana tidak ada

metode prediksi yang mampu menghasilkan prediksi dengan akurasi sempurna (Ayuni et al., 2019). Terdapat berbagai cara untuk menghitung besarnya *error* yang terjadi diantaranya *mean absolute error* (MAE), *root mean squared error* (RMSE), koefisien determinasi atau R2 score, dan *mean absolute percentage error* (MAPE).

2.7.1 Mean Absolute Error (MAE)

MAE menghitung nilai absolut rata-rata dari selisih antara nilai aktual dan nilai prediksi yang dihasilkan oleh model. Secara matematis, MAE dapat diformulasikan melalui persamaan (3) (Rahayuningtyas et al., 2020):

$$MAE = \frac{\sum |y_n - \hat{y}_n|}{n} \quad (3)$$

dimana y adalah nilai aktual, \hat{y} adalah nilai prediksi, dan n adalah jumlah total sampel data

2.7.2 Root Mean Squared Error (RMSE)

RMSE mengkuantifikasi rata-rata kesalahan kuadrat antara nilai aktual dan nilai prediksi yang dihasilkan oleh model. Secara matematis, RMSE dihitung dengan mengambil akar kuadrat dari rata-rata kuadrat selisih antara setiap pasangan nilai aktual dan prediksi. Formula RMSE dapat dinyatakan sebagai berikut:

$$RMSE = \sqrt{\frac{\sum (y_n - \hat{y}_n)^2}{n}} \quad (4)$$

dimana y adalah nilai aktual, \hat{y} adalah nilai prediksi, dan n adalah jumlah total sampel data.

2.7.3 Koefisien Determinasi (R2 Score)

Koefisien determinasi merupakan suatu ukuran yang menunjukkan seberapa baik variabel bebas dapat menjelaskan atau memprediksi variabel terikat. Nilai koefisien determinasi berada dalam rentang 0 hingga 1, dimana semakin mendekati 1 mengindikasikan bahwa model yang digunakan semakin baik. Dengan demikian, koefisien determinasi dapat dijadikan indikator untuk mengevaluasi apakah model regresi yang digunakan sudah tepat atau belum. (Dama et al., 2021). R2 dapat dicari melalui persamaan (5) berikut:

$$R2 = 1 - \frac{SS\ error}{SS\ total} \quad (5)$$

2.7.4 Mean Absolute Percentage Error (MAPE)

MAPE adalah nilai absolute dari persentase *error* data terhadap mean. MAPE yang digunakan untuk mengetahui persentase penyimpangan dan dapat dirumuskan sebagai berikut:

$$MAPE = \frac{\sum \left(\frac{Prediksi - Aktual}{Aktual} \right) * 100}{n} \quad (6)$$

3. HASIL DAN PEMBAHASAN

Data mentah yang dikumpulkan sebelum dilakukan *pre-process* berjumlah 38089. Data disimpan dalam bentuk file csv. Data terdiri dari enam variabel, lima variabel sebagai data input dan satu variabel sebagai output. Variabel input terdiri dari lokasi, kamar tidur, kamar mandi, luas tanah, dan luas bangunan sedangkan variabel outputnya adalah harga rumah. Dataset dapat lebih jelas dilihat pada Gambar 2.

	location	bedroom	bathroom	land_area	building_area	price
0	Menteng, Jakarta Pusat	8.0	8.0	2600 m ²	1500 m ²	Rp 350 Miliar
1	Roxy, Jakarta Pusat	5.0	3.0	129 m ²	280 m ²	Rp 3,5 Miliar
2	Menteng, Jakarta Pusat	5.0	3.0	716 m ²	300 m ²	Rp 22,5 Miliar
3	Menteng, Jakarta Pusat	10.0	10.0	2629 m ²	1724 m ²	Rp 325 Miliar
4	Cempaka Putih, Jakarta Pusat	5.0	5.0	800 m ²	468 m ²	Rp 15 Miliar
...
32084	Cempaka Putih, Jakarta Pusat	5	3	227m2	286m2	Rp 4,5 Miliar
32085	Menteng, Jakarta Pusat	9+7	9+2	925m2	1585m2	Rp 65 Miliar
32086	Kemayoran, Jakarta Pusat	6	2	187m2	187m2	Rp 5,5 Miliar
32087	Roxy, Jakarta Pusat	25	9	432m2	432m2	Rp 25 Miliar
32088	Wahid Hasyim, Jakarta Pusat	6	6	385m2	1200m2	Rp 45 Miliar

32089 rows × 6 columns

Gambar 2. Dataset kotor


Data mentah hasil *scraping* merupakan data kotor dan tidak dapat digunakan untuk analisis lebih lanjut sehingga perlu dilakukan *data pre-processing*. Data bersih hasil *pre-processing* berjumlah 17040 dapat dilihat pada Gambar 3.

	location	bedroom	bathroom	land_area	building_area	price
0	Menteng	8	8	2600	1500	350000.0
1	Roxy	5	3	129	280	3500.0
2	Menteng	5	3	716	300	22500.0
3	Cempaka Putih	5	5	800	468	15000.0
4	Bendungan Hilir	1	1	581	230	22000.0
...
17035	Menteng	7	6	728	690	53000.0
17036	Cempaka Putih	5	3	227	286	4500.0
17037	Kemayoran	6	2	187	187	5500.0
17038	Roxy	25	9	432	432	25000.0
17039	Wahid Hasyim	6	6	385	1200	45000.0

17040 rows × 7 columns


Gambar 3. Dataset bersih

Setelah data bersih, sebaran data dari data rumah dapat dilihat pada Gambar 4 mulai dari kamar mandi, kamar tidur, luas bangunan, dan luas tanah.



Gambar 4. Analisis antara harga dengan variabel input

Matriks korelasi merupakan tabel yang menunjukkan hubungan linier antar variabel menggunakan koefisien korelasi Pearson (-1 sampai +1). Nilai positif menggambarkan hubungan positif, nilai negatif menunjukkan hubungan negatif, sedangkan 0 berarti tidak ada hubungan linier antar variabel (Haryanto, 2023). Dapat dilihat pada Gambar 5 bahwa warna merah menunjukkan korelasi yang kuat sedangkan warna biru menunjukkan korelasi yang lemah.



Gambar 5. Matriks korelasi

Menyesuaikan jumlah data, dataset dibagi menjadi dua, data latih dan data uji, dengan skala 17:3 dimana 85% adalah data latih dan 15% adalah data uji. Hasil evaluasi tercantum pada Tabel 1.

Table 1. Perbandingan model *machine learning*

<i>Model</i>	<i>MAE</i>	<i>RMSE</i>	<i>R2</i>	<i>MAPE</i>
Regresi Linear	3,885e13	4,917e14	-2,727e20	1,1402e10
Random Forest	3023,501	7112,713	0,942	0,269
SVM	15556,16	31428,257	-0,113	1,251

4. SIMPULAN DAN SARAN

Berdasarkan hasil pengujian dan pembahasan yang telah dilakukan maka dapat diambil kesimpulan bahwa:

1. Melalui ujian korelasi menggunakan matriks korelasi, variabel dengan pengaruh terbesar terhadap harga rumah adalah variabel luas tanah dan luas bangunan. Hal ini didukung dalam penelitian sebelumnya yang dilakukan oleh Hadi et al. dalam implementasi *machine learning* untuk prediksi harga rumah.
2. Dari tiga algoritma *machine learning* yaitu regresi linear, SVM, dan Random Forest, Random Forest menunjukkan hasil terbaik dengan nilai MAE 3023,501, RMSE 7112,713, R2 0,942, dan MAPE 0,269

Beberapa hal dibawah ini dapat dijadikan acuan untuk penelitian dan pengujian kedepan agar mendapatkan hasil yang lebih baik:

1. Menggunakan k-fold *cross validation* untuk meminimalisir bias dan menjadikan model yang lebih tergeneralisasi.
2. Penelitian ini hanya menggunakan 5 variabel input. Disarankan agar menambah variabel-variabel lain yang memiliki korelasi terhadap harga.
3. Mengimplementasikan *hyperparameter tuning* seperti Grid Search untuk meningkatkan performa model.

5. DAFTAR PUSTAKA

- Athiyah, U., Hananta, A., Maulidi, T., Putra, V. M. E., Purba, T. F. H., & Bakowatun, E. a. W. (2021). Sistem Pendukung Keputusan Prediksi Harga Rumah Kost untuk Mahasiswa IT Telkom Purwokerto Menggunakan Metode Fuzzy Tsukamoto Berbasis Web. *Journal of Dinda*, 1(2), 77–81. <https://doi.org/10.20895/dinda.v1i2.202>
- Ayuni, G. N., & Fitriannah, D. (2019). Penerapan Metode Regresi Linear Untuk Prediksi Penjualan Properti pada PT XYZ. *Deleted Journal*, 14(2), 79–86. Retrieved from <https://journal.ithb.ac.id/telematika/article/download/321/pdf>
- Dama, H. R. A., Supianto, A. A., & Setiawan, N. Y. (2021). Analisis Penggunaan Model Regresi untuk Prediksi Penjualan Spare Part pada AHASS Nur Andhita Grogol. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 5(12), 5591–5603. Diambil dari <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/10304>
- Guntara, N. R. G. (2023). Pelatihan Sains Data Bagi Pelaku UMKM di Kota Tasikmalaya Menggunakan Google Colab. *Joong-Ki*, 2(2), 245–251. <https://doi.org/10.56799/joongki.v2i2.1572>
- Hadi, N., & Benedict, J. (2024). Implementasi Machine Learning Untuk Prediksi Harga Rumah Menggunakan Algoritma Random Forest. *Computatio*, 8(1), 50–61. <https://doi.org/10.24912/computatio.v8i1.15173>
- Haryanto, C., Rahaningsih, N., & Basysyar, F. M. (2023). KOMPARASI ALGORITMA MACHINE LEARNING DALAM MEMREDIKSI HARGA RUMAH. *JATI*, 7(1), 533–539. <https://doi.org/10.36040/jati.v7i1.6343>
- Herwanto, H. W., Widiyaningtyas, T., & Indriana, P. (2019). Penerapan Algoritme Linear Regression untuk Prediksi Hasil Panen Tanaman Padi. *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi*, 8(4), 364. <https://doi.org/10.22146/jnteti.v8i4.537>
- Kusumodestoni, R. H., & Sarwido, S. (2017). KOMPARASI MODEL SUPPORT VECTOR MACHINES (SVM) DAN NEURAL NETWORK UNTUK MENGETAHUI TINGKAT AKURASI PREDIKSI TERTINGGI HARGA SAHAM. *Jurnal Informatika UPGRIS*, 3(1). <https://doi.org/10.26877/jiu.v3i1.1536>
- Lestari, E. S., & Astuti, I. (2022). Penerapan Random Forest Regression Untuk Memprediksi Harga Jual Rumah Dan Cosine Similarity Untuk Rekomendasi Rumah Pada Provinsi Jawa Barat. *Jurnal Ilmiah FIFO*, 14(2), 131. <https://doi.org/10.22441/fifo.2022.v14i2.003>
- Mikhael, Andreas, F., Enri, U. (2022). Perbandingan Algoritma Linear Regression, Neural Network, Deep Learning, Dan K-Nearest Neighbor (K-NN) Untuk Prediksi Harga Bitcoin. *JSI : Jurnal Sistem Informasi E-journal*, 14(1). <https://doi.org/10.18495/jsi.v14i1.16561>
- Rahayuningtyas, E. F., Rahayu, F. N., & Azhar, Y. (2021). Prediksi Harga Rumah Menggunakan General Regression Neural Network. *Jurnal Informatika/Jurnal Informatika*, 8(1), 59–66. <https://doi.org/10.31294/ji.v8i1.9036>

- Saiful, A. (2021). Prediksi Harga Rumah Menggunakan Web Scrapping dan Machine Learning Dengan Algoritma Linear Regression. *JATISI (Jurnal Teknik Informatika Dan Sistem Informasi)/JATISI: Jurnal Teknik Informatika Dan Sistem Informasi*, 8(1), 41–50. <https://doi.org/10.35957/jatisi.v8i1.701>
- Sari, R. P., & Novitasari, L. (2022). Sistem Penentuan Kelayakan Kredit Pemilikan Rumah Non-Subsidi Menggunakan Metode Weight Product. *JURTI (Jurnal Rekayasa Teknologi Informasi)*, 6(1), 18. <https://doi.org/10.30872/jurti.v6i1.7656>
- Wijaya, D. D., & Anastasia, N. (2021). Pertimbangan Generasi Milenial Pada Kepemilikan Rumah Dan Kendala Finansial. *Jurnal Manajemen Aset Dan Penilaian*, 1(2). <https://doi.org/10.56960/jmap.v1i2.23>