



Rekayasa Fitur untuk Prediksi Harga Mata Uang Virtual dalam Game Online Menggunakan Pendekatan Regresi Linier Berganda

Feature Engineering for Virtual Currency Price Prediction in Online Games Using a Multiple Linear Regression Approach

Muhammad Artherio Chanifudin^{1, a)*}, Sri Ngudi Wahyuni^{2, b)}

^{1,2)}Program Studi Informatika, Fakultas Ilmu Komputer, Fakultas Ilmu Komputer Universitas Amikom, Jl. Ringroad Utara, Sleman, Yogyakarta, Indonesia

^{a)} Corresponding author: Muhammad Artherio Chanifudin, Email: arterioc3@gmail.com

Received: August 8, 2026; Accepted: August 17, 2026

KEY WORDS

Kata kunci:

Feature Engineering
Harga Game
Prediksi
Regresi linier berganda
Machine learning

Keywords:

Feature Engineering
Game Pricing
Prediction
Regresi linier berganda
Machine learning

ABSTRAK

Abstrak. Perubahan harga mata uang virtual Growtopia dapat memengaruhi keputusan pemain ketika membeli, menjual, atau menyimpan item, sementara informasi harga yang beredar di komunitas sering bersifat tidak konsisten. Kondisi ini menegaskan kebutuhan akan prediksi berbasis data yang transparan. Penelitian ini bertujuan memprediksi harga World Lock (WL), Diamond Lock (DL), dan Blue Gem Lock (BGL) menggunakan regresi linier berganda. Kebaruan penelitian terletak pada penerapan tiga model terpisah dengan kombinasi fitur lag dan fitur waktu siklis, disertai pembagian data kronologis untuk menghindari kebocoran informasi. Dataset awal memuat 925 pengamatan harian tahun 2024–2026, sedangkan pemodelan dibatasi pada 194 data tahun 2026 yang memiliki skala konsisten. Setelah pembentukan Lag_1, Lag_2, Lag_7, Day_Sin, dan Day_Cos, tersedia 187 baris lengkap yang dibagi menjadi 150 data latih dan 37 data uji. Model dievaluasi menggunakan MSE, RMSE, MAPE, dan R². Ketiga model menghasilkan R² 0,9318, MAPE 2,3191%, serta akurasi berbasis MAPE 97,6809%. RMSE masing-masing adalah 0,1400 untuk WL, 14,0017 untuk DL, dan 1.400,1705 untuk BGL. Pada 13 Juli 2026, selisih aktual dan prediksi berturut-turut sebesar 0,1743 WL, 17,4286 DL, dan 1.742,8648 BGL. Prediksi rekursif 123 hari menghasilkan nilai akhir 2,8357 WL, 283,5670 DL, dan 28.356,6979 BGL. Hasil menunjukkan model mengikuti pola umum, tetapi responsnya melemah saat perubahan harga terjadi mendadak. Temuan dapat digunakan sebagai informasi pendamping transaksi, bukan sebagai kepastian harga atau anjuran investasi.

Abstract. Changes in the price of Growtopia's virtual currency can influence players' decisions when buying, selling, or storing items, while price information circulating in the community is often inconsistent. This condition confirms the need for transparent, data-driven predictions. This study aims to predict the prices of World Lock (WL), Diamond Lock (DL), and Blue Gem Lock (BGL) using multiple linear regression. The novelty of the study lies in the application of three separate models with a combination of lag features and cyclic time features, accompanied by chronological data sharing to avoid information leakage. The initial dataset contained 925 daily observations from 2024–2026, while the modeling was limited to 194 data points from 2026 that had a consistent scale. After the formation of Lag_1, Lag_2, Lag_7, Day_Sin, and Day_Cos, 187 complete lines are available, divided into 150 training data and 37 test data. The models were evaluated using MSE, RMSE, MAPE, and R². All three models yield an R² of 0.9318, a MAPE of 2.3191%, as well as a MAPE-based accuracy of 97.6809%. The RMSE is 0.1400 for WL, 14.0017 for DL, and 1,400.1705 for BGL, respectively. As of July 13, 2026, the actual and predicted differences are 0.1743 WL, 17.4286 DL, and 1,742.8648 BGL, respectively. The 123-day recursive prediction yields a final value of 2.8357

WL, 283.5670 DL, and 28,356.6979 BGL. The results show the model follows a general pattern, but its response weakens when price changes occur suddenly. The findings can be used as companion information to transactions, rather than as price certainty or investment recommendations.

1. Pendahuluan

Growtopia merupakan gim massively multiplayer online berjenis sandbox yang memberi kebebasan kepada pemain untuk membangun world, memproduksi item, serta berinteraksi melalui perdagangan antar pemain. Aktivitas tersebut membentuk ekonomi virtual yang nilainya tidak hanya ditentukan oleh aturan pengembang, tetapi juga oleh kelangkaan, utilitas, dan kesepakatan komunitas [5], [17], [19]. Dalam beberapa tahun terakhir, mata uang dalam gim juga mendapat perhatian karena desain dan transparansinya dapat memengaruhi cara pengguna memahami serta memperlakukan nilai digital [20], [21]. World Lock (WL), Diamond Lock (DL), dan Blue Gem Lock (BGL) digunakan sebagai satuan nilai utama dalam transaksi Growtopia. World Lock menjadi satuan dasar yang paling umum digunakan, 100 WL dapat dikonversi menjadi 1 DL, dan 100 DL dapat dikonversi menjadi 1 BGL [7]–[10]. Walaupun hubungan konversinya tetap, ketiga satuan dipakai pada transaksi dengan skala berbeda. Perubahan nilai salah satunya dapat mempengaruhi penilaian pemain terhadap harga item dan keputusan untuk membeli, menjual, atau menyimpan aset virtual. Harga dalam ekonomi virtual tidak selalu bergerak stabil. Ketersediaan item, perubahan minat pemain, pola produksi, intensitas transaksi, pembaruan gim, dan aturan platform dapat menggeser keseimbangan pasar [6], [17], [19]. Namun, pengaruh peristiwa eksternal hanya dapat dimasukkan ke model apabila tersedia catatan yang konsisten dan terukur. Dataset penelitian ini tidak menyediakan pengukuran harian tentang event, kebijakan pengembang, jumlah permintaan, aktivitas bot, maupun aktivitas ilegal. Oleh sebab itu, faktor-faktor tersebut diperlakukan sebagai konteks keterbatasan, bukan sebagai variabel prediktor. Bagi pemain yang rutin berdagang, keputusan sering dibuat berdasarkan percakapan komunitas dan pengamatan harga jangka pendek. Informasi tersebut tetap berguna, tetapi dapat menghasilkan penilaian yang tidak konsisten ketika pasar berubah cepat. Analisis deret waktu menawarkan pendekatan yang lebih terukur karena estimasi dibentuk dari urutan nilai masa lalu, lalu diuji pada periode yang lebih baru [11], [12]. Evaluasi yang mempertahankan urutan waktu juga penting agar informasi masa depan tidak bocor ke proses pelatihan dan menghasilkan kinerja yang tampak terlalu tinggi [13], [18]. Regresi linier berganda digunakan karena mampu memodelkan satu variabel respons melalui kombinasi beberapa prediktor dan tetap memberikan koefisien yang mudah ditelusuri [1], [2], [14]. Pada penelitian ini, prediktor tidak dibentuk dari dugaan faktor yang datanya tidak tersedia, melainkan langsung dari urutan harga. Lag_1, Lag_2, dan Lag_7 mewakili harga satu, dua, dan tujuh hari sebelumnya, sedangkan *Day_Sin* dan *Day_Cos* merepresentasikan pola hari secara siklis [15], [16]. Susunan yang sama diterapkan secara terpisah pada WL, DL, dan BGL. Penelitian prediksi aset digital sebelumnya memperlihatkan bahwa data historis dan rancangan evaluasi memegang peranan penting dalam membaca perubahan harga [3], [4]. Meskipun objek dan metode pada penelitian tersebut tidak sama dengan Growtopia, prinsip pengujian kronologis dan penggunaan beberapa ukuran kesalahan tetap relevan. Celah yang diisi penelitian ini adalah penerapan regresi linier berganda secara khusus pada tiga satuan mata uang Growtopia, disertai rekayasa fitur lag, fitur waktu siklus, evaluasi pada data terbaru, serta prediksi rekursif selama empat bulan.

Tujuan penelitian adalah menyiapkan data harga yang konsisten, membangun tiga model regresi linier berganda, mengukur kinerja menggunakan Mean Squared Error (MSE), Root Mean Squared Error (RMSE), Mean Absolute Percentage Error (MAPE), dan R-Square (R^2), serta menghasilkan prediksi 123 hari. Kontribusi akademiknya ialah menunjukkan alur pemodelan harga virtual yang transparan dan terhindar dari pengacakan deret waktu. Kontribusi praktisnya adalah menyediakan informasi berbasis data bagi pemain sebagai pendamping ketika mempertimbangkan transaksi. Hasil model bukan jaminan harga ataupun anjuran investasi. Perkembangan infrastruktur Virtual Private Server (VPS) saat ini diiringi oleh peningkatan ancaman keamanan siber, khususnya serangan otomatis berbasis botnet seperti brute force dan port scanning [1]–[4]. Untuk memitigasi serangan ini, administrator umumnya mengandalkan pemfilteran paket melalui antarmuka baris perintah (CLI) yang memiliki kompleksitas konfigurasi tinggi dan rentan terhadap human error [5]. Sebagai alternatif, berbagai alat bantu berbasis Graphical User Interface (GUI) seperti Cockpit atau Webmin telah dikembangkan untuk menyederhanakan manajemen server. Namun, fungsionalitas manajemen firewall pada alat bantu eksisting tersebut masih sangat terbatas pada aturan allow/deny yang bersifat statis. Kondisi tersebut menunjukkan kebutuhan akan mekanisme respons yang dapat menyesuaikan parameter mitigasi berdasarkan bukti serangan pada log secara lebih cepat dan terukur [1], [6].

Guna menutupi celah fungsionalitas tersebut, penelitian ini bertujuan untuk membangun sebuah aplikasi manajemen keamanan jaringan berbasis antarmuka web. Sistem ini dibuat untuk menggabungkan komponen keamanan Linux ke dalam satu ekosistem yang terpusat. Konsep ini menerapkan kemudahan manajemen zona yang ditawarkan oleh *firewalld* (sebagai lapis kebijakan) dengan kecepatan serta efisiensi pemfilteran paket tingkat dasar dari *nftables* (sebagai lapis eksekusi). Penggabungan dua teknologi ini bertujuan memberikan kontrol visual yang terpusat dan intuitif bagi administrator tanpa harus menurunkan performa sistem operasi.

Kebaruan utama dalam penelitian ini terletak pada integrasi sistem deteksi intrusi aktif yang dilengkapi dengan logika Adaptive Defense Levels. Berbeda dengan sistem firewall statis, fitur pertahanan adaptif ini mampu melakukan auto-scaling response dengan mengubah parameter keamanan, seperti batas maksimal percobaan (maxretry) dan durasi pemblokiran (bantime), dan secara otomatis dikategorikan ke dalam tiga tingkatan (Moderate, Aggressive, Under Attack) berdasarkan kondisi ancaman seketika [7]. Integrasi deteksi berbasis log, pemblokiran IP otomatis, dan visualisasi insiden terpusat diharapkan meningkatkan kecepatan respons administrator terhadap ancaman berulang [8], [9].

2. Tinjauan Pustaka

Ekonomi virtual merupakan sistem pertukaran nilai yang beroperasi di dalam lingkungan digital. Nilai aset virtual dapat muncul dari fungsi aset, tingkat kelangkaan, aturan platform, serta kebiasaan komunitas [5], [17]. Studi mengenai permainan daring menunjukkan bahwa hubungan antara pengelola sistem dan pelaku ekonomi virtual dapat membentuk produksi, distribusi, serta perilaku transaksi [6], [17]. Kasus ekonomi permainan lain juga memperlihatkan bahwa pasar virtual dapat bertahan dalam jangka panjang ketika komunitas memahami mekanisme kepemilikan dan pertukarannya [19]. Pada Growtopia, WL, DL, dan BGL membentuk jenjang mata uang yang saling terhubung [7]–[10]. Relasi konversi tetap membantu penyederhanaan transaksi bernilai besar, tetapi sekaligus membuat pola perubahan persentase ketiga satuan dapat terlihat sama apabila dataset dibentuk dengan skala yang konsisten. Oleh karena itu, perbandingan model tidak cukup dilakukan hanya dengan kesalahan absolut. Metrik relatif diperlukan agar perbedaan satuan tidak menghasilkan kesimpulan yang menyesatkan. Regresi linier berganda memodelkan variabel respons melalui persamaan (1).

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon \quad (1)$$

Dimana Nilai β_0 merupakan intersep, β_1 hingga β_n merupakan koefisien prediktor, dan ε merupakan galat. Metode ini digunakan pada prediksi harga karena perhitungannya efisien, transparan, dan dapat menjelaskan arah hubungan prediktor terhadap target [1], [2], [14]. Implementasi Linear Regression mengestimasi koefisien dengan meminimalkan jumlah kuadrat residu [22]. Pavlyshenko menggunakan pendekatan linier pada harga aset digital yang berubah sepanjang waktu [3], sedangkan Gunarto, Sa'adah, dan Utama menekankan pentingnya RMSE dan MAPE dalam evaluasi prediksi aset digital [4]. Penelitian tersebut menunjukkan bahwa performa tidak seharusnya dinilai melalui satu angka saja. Dalam konteks Growtopia, regresi linier berganda dipakai sebagai model dasar yang dapat diuji dan dijelaskan, bukan untuk dibandingkan dengan algoritma lain. Fitur lag mengubah nilai masa lalu menjadi prediktor bagi nilai berikutnya. Penggunaan Lag_1, Lag_2, dan Lag_7 memungkinkan model membaca ketergantungan harga jangka sangat pendek dan pola mingguan [16]. Sementara itu, representasi sinus dan cosinus membuat urutan hari dipahami secara melingkar, sehingga akhir dan awal siklus tidak dianggap berjauhan [15]. Kombinasi fitur lag dan fitur waktu memberikan lima prediktor yang sama bagi ketiga target.

Evaluasi peramalan harus mempertahankan urutan waktu dan memisahkan data lama sebagai data latih serta data yang lebih baru sebagai data uji [11]–[13], [18]. MSE dan RMSE mengukur kesalahan absolut, MAPE mengukur kesalahan relatif dalam persentase, sedangkan R^2 menjelaskan proporsi variasi nilai aktual yang dapat diterangkan oleh model [12], [23]. R^2 bukan persentase akurasi, sedangkan nilai 100% dikurangi MAPE dalam penelitian ini hanya digunakan sebagai ringkasan akurasi berbasis MAPE.

3. Metode Penelitian

3.1. Pengumpulan Data

Dataset awal terdiri atas 925 pengamatan harian harga WL, DL, dan BGL dari 1 Januari 2024 sampai 13 Juli 2026. Pemeriksaan awal meliputi validasi tanggal, data kosong, data ganda, dan tipe data. Tidak ditemukan tanggal ganda, tanggal terlewat, atau nilai kosong. Akan tetapi, data 2024–2025 memiliki skala yang sangat berbeda dari pola tahun 2026. Agar model tidak mencampurkan rezim data yang tidak sebanding, pemodelan dibatasi pada 194 pengamatan dari 1 Januari sampai 13 Juli 2026. Setelah fitur lag dibuat, tujuh baris pertama belum memiliki riwayat lengkap sehingga dikeluarkan dari pemodelan. Data akhir yang memiliki seluruh fitur berjumlah 187 baris. Model dibangun secara terpisah untuk Harga_WL, Harga_DL, dan Harga_BGL. Seluruh target memiliki lima prediktor yang sama dan tidak menggunakan event, kebijakan pengembang, permintaan, bot, atau aktivitas ilegal karena variabel tersebut tidak tersedia sebagai data terukur.

Tabel 1.

Variabel yang Digunakan dalam Model

Variabel	Peran	Keterangan
Harga_WL	Target	Harga harian World Lock
Harga_DL	Target	Harga harian Diamond Lock
Harga_BGL	Target	Harga harian Blue Gem Lock

Lag_1	Prediktor	Harga satu hari sebelumnya
Lag_2	Prediktor	Harga dua hari sebelumnya
Lag_7	Prediktor	Harga tujuh hari sebelumnya
Day_Sin	Prediktor	Komponen sinus pola hari
Day_Cos	Prediktor	Komponen cosinus pola hari

3.2. Persiapan Data dan Pembentukan Fitur

Tahapan persiapan dimulai dengan membaca dataset, mengubah kolom tanggal menjadi tipe tanggal, mengurutkan data secara kronologis, memeriksa kelengkapan, dan memilih data tahun 2026. Pada setiap target dibuat Lag_1, Lag_2, dan Lag_7 dengan menggeser deret harga. Day_Sin dan Day_Cos dihitung dari posisi hari pada siklus mingguan. Baris yang masih memiliki nilai kosong akibat pembentukan lag kemudian dihapus. Prosedur ini menghasilkan matriks prediktor yang konsisten untuk tiga model. Tidak dilakukan pengecekan. Sebanyak 150 baris pertama digunakan sebagai data latih dan 37 baris terakhir sebagai data uji. Pembagian ini menempatkan data yang lebih lama sebagai dasar pembelajaran dan data lebih baru sebagai simulasi kondisi prediksi nyata. Pendekatan tersebut mengurangi risiko kebocoran informasi dan sejalan dengan prinsip pengujian deret waktu [11]–[13].

3.3. Pemodelan dan Evaluasi

Tiga model dilatih secara independen: Model WL, Model DL, dan Model BGL. Setiap model menggunakan persamaan regresi linier berganda dengan lima prediktor. Prediksi negatif dibatasi menjadi nol karena harga tidak mungkin bernilai negatif. Hasil prediksi pada 37 data uji dibandingkan dengan nilai aktual menggunakan empat metrik utama.

$$MSE = (1/n) \sum (Y_i - \hat{Y}_i)^2 \quad (2)$$

$$RMSE = \sqrt{(1/n) \sum (Y_i - \hat{Y}_i)^2} \quad (3)$$

$$MAPE = (100\%/n) \sum |(Y_i - \hat{Y}_i) / Y_i| \quad (4)$$

$$R^2 = 1 - [\sum(Y_i - \hat{Y}_i)^2 / \sum(Y_i - \bar{Y})^2] \quad (5)$$

Di mana Y_i menyatakan nilai aktual, $\hat{Y}_i$ menyatakan nilai prediksi, $\bar{Y}$ merupakan rata-rata nilai aktual, dan n adalah jumlah data uji. MSE memberikan penalti lebih besar pada kesalahan besar; RMSE kembali ke satuan target; MAPE memudahkan perbandingan lintas skala; dan R^2 menunjukkan daya model [12], [23]. Akurasi berbasis MAPE dihitung sebagai $100\% - MAPE$, tetapi tidak dimaknai sebagai accuracy klasifikasi.

3.4. Prediksi Rekursif

Setelah pengujian, model final dilatih kembali menggunakan seluruh 187 baris yang memiliki fitur lengkap. Prediksi dibuat secara rekursif untuk 123 hari, mulai 14 Juli sampai 13 November 2026. Hasil prediksi suatu hari dimasukkan ke riwayat dan digunakan untuk membentuk Lag_1, Lag_2, dan Lag_7 pada hari berikutnya. Cara ini memungkinkan prediksi harian beruntun, tetapi ketidakpastian dapat terakumulasi ketika horizon semakin panjang [11], [16]. Metode penelitian yang digunakan dalam pengembangan sistem ini mengadopsi model *Prototyping*. Model ini dipilih untuk memfasilitasi integrasi dan pengujian modul keamanan secara bertahap. Fokus utama pada metodologi ini adalah penerapan arsitektur Adaptive Defense Firewall yang dikendalikan melalui sebuah aplikasi antarmuka web secara terpusat.

4. Hasil dan Pembahasan

4.1. Pembentukan Model

Pemilihan data tahun 2026 menghasilkan 194 pengamatan dengan skala yang konsisten. Sesudah pembentukan fitur, 187 baris dapat digunakan, terdiri atas 150 data latih dan 37 data uji. Seluruh kolom target dan prediktor bertipe numerik, tidak terdapat data kosong pada matriks akhir, dan urutan tanggal tetap terjaga. Proses pemodelan yang sama dijalankan tiga kali sehingga setiap mata uang memiliki model sendiri. Dataset mempertahankan hubungan skala $DL = WL \times 100$ dan $BGL = DL \times 100$. Konsekuensinya, pola perubahan relatif ketiga target identik, tetapi galat absolutnya berbeda. Kondisi ini penting untuk interpretasi: nilai RMSE BGL yang besar tidak dapat langsung dianggap lebih buruk daripada RMSE WL karena satuan BGL memang jauh lebih besar.

4.2. Hasil Evaluasi Model

Evaluasi kinerja model dilakukan untuk mengetahui tingkat kemampuan masing-masing model dalam menghasilkan prediksi harga pada beberapa mata uang. Pengukuran menggunakan beberapa metrik, yaitu R^2 , MAPE, RMSE, MSE, dan akurasi berbasis MAPE. R^2 digunakan untuk melihat kemampuan model dalam menjelaskan variasi data, sedangkan MAPE menunjukkan tingkat kesalahan relatif. Sementara itu, RMSE dan


MSE digunakan untuk mengukur besarnya kesalahan prediksi berdasarkan selisih antara nilai aktual dan hasil prediksi model. Adapun hasil evaluasi model disajikan pada Tabel 2.

Tabel 2.

Hasil Evaluasi Model prediksi

Mata Uang	R ²	MAPE (%)	RMSE	MSE	Akurasi (%)
WL	0,9318	2,3191	0,1400	0,0196	97,6809
DL	0,9318	2,3191	14,0017	196,0477	97,6809
BGL	0,9318	2,3191	1.400,1705	1.960.477,0000	97,6809

Ketiga model memperoleh R² sebesar 0,9318. Artinya, sekitar 93,18% variasi harga pada data uji dapat diterangkan oleh kombinasi fitur yang digunakan. MAPE sebesar 2,3191% menunjukkan rata-rata kesalahan relatif yang rendah, sedangkan akurasi berbasis MAPE bernilai 97,6809%. Nilai terakhir merupakan transformasi MAPE untuk kemudahan pembacaan, bukan ukuran akurasi klasifikasi. Perbedaan skala terlihat pada MSE dan RMSE. Model WL menghasilkan MSE 0,0196 dan RMSE 0,1400; Model DL menghasilkan MSE 196,0477 dan RMSE 14,0017; sedangkan Model BGL menghasilkan MSE 1.960.477,0000 dan RMSE 1.400,1705. Perbandingan lintas mata uang lebih tepat dilakukan dengan MAPE dan R², sedangkan MSE serta RMSE dibaca pada satuan target masing-masing.



Gambar 1. Perbandingan Akurasi Berbasis MAPE WL, DL, dan BGL

Gambar 1 menunjukkan bahwa model WL, DL, dan BGL memiliki akurasi berbasis MAPE yang sama, yaitu 97,6809%. Kesamaan ini berasal dari hubungan skala yang tetap pada dataset dan tidak menunjukkan bahwa hanya satu model yang dibangun.

4.3. Perbandingan Harga Aktual dan Prediksi

Pada sebagian besar periode uji, prediksi berada dekat dengan nilai aktual. Harga WL meningkat hingga 4,30 dan DL mencapai 430,00 pada 3 Juli 2026. Ketika terjadi penurunan tajam pada 9–11 Juli, residual membesar karena Lag_1, Lag_2, dan Lag_7 masih membawa informasi harga dari hari-hari sebelumnya. Pada 13 Juli 2026, harga aktual WL sebesar 2,8000 dengan prediksi 2,9743; harga aktual DL sebesar 280,00 dengan prediksi 297,4286; dan harga aktual BGL sebesar 28.000 dengan prediksi 29.742,8648.

Tabel 3.

Perbandingan Nilai Aktual dan Prediksi pada 13 Juli 2026

Mata Uang	Nilai Aktual	Nilai Prediksi	Selisih Absolut
WL	2,8000	2,9743	0,1743
DL	280,0000	297,4286	17,4286
BGL	28.000,0000	29.742,8648	1.742,8648

Tabel 3 memperlihatkan selisih antara nilai aktual dan hasil prediksi pada akhir periode uji. Selisih absolut meningkat sesuai skala mata uang, sedangkan pola kesalahan relatif ketiganya tetap sebanding. Pola tersebut menunjukkan bahwa model bekerja lebih baik ketika perubahan harga berlangsung bertahap. Model tidak selalu dapat mengikuti kejutan harga pada hari yang sama karena prediktor utamanya berasal dari riwayat. Meskipun demikian, nilai MAPE dan R² memperlihatkan bahwa model tetap mampu mengikuti pola umum selama periode

uji. Keterlambatan respons terhadap perubahan ekstrem merupakan keterbatasan penting yang harus dipertimbangkan sebelum hasil digunakan dalam keputusan transaksi.

4.4. Prediksi Harga Empat Bulan

Hasil prediksi harga untuk periode empat bulan disajikan pada Tabel 4 untuk memberikan gambaran mengenai kecenderungan nilai prediksi yang dihasilkan oleh masing-masing model. Prediksi dilakukan berdasarkan pola historis yang telah dipelajari, kemudian dirangkum dalam bentuk rata-rata bulanan pada setiap periode pengamatan. Penyajian ini bertujuan untuk memudahkan perbandingan hasil prediksi antara model WL, DL, dan BGL, sekaligus mengidentifikasi kecenderungan perubahan nilai prediksi selama horizon peramalan. Dengan demikian, tabel memberikan gambaran kuantitatif mengenai arah dan stabilitas prediksi harga.

Tabel 4.

Rata-rata Prediksi Harga Empat Bulan

Periode	Rentang Tanggal	Rata-rata WL	Rata-rata DL	Rata-rata BGL
Bulan ke-1	14 Jul–13 Agu 2026	2,8839	288,3921	28.839,2054
Bulan ke-2	14 Agu–13 Sep 2026	2,8445	284,4488	28.444,8810
Bulan ke-3	14 Sep–13 Okt 2026	2,8386	283,8622	28.386,2210
Bulan ke-4	14 Okt–13 Nov 2026	2,8383	283,8325	28.383,2538

Prediksi dilakukan selama 123 hari. Rata-rata pada bulan pertama sebesar 2,8839 WL, 288,3921 DL, dan 28.839,2054 BGL. Rata-rata kemudian menurun tipis pada bulan kedua dan bergerak relatif stabil sampai bulan keempat. Pada 13 November 2026, nilai prediksi terakhir sebesar 2,8357 WL, 283,5670 DL, dan 28.356,6979 BGL. Selama keseluruhan horizon, prediksi WL berada pada kisaran 2,8200–2,9260, DL pada kisaran 281,9992–292,6013, dan BGL pada kisaran 28.199,9200–29.260,1320. Model tidak memprediksi BGL mendekati 50.000 dalam empat bulan. Hasil tersebut mencerminkan pola data tahun 2026 yang dipelajari oleh model dan bukan kepastian kondisi pasar pada masa mendatang.

5. Kesimpulan

Berdasarkan seluruh tahapan penelitian, regresi linier berganda dapat digunakan untuk memprediksi harga World Lock (WL), Diamond Lock (DL), dan Blue Gem Lock (BGL) secara terpisah dengan Lag_1, Lag_2, Lag_7, Day_Sin, dan Day_Cos sebagai prediktor. Temuan ini menjawab pertanyaan penelitian mengenai penerapan model, tingkat kinerja, serta hasil prediksi empat bulan. Dari 194 data harian tahun 2026, diperoleh 187 baris lengkap yang dibagi secara kronologis menjadi 150 data latih dan 37 data uji. Ketiga model menghasilkan R^2 0,9318, MAPE 2,3191%, dan akurasi berbasis MAPE 97,6809%. RMSE sebesar 0,1400 untuk WL, 14,0017 untuk DL, dan 1.400,1705 untuk BGL memperlihatkan perbedaan skala, bukan perbedaan pola relatif. Pada 13 Juli 2026, nilai aktual dan prediksi masing-masing adalah 2,8000 dan 2,9743 WL; 280,0000 dan 297,4286 DL; serta 28.000,0000 dan 29.742,8648 BGL. Prediksi rekursif 123 hari menghasilkan nilai akhir 2,8357 WL, 283,5670 DL, dan 28.356,6979 BGL. Kontribusi penelitian adalah menyediakan baseline prediksi ekonomi virtual yang transparan, menggunakan pembagian kronologis, serta menjelaskan hubungan antara kesalahan absolut dan skala mata uang. Secara praktis, hasil dapat menjadi informasi pendamping ketika pemain membandingkan harga, tetapi tidak boleh diperlakukan sebagai kepastian atau anjuran investasi. Keterbatasan penelitian mencakup penggunaan data konsisten hanya dari tahun 2026, tidak tersedianya variabel event, permintaan, kebijakan pengembang, dan aktivitas bot, serta akumulasi kesalahan pada prediksi rekursif. Penelitian selanjutnya perlu memperpanjang periode data yang konsisten, memperbarui model secara berkala, meningkatkan dokumentasi sumber harga, dan menambahkan variabel pasar yang benar-benar terukur dengan tetap menggunakan regresi linier berganda agar keterbandingan hasil terjaga.

Funding

Penelitian ini tidak menerima pendanaan khusus dari lembaga pemerintah, lembaga komersial, maupun organisasi nirlaba mana pun.

Author's contribution

Muhammad Artherio Chanifudin: Konsep, Metodologi, olah data, dan Penulisan - Draf Asli, Penulisan - Tinjauan & Penyuntingan, Supervisi. Sri Ngudi Wahyuni: Investigasi, Kurasi Data dan Penulisan. Semua penulis telah membaca dan menyetujui versi naskah yang telah diterbitkan.

Acknowledgments

Penulis menyampaikan terima kasih kepada semua pihak yang telah memberikan dukungan dalam pelaksanaan penelitian ini. Penelitian ini didukung secara pribadi oleh penulis dan tidak menerima pendanaan khusus dari lembaga pemerintah, institusi, maupun organisasi pendanaan lainnya.

AI Use Declaration

Penulis menyatakan bahwa alat bantu AI digunakan secara terbatas dalam proses penyusunan manuskrip untuk membantu tata tulis, memeriksa tata bahasa, dan meningkatkan keterbacaan teks; tidak digunakan dalam perancangan penelitian, pengumpulan dan pengolahan data, analisis, interpretasi hasil, maupun penyusunan kesimpulan.

Daftar Pustaka

- [1] Q. Wang, C. Xu, and T. Zhou, "Stock price prediction based on multiple linear regression," *BCP Business & Management*, vol. 36, pp. 48–54, 2023, doi: 10.54691/bcpbm.v36i.3384.
- [2] R. Hu, "Stock Price Prediction Based on Multiple Linear Regression Model," in *Proceedings of FTBM 2023*, pp. 439–447, 2023, doi: 10.2991/978-94-6463-298-9_48.
- [3] B. M. Pavlyshenko, "Bitcoin Price Predictive Modeling Using Expert Correction," arXiv:2201.02729, 2022.
- [4] D. M. Gunarto, S. Sa'adah, and D. Q. Utama, "Predicting Cryptocurrency Price Using RNN and LSTM Method," *Jurnal Sisfokom*, vol. 12, no. 1, pp. 1–8, 2023, doi: 10.32736/sisfokom.v12i1.1554.
- [5] A. R. Asadi and R. Hemadi, "Understanding Currencies in Video Games: A Review," arXiv:2203.14253, rev. 2024, doi: 10.48550/arXiv.2203.14253.
- [6] Z. Lin, "Design of an in-game economic system based on virtual currency and its impact on player behavior," *Applied Mathematics and Nonlinear Sciences*, vol. 10, no. 1, pp. 1–17, 2025, doi: 10.2478/amns-2025-0662.
- [7] Growtopia, "Growtopia Official Website." [Online]. Available: <https://www.growtopiagame.com/>
- [8] Growtopia Wiki, "World Lock." [Online]. Available: https://growtopia.fandom.com/wiki/World_Lock
- [9] Growtopia Wiki, "Diamond Lock." [Online]. Available: https://growtopia.fandom.com/wiki/Diamond_Lock
- [10] Growtopia Wiki, "Blue Gem Lock." [Online]. Available: https://growtopia.fandom.com/wiki/Blue_Gem_Lock
- [11] R. J. Hyndman and G. Athanasopoulos, *Forecasting: Principles and Practice*, 3rd ed. OTexts, 2021.
- [12] H. Hewamalage, K. Ackermann, and C. Bergmeir, "Forecast evaluation for data scientists: common pitfalls and best practices," *Data Mining and Knowledge Discovery*, vol. 37, pp. 788–832, 2023, doi: 10.1007/s10618-022-00894-5.
- [13] S. Kapoor and A. Narayanan, "Leakage and the reproducibility crisis in machine-learning-based science," *Patterns*, vol. 4, no. 9, Art. no. 100804, 2023, doi: 10.1016/j.patter.2023.100804.
- [14] G. James, D. Witten, T. Hastie, R. Tibshirani, and J. Taylor, *An Introduction to Statistical Learning: with Applications in Python*. Springer, 2023, doi: 10.1007/978-3-031-38747-0.
- [15] Scikit-learn Developers, "Time-related feature engineering," scikit-learn documentation, 2026.
- [16] Scikit-learn Developers, "Lagged features for time series forecasting," scikit-learn documentation, 2026.
- [17] G. Zhang and S. Bi, "Evolutionary game analysis of online game studios and online game companies participating in the virtual economy of online games," *PLOS ONE*, vol. 19, no. 1, Art. no. e0296374, 2024, doi: 10.1371/journal.pone.0296374.
- [18] S. Makridakis, E. Spiliotis, and V. Assimakopoulos, "M5 accuracy competition: Results, findings, and conclusions," *International Journal of Forecasting*, vol. 38, no. 4, pp. 1346–1364, 2022, doi: 10.1016/j.ijforecast.2021.11.013.
- [19] M. L. F. Ramos, "The MTGO Virtual Economy: A Case Study on a Play-to-Earn Game," *Games and Culture*, vol. 21, no. 4, pp. 647–665, 2026, doi: 10.1177/15554120241273867.
- [20] European Commission, "Key Principles on In-Game Virtual Currencies," 2025.
- [21] J. Alcazar and S. Baird, "Game Changer: The Evolution of Video Games' Payments Infrastructure," *Federal Reserve Bank of Kansas City*, 2025.
- [22] Scikit-learn Developers, "LinearRegression," scikit-learn documentation, 2026.
- [23] Scikit-learn Developers, "Metrics and scoring: quantifying the quality of predictions," scikit-learn documentation, 2026.