

PREDIKSI KONSUMSI ENERGI MENGGUNAKAN *REGRESI LINIER* DAN *MULTILAYER PERCEPTRON (MLP)* PADA ALGORITMA KONSENSUS *PROOF OF WORK (POW)*

Wahid Ivan Saputra¹, Bagus Satrio Waluyo Poetro²

^{1,2}Universitas Islam Sultan Agung, Semarang

vandv190220@std.unissula.ac.id¹, bagusswp@unissula.ac.id²

Received: 10-08-2025

Revised: 20-08-2025

Approved: 25-08-2025

ABSTRAK

Penelitian ini bertujuan untuk membangun model prediksi konsumsi energi yang akurat pada jaringan blockchain Bitcoin yang menggunakan algoritma konsensus Proof of Work (PoW). Permasalahan utama yang diangkat adalah tingginya konsumsi energi PoW yang bersifat dinamis dan non-linier, sehingga sulit diprediksi menggunakan metode linier sederhana. Untuk mengatasi hal ini, penelitian ini menerapkan metode deep learning menggunakan Multilayer Perceptron (MLP) untuk memprediksi selisih konsumsi energi (*gap_twh*). Kinerja model MLP kemudian dievaluasi dan dibandingkan dengan model Regresi Linier yang digunakan sebagai baseline. Data historis dari Digiconomist (2017–2025) digunakan setelah melalui tahap preprocessing dan feature engineering. Hasil evaluasi menunjukkan bahwa model MLP memiliki kinerja yang jauh lebih unggul, dengan nilai MAE 3.4620, MSE 46.9281, dan R^2 0.9390, dibandingkan dengan Regresi Linier. Temuan ini membuktikan bahwa MLP sangat efektif dalam memodelkan kompleksitas konsumsi energi PoW dan dapat menjadi acuan bagi para pemangku kepentingan untuk mengoptimalkan efisiensi energi dalam aktivitas penambangan kripto.

Kata kunci: Blockchain, Proof of Work, Konsumsi Energi, Regresi Linier, Multilayer Perceptron

PENDAHULUAN

Teknologi blockchain menghadirkan revolusi dalam pencatatan transaksi yang aman, transparan, dan terdesentralisasi. Penerapannya tidak hanya terbatas pada sektor keuangan, tetapi juga merambah ke bidang kesehatan, logistik, hingga pemerintahan digital (Poongodi dkk., 2020). Inti dari keandalan teknologi ini terletak pada algoritma konsensus, yaitu mekanisme yang menjamin validitas data di seluruh jaringan (Xiong dkk., 2022).

Di antara berbagai algoritma konsensus, *Proof of Work* (PoW) merupakan mekanisme paling fundamental dan teruji. Algoritma ini mengharuskan penambang menyelesaikan teka-teki kriptografi kompleks menggunakan daya komputasi tinggi untuk memvalidasi transaksi dan menambahkan blok baru ke rantai blockchain (Afrian dkk., 2024). Mekanisme PoW terbukti tangguh terhadap serangan karena memerlukan kekuatan komputasi yang sangat besar untuk melakukan manipulasi data, sebuah konsep yang dikenal dengan 51% *attack* (Lee & Kim, 2020).

Namun, Kekuatan komputasi yang menjadi dasar keamanan algoritma *Proof of Work* (PoW) juga menjadi sumber utama permasalahan terkait keberlanjutan energi. Penelitian oleh (de Vries, 2018) menyoroti bahwa seringkali konsumsi energi Bitcoin tidak diestimasi dengan tepat. Menurut analisisnya, setiap kenaikan 1 dolar AS pada harga Bitcoin diperkirakan meningkatkan konsumsi energi tahunan jaringan sebesar 5,4 Terawatt-hour (TWh). Dengan mempertimbangkan dinamika pasar, estimasi konsumsi energi tahunan jaringan pada akhir tahun 2020 bisa mencapai 128 TWh, sebuah angka yang setara dengan konsumsi listrik negara Argentina atau Uni Emirat Arab pada tahun yang sama. Angka ini menunjukkan bahwa dampak energi dari setiap fluktuasi harga aset kripto sangatlah signifikan. Dampak konsumsi ini bersifat multidimensi, termasuk emisi karbon yang mencapai lebih dari 90 juta ton per

tahun(Sapra & Shaikh, 2023). Secara sosial-ekonomi, konsumsi listrik masif ini telah memicu krisis energi lokal serta mengancam stabilitas jaringan listrik nasional, sehingga mendorong negara seperti Tiongkok, Argentina, dan Iran memberlakukan pembatasan bahkan pelarangan total aktivitas *mining*(Truby dkk., 2022).

Sebagai respons, industri *blockchain* mengembangkan mekanisme alternatif yang lebih ramah energi, seperti *Proof of Stake* (PoS) yang berhasil diadopsi *Ethereum* melalui pembaruan The Merge pada 2022, mengurangi konsumsi energi hingga 99,95%(Tsuyuguchi & Wang, 2024). Kendati demikian, PoW tetap digunakan oleh *Bitcoin* sebagai kripto dengan kapitalisasi pasar terbesar di dunia. Oleh sebab itu, dampak lingkungan PoW tidak dapat diabaikan dalam konteks ekosistem energi global.


Permasalahan yang muncul adalah konsumsi energi PoW bersifat dinamis dan non-linier sehingga sulit diprediksi secara akurat. Upaya prediksi menggunakan metode sederhana seperti regresi linier menunjukkan keterbatasan karena model ini tidak mampu menangkap pola non-linier yang kompleks(Rukhiran dkk., 2024). Sementara itu, potensi penerapan *Multilayer Perceptron* (MLP) dalam konteks prediksi energi PoW masih jarang dieksplorasi secara komprehensif. Untuk menjawab celah penelitian ini, studi ini mengusulkan penggunaan MLP sebagai model prediksi yang lebih adaptif dibanding regresi linier. MLP dipilih karena kemampuannya dalam menangkap hubungan non-linier dan mengolah data berdimensi tinggi, sehingga diharapkan dapat memberikan hasil prediksi yang lebih presisi(Gulo & Lubis, 2024).

Pada penelitian ini, regresi linier tetap digunakan sebagai *baseline* untuk membandingkan peningkatan performa yang diberikan oleh MLP. Dengan demikian, penelitian ini bertujuan untuk menganalisis pola konsumsi energi PoW berdasarkan data historis *Bitcoin*, mengembangkan model prediksi konsumsi energi menggunakan regresi linier dan MLP, serta mengevaluasi performa kedua model menggunakan metrik MAE, MSE, dan R^2 . Secara praktis, penelitian ini diharapkan mampu memberikan kontribusi dalam strategi penghematan energi *blockchain*, mendukung pengembangan konsep *green mining*(Laimon dkk., 2025), serta menjadi referensi bagi pembuat kebijakan dalam merumuskan regulasi terkait konsumsi energi *kripto*.

METODE PENELITIAN

Pada tahap ini, dijelaskan secara menyeluruh arsitektur konseptual dan alur kerja penelitian yang dirancang untuk mendukung proses analisis konsumsi energi berbasis *blockchain*. Penelitian ini disusun dalam beberapa tahapan utama yang saling terintegrasi, dimulai dari pengumpulan data mentah hingga evaluasi hasil prediksi secara kuantitatif. Setiap tahapan dirancang untuk memastikan bahwa proses berjalan secara sistematis, efisien, dan dapat direproduksi, sehingga hasil yang diperoleh memiliki validitas dan reliabilitas yang tinggi.

Diagram alur kerja berikut menggambarkan secara visual tahapan-tahapan utama dalam penelitian ini, mulai dari pengumpulan data hingga *deployment* model, dan menjadi fondasi metodologis dalam menghasilkan analisis tren konsumsi energi yang akurat dan bermakna.



Gambar 1 Tahap penelitian

Proses dimulai dari langkah-langkah yang akan dilakukan secara komprehensif dengan tahapan awal mengambil dataset konsumsi energi *Bitcoin* dari sumber *Digiconomist*, yang memuat informasi datetime, estimasi konsumsi energi tahunan (TWh), dan konsumsi minimum tahunan. Dataset ini digunakan sebagai dasar analisis tren dan pelatihan model prediksi. Proses selanjutnya *Preprocessing*, yang mencakup *cleaning data*, mengubah nilai string ke float, menangani *missing values* untuk memastikan kualitas data. Proses ini dilanjutkan dengan *feature engineering* yaitu mengubah variabel dari data mentah agar lebih informatif dan relevan untuk model prediksi dengan ekstraksi fitur waktu dari kolom *DateTime* untuk membantu model mengenali pola musim serta tren jangka panjang, serta dibuat *lag features* yang bertujuan mempresentasikan nilai konsumsi energi pada hari-hari sebelumnya. Setelah data siap, dilakukan pemodelan *regresi linier* untuk mengidentifikasi tren konsumsi energi dari waktu ke waktu serta memahami pola dasar pertumbuhan energi pada jaringan blockchain *Proof of Work (PoW)*. Hasil dari proses analisis regresi linier digunakan sebagai dasar untuk membangun model prediksi berbasis *Artificial Neural Network (ANN)*, yaitu *Multilayer Perceptron (MLP)*. Model ini dirancang untuk menangkap pola non-linier dan fluktuatif dalam data.

Model dievaluasi menggunakan metrik seperti *Mean Squared Error (MSE)*, *Mean Absolute Error (MAE)*, dan *R-squared (R^2)*, untuk mengukur akurasi dan performa prediksi. Selanjutnya, dilakukan visualisasi hasil prediksi dan residual guna mempermudah interpretasi dan analisis performa model. Tahapan akhir adalah *deployment*, yaitu penerapan model dalam antarmuka interaktif berbasis *Streamlit* agar pengguna dapat melihat prediksi konsumsi energi secara real-time dan eksploratif.

Adapun metode penelitian yang digunakan oleh penelitian tersebut, yaitu sebagai berikut:

1. Pengumpulan Data

Pada tahap awal pengumpulan data yang diperlukan untuk penelitian dengan menggunakan *dataset* yang berasal dari sumber terbuka. *Dataset* yang digunakan diambil dari platform *Digiconomist* [Bitcoin Energy Consumption Index - Digiconomist](#), yang secara rutin menyediakan estimasi konsumsi energi jaringan *blockchain*. *Dataset* tersebut kemudian diunduh dan disimpan secara lokal untuk kebutuhan pengolahan data dan pemodelan.

Dataset yang digunakan secara khusus berfokus pada jaringan Bitcoin dan memuat tiga kolom utama, yaitu *DateTime*, *Estimated TWh per Year*, dan *Minimum TWh per Year*. Data ini dipilih karena menyajikan informasi konsumsi energi tahunan yang relevan, lengkap, dan terstruktur, sehingga dapat digunakan untuk menganalisis efisiensi algoritma konsensus *Proof of Work* (PoW). Selain itu, *dataset* ini juga memiliki keunggulan karena mencakup data historis yang cukup panjang, mulai dari tahun 2017 hingga 2025, yang sangat berguna untuk membangun model prediksi berbasis tren jangka panjang.

Nilai *Estimated TWh per Year* dan *Minimum TWh per Year* pada *dataset* ini nantinya akan digunakan untuk menghitung selisih konsumsi energi (*gap_twh*) sebagai variabel target prediksi. Sementara itu, kolom *DateTime* akan diolah menjadi berbagai fitur berbasis waktu seperti tahun, bulan, dan *ordinal time* untuk membantu model mengenali pola musiman. Data yang telah dikumpulkan ini menjadi fondasi utama dalam proses analisis dan pelatihan model, baik untuk metode *Regresi Linier* sebagai *baseline* maupun *Multilayer Perceptron* (MLP) untuk prediksi dengan pendekatan non-linear (Pawar dkk., 2025).

2. Preprocessing Data

Tahap preprocessing dilakukan untuk memastikan kualitas data sebelum digunakan dalam pemodelan. Proses ini mencakup beberapa langkah penting, yaitu:

a. Data Cleaning

Pemeriksaan awal menunjukkan adanya nilai kosong (*missing values*) pada kolom *Estimated TWh per Year*, khususnya pada tahun 2021 dan 2022. Sebanyak 365 baris data diisi menggunakan metode interpolasi linier untuk menjaga kontinuitas tren konsumsi energi. Selain itu, ditemukan dua baris duplikat yang dihapus menggunakan fungsi `drop_duplicates()` agar tidak mempengaruhi distribusi data.

b. Feature Engineering

Feature engineering dilakukan untuk meningkatkan relevansi dan representasi data terhadap target prediksi (*gap_twh*). Langkah-langkah yang dilakukan meliputi:

- Ekstraksi Waktu: Kolom *DateTime* diubah menjadi fitur tahun, bulan, dan *ordinal time* untuk menangkap pola musiman dan kronologi data.
- Lag Features: Dibentuk fitur historis seperti *TWh_Lag1*, *TWh_MA7*, *TWh_MA30*, dan *TWh_MA90* untuk memberikan konteks temporal terhadap konsumsi energi.
- Hash Rate dan Difficulty: Dua fitur teknis ditambahkan untuk merepresentasikan kekuatan komputasi dan tingkat kesulitan jaringan PoW, yang berpengaruh langsung terhadap konsumsi energi.
- Gap TWh: Dihitung sebagai selisih antara *Estimated TWh* dan *Minimum TWh*, digunakan sebagai target prediksi.

c. Normalisasi

Seluruh fitur numerik dinormalisasi menggunakan metode *MinMaxScaler* ke dalam

rentang [0, 1]. Tujuannya adalah untuk menyamakan skala antar fitur dan mencegah dominasi fitur dengan nilai besar terhadap proses pembelajaran model, khususnya pada MLP yang sensitif terhadap skala *input*(Fadel Pradika Rodney dkk., 2022).

3. Pelatihan Model

Tahap pelatihan model merupakan inti dari proses prediksi konsumsi energi pada jaringan *blockchain* berbasis *Proof of Work* (PoW). Dua pendekatan digunakan dalam penelitian ini, yaitu *Regresi Linier* sebagai *baseline* dan *Multilayer Perceptron* (MLP) sebagai model *deep learning* untuk menangkap pola non-linier.

a. Regresi Linier

Regresi Linier digunakan sebagai model dasar (*baseline*) karena sifatnya yang sederhana dan interpretatif. Model ini bertujuan untuk mengidentifikasi hubungan linier antara fitur-fitur teknis seperti *ordinal_time*, *hash_rate*, dan *difficulty_est* terhadap target prediksi *gap_twh*, yaitu selisih antara konsumsi energi estimasi dan minimum(Fadel Pradika Rodney dkk., 2022).

Sebelum pelatihan dimulai, seluruh fitur *input* dinormalisasi menggunakan *StandardScaler* agar memiliki distribusi dengan rata-rata nol dan standar deviasi satu. Normalisasi ini penting untuk menghindari dominasi fitur dengan skala besar terhadap parameter model. Model dibangun menggunakan algoritma *Ordinary Least Squares* (OLS)(Sapra dkk., 2023), yang bekerja dengan meminimalkan jumlah kuadrat dari selisih antara nilai aktual dan nilai prediksi. Proses pelatihan dilakukan pada data *training* yang telah dipisahkan sebelumnya dengan rasio 80:20.


Tabel 1 Split data

Dataset	Jumlah data	Split data	
		Data Training	Data Testing
Konsumsi_energi	3074	2457	615

Setelah model dilatih, dilakukan analisis terhadap nilai *intercept* dan koefisien regresi untuk memahami kontribusi masing-masing fitur terhadap prediksi. Koefisien positif menunjukkan bahwa peningkatan fitur tersebut akan meningkatkan nilai prediksi, sedangkan koefisien negatif menunjukkan hubungan sebaliknya. Visualisasi hasil prediksi terhadap nilai aktual ditampilkan dalam bentuk grafik Prediksi vs Aktual, serta *Residual Plot* untuk mengevaluasi distribusi kesalahan. Hasil menunjukkan bahwa meskipun model mampu menangkap tren dasar, terdapat deviasi yang cukup besar pada nilai ekstrem, menandakan keterbatasan *regresi linier* dalam menangani pola non-linier.

b. Multilayer Perceptron (MLP)

Untuk mengatasi keterbatasan regresi linier, digunakan pendekatan *Multilayer Perceptron* (MLP), yaitu jenis jaringan saraf tiruan yang mampu mempelajari hubungan non-linier antar fitur(Nainwal & Sharma, 2023). Model ini dirancang untuk menangkap kompleksitas data konsumsi energi yang fluktuatif dan dinamis.



Gambar 3. Arsitektur *Multilayer perceptron* (MLP)

Diagram arsitektur model ANN berbasis *Multilayer perceptron* (MLP) yang digunakan dalam penelitian ini (Eligüzel & Aydoğan, 2025). Arsitektur terdiri dari 3 layer utama, adapun arsitektur MLP yang digunakan terdiri dari:

- *Input Layer*: 3 neuron, masing-masing mewakili fitur *ordinal_time*, *hash_rate*, dan *difficulty_est*.
- *Hidden Layers*: 4 lapisan tersembunyi dengan konfigurasi 256, 128, 64, dan 32 neuron. Fungsi aktivasi yang digunakan adalah *ReLU* karena efisien dalam menangani *non-linearitas* dan menghindari masalah *vanishing gradient*.
- *Output Layer*: 1 neuron dengan aktivasi linier untuk menghasilkan nilai prediksi kontinu.

Sebelum pelatihan, seluruh fitur *input* dinormalisasi menggunakan *MinMaxScaler* ke dalam rentang $[0, 1]$. Hal ini bertujuan untuk menjaga stabilitas pembelajaran dan mempercepat konvergensi. Model dilatih menggunakan *Adam Optimizer* dengan *learning rate* awal sebesar 0.0005, selama 200 *epoch* dan batch size 32. Proses pelatihan dilakukan secara iteratif, di mana bobot dan bias diperbarui berdasarkan nilai *loss* yang dihitung menggunakan *Mean Squared Error* (MSE).

Selama pelatihan, dilakukan monitoring terhadap *training loss* dan *validation loss* untuk menghindari *overfitting*. Strategi *early stopping* diterapkan untuk menghentikan pelatihan jika tidak ada peningkatan signifikan pada *validation loss* selama beberapa *epoch* berturut-turut. Setelah pelatihan selesai, dilakukan analisis terhadap *Residual Plot* dan Distribusi Residu untuk mengevaluasi stabilitas dan akurasi model. Hasil menunjukkan bahwa MLP mampu menangkap pola konsumsi energi dengan lebih baik, bahkan pada titik-titik ekstrem yang gagal ditangani oleh regresi linier.

4. Perbandingan dan Evaluasi

Evaluasi dilakukan untuk mengukur seberapa akurat model dalam memprediksi nilai konsumsi energi (*gap_twh*) berdasarkan data uji. Tiga metrik statistik digunakan dalam penelitian ini, yaitu *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), dan *Koefisien Determinasi* (R^2). Metrik ini memberikan gambaran kuantitatif terhadap performa model, baik dari sisi kesalahan prediksi maupun kemampuan menjelaskan variansi data.

a. *Mean Absolute Error* (MAE)

Digunakan untuk mengukur rata-rata dari kesalahan absolut antara nilai prediksi dan nilai aktual. Metrik ini mudah karena memiliki satuan yang sama dengan variabel

target(Kaur dkk., 2024).

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

- n : Jumlah total data atau observasi dalam dataset
- y : Nilai aktual atau nilai sebenarnya dari data ke- i
- \hat{y}_i : Nilai prediksi yang dihasilkan oleh model untuk data ke- i
- i : Simbol untuk nilai absolut, dimana nilai didalamnya baik berupa negatif maupun positif tetap akan di ubah ke nilai positif.

b. *Mean Squared Error* (MSE)

Menghitung rata-rata dari kuadrat selisih antara nilai prediksi dan aktual. Dengan mengkuadratkan selisihnya, MSE memberikan pinalti yang lebih besar pada kesalahan yang besar, sehingga sangat sensitif terhadap *outlier*.

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

- n : Jumlah total data atau observasi dalam dataset
- y : Nilai aktual atau nilai sebenarnya dari data ke- i
- \hat{y}_i : Nilai prediksi yang dihasilkan oleh model untuk data ke- i
- i : Simbol untuk nilai absolut, dimana nilai didalamnya baik berupa negatif maupun positif tetap akan di ubah ke nilai positif.

c. *R-Squared* (R^2)

R-squared mengukur seberapa baik variabel independen dapat menjelaskan variabilitas dari variabel dependen. Nilainya berkisar antara 0 hingga 1, di mana nilai yang mendekati 1 menunjukkan bahwa model mampu menjelaskan sebagian besar variabilitas data dengan baik.

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

- R^2 : Hasil akhir dari metrik Koefisien Determinasi, yang mengukur seberapa baik model menjelaskan variasi data.
- n : Jumlah total data atau observasi.
- y_i : Nilai aktual atau nilai sebenarnya dari data ke- i
- \hat{y}_i : Nilai prediksi yang dihasilkan oleh model untuk data ke- i
- \bar{y} : Nilai rata-rata dari seluruh nilai aktual (y)

d. Perbandingan


Tabel 2 Hasil perbandingan evaluasi

del	E ↓	E ↓	↑
regresi Linier	3331	7.5541	914
ltilayer Perceptron	620	9281	390

Multilayer Perceptron (MLP) menunjukkan performa yang jauh lebih unggul dibanding Regresi Linier dalam semua metrik evaluasi. Hal ini mengonfirmasi bahwa pendekatan *deep learning* lebih efektif dalam menangkap pola konsumsi energi *blockchain* yang bersifat dinamis dan non-linier(Arfa dkk., 2023).

5. Perancangan User Interface

Pada tahap ini peneliti akan menentukan alur kerja sistem berupa *flowchart* yang akan memberikan gambaran dari alur sistemnya. Dimana model yang dipilih nantinya akan melakukan prediksi konsumsi energi pada jaringan *bitcoin*. Alur kerja dirancang secara sederhana namun efektif, sehingga proses dapat dipahami dan dijalankan secara berurutan. Tahapan dimulai dari pemuatan data historis yang telah dipersiapkan, kemudian dilanjutkan pada proses prediksi gabungan menggunakan model *time series Prophet* dan model. Hasil prediksi ditampilkan dalam bentuk visualisasi grafik dan metrik, sehingga memudahkan interpretasi terhadap tren konsumsi energi yang diproyeksikan.



Gambar 4 *Flowchart* perancangan system

Berdasarkan gambar *flowchart* di atas, proses perancangan sistem berjalan secara linear dari tahap awal hingga akhir. Setelah data berhasil dimuat, sistem langsung melakukan proses prediksi gabungan yang mengombinasikan tren jangka panjang dan variasi selisih energi. Tahap akhir menampilkan hasil prediksi secara interaktif, yang dapat digunakan sebagai dasar pengambilan keputusan maupun kajian lanjutan terkait efisiensi energi pada mekanisme *Proof of Work (PoW)*. Alur yang sederhana ini diharapkan dapat meminimalkan kompleksitas proses dan memaksimalkan kecepatan analisis.

HASIL DAN PEMBAHASAN

1. Pengumpulan data

Tahap pengumpulan data pada penelitian ini dilakukan dengan memanfaatkan sumber data yang relevan dan dapat dipercaya, yaitu *Digiconomist*, sebuah platform yang menyediakan estimasi konsumsi energi jaringan *blockchain* secara berkala.

Tabel 3 *Dataset* konsumsi energi

DateTime	Estimated TWh per Year	Minimum TWh per Year
02/10/2017 00:00	9.585659451	3.331026429
02/11/2017 00:00	9.547335368	3.316227361
02/12/2017 00:00	9.578774259	3.198969144
02/13/2017 00:00	9.476506126	3.045178216
02/14/2017 00:00	9.544807316	3.15006245
02/15/2017 00:00	9.569005513	3.337439903
02/16/2017 00:00	9.392170135	3.330369055
02/17/2017 00:00	9.323758505	3.238448041

Dataset yang digunakan secara khusus berfokus pada jaringan Bitcoin dan terdiri dari tiga kolom utama, yaitu Estimated TWh per Year, DateTime, dan Minimum TWh per Year. Data ini diperoleh dalam format CSV dan memiliki rentang waktu historis yang cukup panjang, sehingga dapat digunakan untuk menganalisis tren konsumsi energi *Bitcoin* dari waktu ke waktu. Proses pengumpulan data dilakukan melalui dua metode. Pertama, data historis diunduh secara langsung dari hasil pemrosesan sebelumnya yang telah disimpan dalam file CSV bernama hasil_filter.csv. Kedua, untuk keperluan pembaruan data, penelitian ini juga memanfaatkan API *Digiconomist* guna mengambil data real-time konsumsi energi harian *Bitcoin*. Hasil dari kedua sumber data ini kemudian digabungkan dan disimpan untuk digunakan pada tahap *preprocessing*.

Pemilihan *dataset* ini didasarkan pada beberapa pertimbangan. *Digiconomist* merupakan salah satu sumber data yang kredibel dalam mempublikasikan estimasi konsumsi energi *blockchain* dengan metodologi yang jelas dan teruji. Selain itu, *dataset* ini memiliki format terstruktur dan memuat informasi yang relevan bagi analisis efisiensi algoritma konsensus *Proof of Work* (PoW), termasuk estimasi konsumsi energi minimum serta estimasi konsumsi aktual yang dapat digunakan untuk menghitung selisih konsumsi energi (*gap*). Dengan karakteristik tersebut, *dataset* ini sangat sesuai digunakan untuk membangun model prediksi dan analisis tren konsumsi energi berbasis *machine learning* dan *time series*.

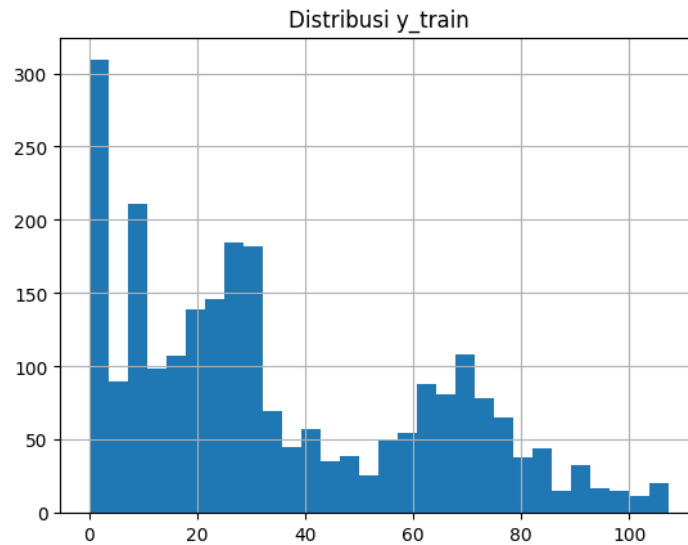
2. Pelatihan Model Regresi Linier dan Multilayer Perceptron (MLP)

Pada tahap ini, dilakukan implementasi dua pendekatan pemodelan untuk memprediksi variabel target berupa selisih konsumsi energi tahunan (*gap_twh*) pada jaringan *blockchain*. Model pertama yang digunakan adalah Regresi Linier, yang berfungsi sebagai *baseline* untuk mengukur hubungan linier antara fitur *input* dan target. Model kedua adalah *Multilayer Perceptron* (MLP), yang dirancang untuk menangkap pola non-linier yang lebih kompleks dalam data, sehingga dapat memberikan prediksi yang lebih akurat dan adaptif terhadap dinamika konsumsi energi.

a. Pembangunan dan Pelatihan Model Regresi Linier

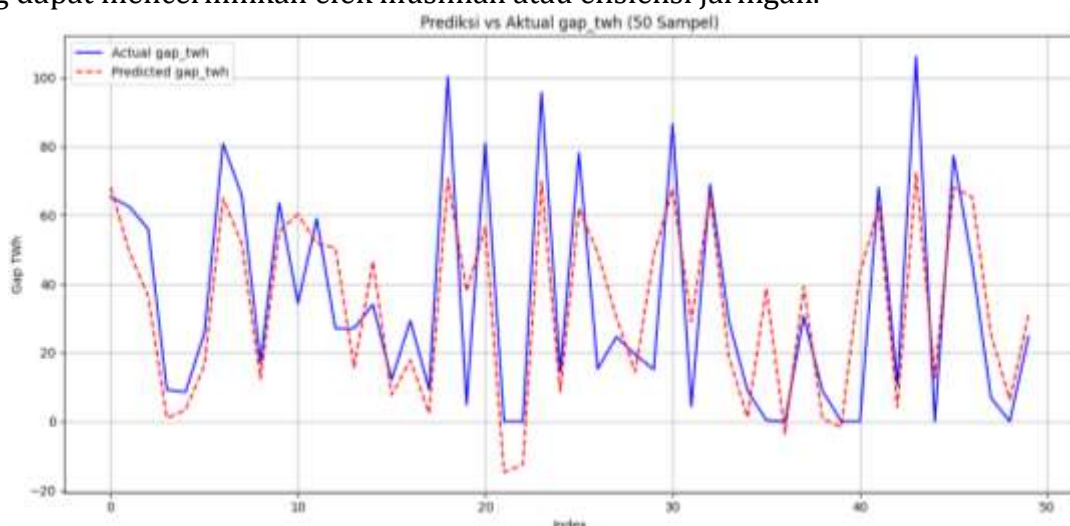
Model regresi linier dibangun menggunakan pustaka *scikit-learn* dengan memanfaatkan kelas *LinearRegression*. Sebelum pelatihan dilakukan, seluruh fitur input distandarisasi menggunakan *StandardScaler* agar memiliki skala yang seragam, yaitu distribusi dengan rata-rata nol dan standar deviasi satu. Proses pelatihan dilakukan menggunakan algoritma *Ordinary Least Squares* (OLS), yang bertujuan untuk meminimalkan jumlah kuadrat dari selisih antara nilai aktual dan nilai prediksi. Target prediksi pada model ini adalah *gap_twh*, yaitu selisih antara *Estimated TWh per Year* dan *Minimum TWh per Year*.

Sebelum pelatihan model dilakukan, ditampilkan terlebih dahulu visualisasi distribusi dari data pelatihan (y_{train}) untuk memahami karakteristik awal target.



Gambar 5 Distribusi y_{train}

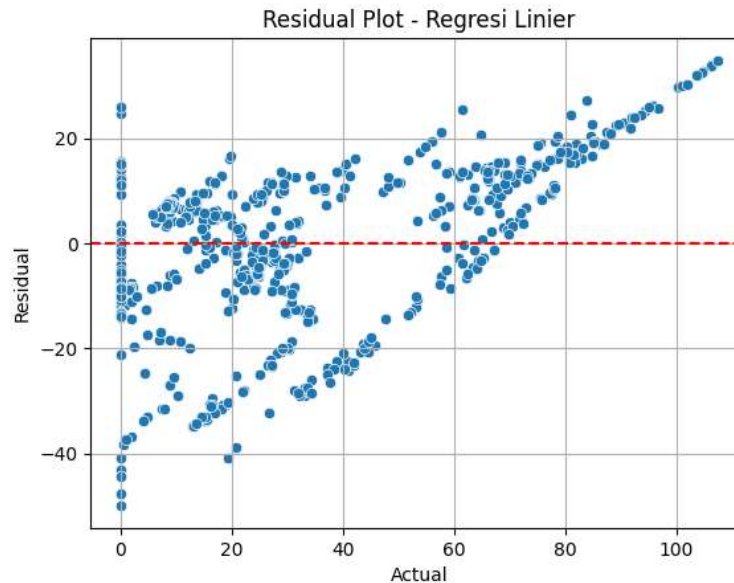
Gambar ini menunjukkan bahwa distribusi gap_{twh} cukup bervariasi dan tidak sepenuhnya mengikuti distribusi normal, dengan konsentrasi data pada rentang 0–40 TWh dan beberapa outlier pada nilai tinggi. Hal ini penting untuk diperhatikan karena regresi linier cenderung bekerja lebih optimal pada data yang mendekati distribusi normal. Setelah pelatihan, nilai intercept dan koefisien regresi yang diperoleh. Model menghasilkan intercept sebesar 1.8274, dengan koefisien -134.187812 untuk *ordinal_time*, serta 94.136008 untuk *hash_rate* dan *difficulty_est*. Koefisien positif pada *hash_rate* dan *difficulty_est* menunjukkan bahwa peningkatan nilai pada fitur tersebut cenderung meningkatkan nilai prediksi gap_{twh} . Sebaliknya, koefisien negatif pada *ordinal_time* mengindikasikan adanya tren penurunan konsumsi energi seiring waktu, yang dapat mencerminkan efek musiman atau efisiensi jaringan.



Gambar 6 visualisasi Prediksi vs Aktual

Gambar 6 memperlihatkan visualisasi Prediksi vs Aktual untuk 50 sampel acak dari data uji. Secara umum, model mampu mengikuti pola fluktuasi nilai aktual dengan cukup baik, meskipun terdapat beberapa deviasi signifikan pada nilai ekstrem. Hal ini

menunjukkan bahwa regresi linier memiliki keterbatasan dalam menangani variasi data yang tidak linier atau mengandung *outlier*.



Gambar 7 Residu plot

Gambar 7 menampilkan residu plot, yaitu selisih antara nilai aktual dan prediksi terhadap nilai aktual itu sendiri. Residu tersebar relatif merata di sekitar garis nol, namun terdapat pola *cluster* negatif pada nilai rendah. Ini mengindikasikan adanya *error* sistematis yang belum sepenuhnya ditangani oleh model linier. Oleh karena itu, pendekatan non-linier seperti MLP dipertimbangkan untuk meningkatkan akurasi dan fleksibilitas prediksi.

b. Pembangunan dan Pelatihan Model *Multilayer Perceptron* (MLP)

Untuk mengatasi keterbatasan regresi linier dalam menangkap pola non-linier, digunakan pendekatan *Multilayer Perceptron* (MLP). MLP merupakan jenis jaringan saraf tiruan yang mampu mempelajari hubungan kompleks antar fitur melalui proses pembelajaran berlapis. Model ini dirancang menggunakan *library* Keras dari *TensorFlow*, dengan arsitektur yang disesuaikan untuk tugas regresi. Struktur arsitektur MLP yang digunakan terdiri dari enam lapisan utama. Lapisan pertama adalah *Input Layer* dengan tiga neuron yang masing-masing merepresentasikan fitur *ordinal_time*, *hash_rate*, dan *difficulty_est*. Karena lapisan ini hanya berfungsi sebagai penerima data, tidak digunakan fungsi aktivasi.


Selanjutnya, terdapat empat *Hidden Layer* bertingkat dengan jumlah neuron 256, 128, 64, dan 32, masing-masing menggunakan fungsi aktivasi *ReLU*. Lapisan-lapisan ini berfungsi untuk menangkap dan memperdalam representasi non-linier dari fitur *input*, serta menyaring informasi yang relevan sebelum proses prediksi. Terakhir, *Output Layer* menggunakan satu neuron dengan *aktivasi* linear, yang sesuai untuk menghasilkan *output* berupa nilai kontinu *gap_twh*.

Struktur ini dirancang untuk menggabungkan kapasitas representasi yang dalam dengan efisiensi komputasi, sehingga model dapat memberikan prediksi yang lebih akurat dan responsif terhadap dinamika konsumsi energi *blockchain*. Dengan pendekatan ini, diharapkan MLP mampu mengatasi keterbatasan regresi linier dan memberikan hasil prediksi yang lebih stabil, terutama pada kondisi data yang kompleks dan tidak linier.

Tabel 5 Hiperparameter

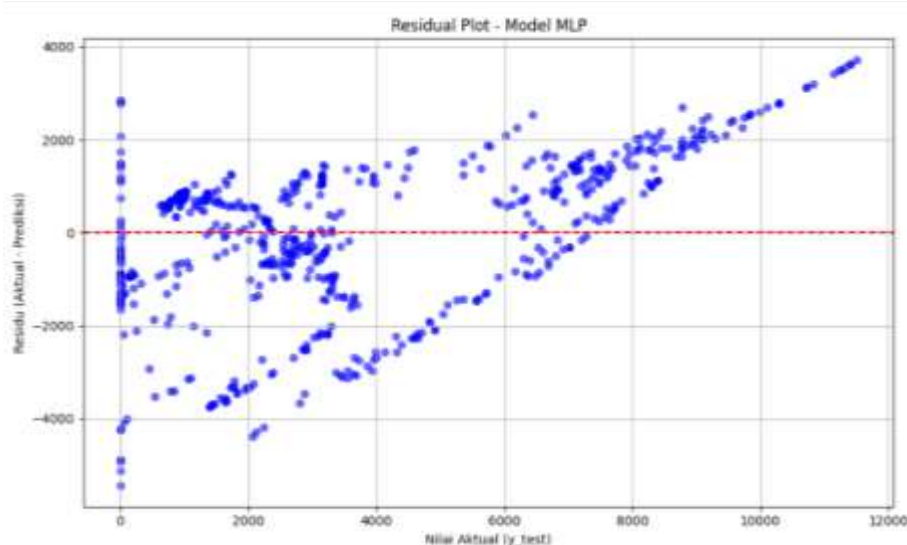
Parameter	Opsi Diuji	Konfigurasi
Hidden layer sizes	(50), (100),	(100, 50)
Activation	Relu, Tanh	Relu
Solver	Adam, Sgd	Adam
Alpa	0.0001, 0.001, 0.01	0,0005

Seluruh fitur input dinormalisasi menggunakan MinMaxScaler ke dalam rentang [0,1] sebelum dimasukkan ke dalam model. Normalisasi ini dilakukan untuk menjaga kestabilan pelatihan, mempercepat konvergensi, dan mencegah dominasi fitur berskala besar terhadap bobot model(Reyad dkk., 2023).



Gambar 8 Grafik training loss

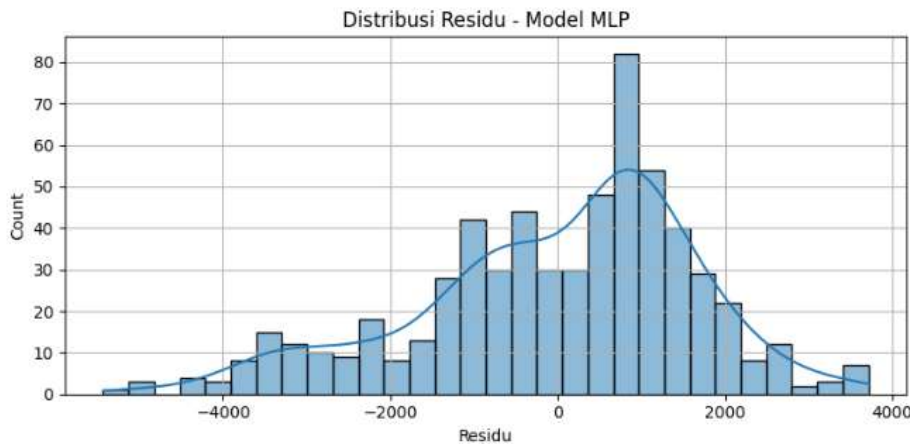
Gambar 8 menunjukkan grafik training loss dan validation loss selama pelatihan MLP. Kedua kurva menurun tajam di awal, lalu melandai dan stabil setelah beberapa epoch. Jarak antar kurva relatif kecil, menandakan model memiliki generalisasi yang baik dan tidak mengalami overfitting. Strategi early stopping berhasil menjaga efisiensi pelatihan.



Gambar 9 residual plot

Gambar 9 menampilkan residual plot, yang menunjukkan bahwa sebagian besar kesalahan prediksi berada di sekitar garis nol. Model tidak menunjukkan bias

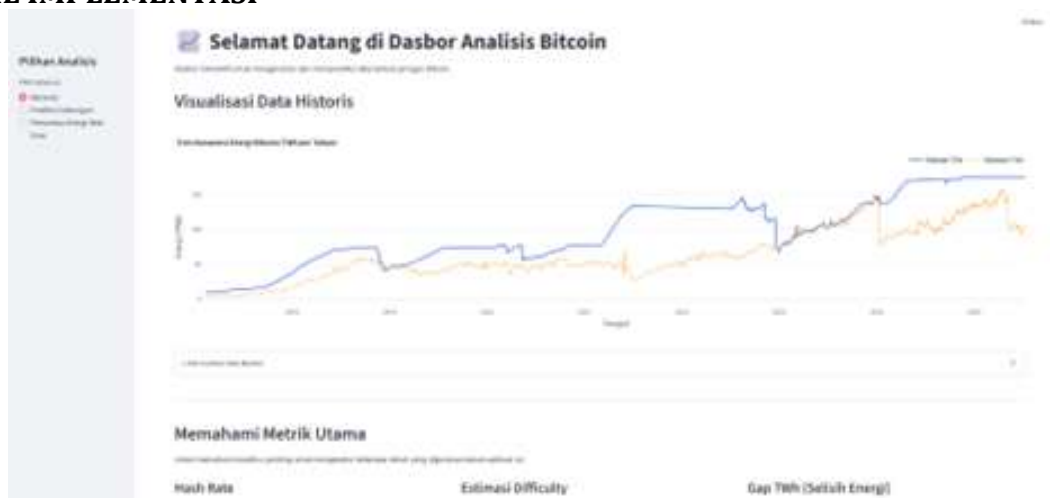
sistematis, namun terdapat penyebaran residu yang lebih besar pada nilai gap_twh tinggi. Hal ini mengindikasikan bahwa prediksi cenderung kurang stabil pada data ekstrem.



Gambar 10 memperlihatkan distribusi residu

Gambar 10 memperlihatkan distribusi residu dalam bentuk histogram. Sebagian besar residu berada di rentang -2000 hingga 2000 dengan puncak di sekitar nol, menunjukkan akurasi yang baik secara umum. Distribusi simetris dengan ekor panjang di kedua sisi mengindikasikan adanya beberapa outlier, namun tidak menunjukkan kecenderungan kesalahan ke arah tertentu.

HASIL IMPLEMENTASI



Gambar 1 Implementasi sistem prediksi

Gambar 11 menampilkan hasil implementasi sistem prediksi konsumsi energi blockchain berbasis model *Multilayer Perceptron* (MLP) dan Regresi Linier yang telah diintegrasikan ke dalam aplikasi web interaktif menggunakan Streamlit. Sistem ini dirancang untuk memudahkan pengguna dalam melakukan analisis dan prediksi konsumsi energi Bitcoin secara historis dan real-time.

Antarmuka aplikasi terdiri dari dua panel: navigasi di sisi kiri untuk memilih jenis analisis, dan panel utama di kanan yang menampilkan grafik *Tren Konsumsi Energi Bitcoin (TWh per Tahun)*. Grafik ini menyajikan kurva estimasi dan minimum konsumsi energi dari tahun 2016 hingga 2025, memberikan gambaran pola jangka panjang.

Di bawah grafik, tersedia penjelasan metrik utama seperti *hash rate*, *difficulty*, dan *gap TWh*, yang membantu pengguna memahami fitur-fitur teknis dalam proses

prediksi. Aplikasi juga memungkinkan input data, pemilihan model, dan penyajian hasil prediksi dalam berbagai satuan energi, lengkap dengan visualisasi interaktif seperti grafik Prediksi vs Aktual dan Residual Plot.

Secara keseluruhan, sistem ini menunjukkan bahwa model yang dikembangkan tidak hanya akurat, tetapi juga praktis dan mudah diakses oleh pengguna non-teknis. Integrasi antara machine learning dan visualisasi dinamis menjadikan aplikasi ini sebagai alat analisis yang efektif dan siap digunakan untuk pengambilan keputusan berbasis data.

KESIMPULAN

Penelitian ini berhasil merancang sistem prediksi konsumsi energi *blockchain* berbasis algoritma *Proof of Work* (PoW) menggunakan pendekatan *machine learning* dan *deep learning*. Setelah melalui tahap pengumpulan dan preprocessing data historis, dua model diterapkan: Regresi Linier sebagai baseline dan *Multilayer Perceptron* (MLP) sebagai model utama.

Hasil evaluasi menunjukkan bahwa MLP unggul secara signifikan dalam akurasi dan kemampuan menjelaskan variansi data, dengan MAE sebesar 3.8406 dan R^2 mencapai 0.9390. Ini membuktikan efektivitas pendekatan *deep learning* dalam menangani pola konsumsi energi yang kompleks dan fluktuatif.

Dengan arsitektur sistem yang modular dan alur kerja yang terstruktur, model ini tidak hanya akurat tetapi juga siap untuk direplikasi dan dikembangkan lebih lanjut. Ke depan, sistem berpotensi diintegrasikan ke dalam platform analisis energi digital dan mendukung pengambilan keputusan dalam konteks keberlanjutan teknologi *blockchain*.

DAFTAR PUSTAKA

- Afriani, F., Akbar, N. I., Khalifatun, S., Latifah, N., Mutiara, D., Informatika, J., Teknik, F., Semarang, U. P., Lantai, G. B., Jl, K., & Timur, S. (2024). *ANALISIS SISTEMATIK ALGORITMA KONSENSUS PADA BLOCKCHAIN pendekatan yang merujuk pada metodologi riset yang dirancang untuk mengidentifikasi*. 9(Sens 9), 519–527.
- Arfa, M. F., Alfathan, M. R., Lumbantobing, H. B., & Rahmadenni, R. (2023). Prediksi Harga Cryptocurrency Dengan Metode Linier Regresi. *SENTIMAS: Seminar Nasional Penelitian dan Pengabdian Masyarakat*, 1(1), 8–15. <https://journal.irpi.or.id/index.php/sentimas/article/view/609%0Ahttps://journal.irpi.or.id/index.php/sentimas/article/download/609/332>
- de Vries, A. (2018). Bitcoin's Growing Energy Problem. *Joule*, 2(5), 801–805. <https://doi.org/10.1016/j.joule.2018.04.016>
- Eligüzel, N., & Aydoğan, S. (2025). Predicting Bitcoin Mining Energy Consumption Using Machine Learning: A Case for k-Nearest Neighbors Regression. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 14(1), 561–582. <https://doi.org/10.17798/bitlisfen.1610560>
- Fadel Pradika Rodney, M., Rizal Sultan, A., & Usman. (2022). Peramalan Beban Listrik Menggunakan Kombinasi Metode Jaringan Saraf Tiruan Dan Regresi Linier Di ULP Sungguminasa. *Sntei*, 2, 441–445.
- Gulo, S. H., & Lubis, A. H. (2024). Penerapan Multi-Layer Perceptron untuk Mengklasifikasi Penduduk Kurang Mampu. *Explorer*, 4(2), 51–59.
- Kaur, H., Rani, V., Kumar, M., Sachdeva, M., Mittal, A., & Kumar, K. (2024). Federated learning: a comprehensive review of recent advances and applications. *Multimedia Tools and Applications*, 83(18), 54165–54188. <https://doi.org/10.1007/s11042-023-17737-0>
- Laimon, M., Almadadha, R., & Goh, S. (2025). Energy Consumption of Crypto Mining: Consequences and Sustainable Solutions Using Systems Thinking and System Dynamics Analysis. *Sustainability (Switzerland)*, 17(8). <https://doi.org/10.3390/su17083522>

- Lee, S., & Kim, S. (2020). Proof-of-stake at stake: Predatory, destructive attack on PoS cryptocurrencies. *CRYBLOCK 2020 - Proceedings of the 3rd Workshop on Cryptocurrencies and Blockchains for Distributed Systems, Part of MobiCom 2020*, 7–11. <https://doi.org/10.1145/3410699.3413791>
- Maarif, M. R., Saleh, A. R., Habibi, M., Fitriyani, N. L., & Syafrudin, M. (2023). Energy Usage Forecasting Model Based on Long Short-Term Memory (LSTM) and eXplainable Artificial Intelligence (XAI). *Information (Switzerland)*, 14(5). <https://doi.org/10.3390/info14050265>
- Nainwal, R., & Sharma, A. (2023). Development of an energy prediction model for residential buildings using Artificial Neural Network. *IOP Conference Series: Earth and Environmental Science*, 1279(1). <https://doi.org/10.1088/1755-1315/1279/1/012006>
- Pawar, M. K., Patil, P., Narayan, D. G., Pandey, V., Jain, S., & Kumar, P. (2025). Efficient Miner Selection in Blockchain Based on Predicted Transaction Time. *Procedia Computer Science*, 252, 202–211. <https://doi.org/10.1016/j.procs.2024.12.022>
- Poongodi, M., Sharma, A., Vijayakumar, V., Bhardwaj, V., Sharma, A. P., Iqbal, R., & Kumar, R. (2020). Prediction of the price of Ethereum blockchain cryptocurrency in an industrial finance system. *Computers and Electrical Engineering*, 81, 106527. <https://doi.org/10.1016/j.compeleceng.2019.106527>
- Reyad, M., Sarhan, A. M., & Arafa, M. (2023). A modified Adam algorithm for deep neural network optimization. *Neural Computing and Applications*, 35(23), 17095–17112. <https://doi.org/10.1007/s00521-023-08568-z>
- Rukhiran, M., Boonsong, S., & Netinant, P. (2024). *Sustainable Optimizing Performance and Energy Efficiency in Proof of Work Blockchain : A Multilinear Regression Approach*.
- Sapra, N., & Shaikh, I. (2023). Impact of Bitcoin mining and crypto market determinants on Bitcoin-based energy consumption. *Managerial Finance*, 49(11), 1828–1846. <https://doi.org/10.1108/MF-03-2023-0179>
- Sapra, N., Shaikh, I., & Dash, A. (2023). Impact of Proof of Work (PoW)-Based Blockchain Applications on the Environment: A Systematic Review and Research Agenda. *Journal of Risk and Financial Management*, 16(4). <https://doi.org/10.3390/jrfm16040218>
- Truby, J., Brown, R. D., Dahdal, A., & Ibrahim, I. (2022). Blockchain, climate damage, and death: Policy interventions to reduce the carbon emissions, mortality, and net-zero implications of non-fungible tokens and Bitcoin. *Energy Research and Social Science*, 88(August 2021), 102499. <https://doi.org/10.1016/j.erss.2022.102499>
- Tsuyuguchi, T., & Wang, H. (2024). Quasi-experimental research and spillover effects on Ethereum Merge. *Applied Economics Letters*, DiD. <https://doi.org/10.1080/13504851.2024.2308587>
- Xiong, H., Chen, M., Wu, C., Zhao, Y., & Yi, W. (2022). Research on Progress of Blockchain Consensus Algorithm: A Review on Recent Progress of Blockchain Consensus Algorithms. *Future Internet*, 14(2). <https://doi.org/10.3390/fi14020047>