

Prediksi Tren Penggunaan *Electronic Money (E-Money)* di Indonesia menggunakan pendekatan *Extreme Learning Machines*

Devita Rizqi Maulida¹, Umi Mahmudah^{2*}, Dini Aulia Ramadhani³

^{1,2}Program Studi Sains Data, UIN K.H. Abdurrahman Wahid Pekalongan, Indonesia

³Prodi Matematika, Universitas Negeri Semarang, Indonesia

*Corresponding author: umi.mahmudah@uingusdur.ac.id



P-ISSN: 2986-4178
E-ISSN: 2988-4004

Riwayat Artikel

Dikirim: 31 Januari 2025
Direvisi: 08 Agustus 2025
Diterima: 28 Oktober 2025

ABSTRAK

Penelitian ini bertujuan untuk menganalisis kemampuan model *Extreme Learning Machine (ELM)* dalam meramalkan nilai transaksi uang elektronik di Indonesia. Data sekunder berupa nilai transaksi uang elektronik periode 2021 sampai 2024 dari bank Indonesia digunakan. Hasil peramalan menunjukkan tren pertumbuhan yang stabil pada nilai transaksi, dengan proyeksi yang meningkat setiap bulan. Hasil metrik evaluasi menunjukkan bahwa model ELM tidak memiliki bias sistematis (*Mean Error* = 0,000). Nilai *Mean Absolute Percentage Error (MAPE)* sebesar 9,533% menunjukkan bahwa kesalahan prediksi masih dalam batas toleransi yang dapat diterima. Secara keseluruhan, model ELM memberikan hasil yang cukup menjanjikan untuk meramalkan transaksi *e-money* di Indonesia. Hasil prediksi menunjukkan bahwa model ELM dapat memberikan proyeksi yang konsisten dengan tren pertumbuhan yang stabil. Prediksi nilai transaksi yang semakin meningkat setiap bulan mencerminkan potensi pertumbuhan yang terus berlanjut dalam sektor uang elektronik di Indonesia. Penelitian ini memberikan kontribusi dalam meningkatkan pemahaman tentang potensi dan keterbatasan model ELM dalam meramalkan transaksi uang elektronik di Indonesia.

Kata Kunci: *Extreme Learning Machine*, peramalan, uang elektronik, *e-money*

ABSTRACT

This study aims to analyze the ability of the Extreme Learning Machine (ELM) model for forecasting the value of electronic money transactions in Indonesia. Secondary data of electronic money transaction values for the period 2021 to 2024 from Bank Indonesia are used. The forecasting results show a steady growth trend in transaction value, with projections increasing every month. The results of the evaluation metrics show that the ELM model has no systematic bias (Mean Error = 0.000). The Mean Absolute Percentage Error (MAPE) value of 9.533% indicates that the prediction error is still within acceptable tolerance limits. Overall, the ELM model provides promising results for forecasting e-money transactions in Indonesia. The prediction results show that the ELM model can provide consistent projections with a stable growth trend. Predicted transaction values that are increasing every month reflect the potential for continued growth in the electronic money sector in Indonesia. This research contributes to an improved understanding of the potential and limitations of the ELM model in forecasting e-money transactions in Indonesia.

Keywords: *Extreme Learning Machine, forecasting, electronic money, e-money*

1. Pendahuluan

Perkembangan teknologi informasi dan komunikasi telah membawa perubahan signifikan pada sektor keuangan, termasuk dalam cara masyarakat melakukan transaksi. Salah satu inovasi yang terus berkembang adalah penggunaan *electronic money (e-money)*, yang menawarkan kemudahan, kecepatan, dan keamanan dalam bertransaksi tanpa memerlukan uang tunai. Di Indonesia, tren penggunaan *e-money* terus meningkat seiring dengan pertumbuhan ekonomi digital dan perluasan ekosistem pembayaran elektronik. Data Bank Indonesia menunjukkan lonjakan transaksi *e-money* dalam lima tahun terakhir, mencerminkan pergeseran dari tunai ke elektronik yang didorong oleh luasnya platform digital [1].

Menurut Bank Indonesia, transaksi *e-money* di Indonesia tumbuh pesat. Desember 2022 mencatat 142,967 miliar rupiah, dengan peningkatan sepanjang 2023 hingga mencapai 184,629 triliun rupiah pada Desember. Data ini mencerminkan pergeseran masyarakat ke pembayaran non-tunai dan potensi besar pertumbuhan *e-money* [2]. Namun, pertumbuhan *e-money* di Indonesia menghadapi tantangan dalam memprediksi tren, dipengaruhi oleh kebijakan, penetrasi internet, literasi digital, dan infrastruktur pembayaran. Ketidakakuratan prediksi dapat menghambat perencanaan strategis. Diperlukan model prediktif yang mampu menangkap pola data kompleks dan non-linear, seperti penggunaan *artificial neural networks (ANN)* dengan arsitektur Extreme Learning Machines (ELM) untuk prediksi yang lebih akurat.

ELM adalah algoritma pembelajaran mesin yang beroperasi pada jaringan saraf *feed-forward (SLFN)* lapisan tersembunyi tunggal. Tidak seperti metode tradisional, ELM menetapkan bobot acak pada lapisan tersembunyi dan menghitung bobot keluaran secara analitis, sehingga menghasilkan waktu pelatihan yang cepat dan mengurangi kompleksitas komputasi.

Dari fakta literatur yang ada saat ini, ditemukan kurangnya pemanfaatan model jaringan saraf dalam analisis peramalan [3]–[9]. Meskipun ada kemajuan dalam teknik pembelajaran mesin dan kecerdasan buatan, termasuk jaringan saraf, penerapannya dalam peramalan transaksi uang elektronik masih relatif terbatas. Tren penelitian yang terkait dengan peramalan penggunaan uang elektronik mencakup berbagai metodologi. Sebuah studi menggunakan model ARIMAX-GARCH untuk meramalkan volume transaksi uang elektronik [10]. Selain itu, sebuah studi melakukan penelitian peramalan difusi empat metode pembayaran elektronik utama [11]. Penelitian lain meramalkan adopsi implementasi pembayaran seluler menggunakan SEM-PLS [12]. Meskipun metode-metode tersebut telah menunjukkan kemandirian dalam konteks tertentu, namun mungkin tidak sepenuhnya menangkap sifat non-linier dan dinamis dari transaksi e-money. Akibatnya, ada kesenjangan penting dalam literatur mengenai eksplorasi dan adopsi model jaringan saraf untuk peramalan uang elektronik, meskipun potensinya untuk menawarkan prediksi dan wawasan yang lebih akurat ke dalam pola transaksi yang kompleks.


Dari penelitian sebelumnya, berbagai pendekatan statistik dan *machine learning* telah digunakan untuk memprediksi tren keuangan, termasuk penggunaan regresi linier, model ARIMA, dan *decision trees* [13]–[15]. Namun, pendekatan ini memiliki keterbatasan dalam menangani data dengan pola yang dinamis dan sangat kompleks. Oleh karena itu, ELM dapat dijadikan sebagai metode alternatif yang efektif untuk mengatasi keterbatasan ini.

Tujuan dari penelitian ini adalah untuk mengatasi kesenjangan yang ada dalam literatur mengenai pemanfaatan model jaringan saraf dalam meramalkan tren uang elektronik. Meskipun teknik *machine learning*, termasuk jaringan saraf, berkembang pesat, namun penelitian tentang penggunaan ELM untuk memprediksi tren e-money di Indonesia masih sangat terbatas, bahkan belum dapat dideteksi. Dimana pendekatan sebelumnya didominasi metode statistik tradisional yang kurang mampu menangkap pola non-linear. Penelitian ini menghadirkan kebaruan melalui penerapan ELM untuk membangun model prediksi tren *e-money*, menangani data kompleks dan non-linear dengan akurasi tinggi. Maka, penelitian ini memiliki nilai kebaruan dan kontribusi tinggi. Secara teoritis, penelitian ini memperkaya literatur tentang *neural networks* di tren keuangan. Secara praktis, hasil penelitian dapat dimanfaatkan pemerintah, lembaga keuangan, serta industri fintech untuk strategi pasar yang lebih efektif.

2. Metodologi Penelitian

2.1. Data

Pendekatan penelitian ini bersifat kuantitatif melalui analisis prediktif, karena penelitian ini berfokus pada pengembangan model prediktif untuk meramalkan tren penggunaan E-money di Indonesia menggunakan pendekatan *extreme machine learning* (ELM). Data sekunder terkait transaksi penggunaan *e-money* di Indonesia yang diperoleh dari website resmi Bank Indonesia pada periode 2021 hingga 2024. Data yang digunakan mencakup transaksi menggunakan berbagai platform E-money yang telah terdaftar dan terintegrasi dalam sistem pembayaran digital Indonesia, seperti GoPay, OVO, DANA, dan lain-lain. Gambar 1 menunjukkan nilai transaksi uang elektronik bulanan di Indonesia dari Januari 2021 hingga Januari 2024, yang menyoroti tren dan fluktuasi utama.



Gambar 1. Plot nilai transaksi e-money (dalam milyar rupiah)

Dari gambar 1, nilai transaksi menunjukkan pertumbuhan yang stabil dari Januari 2021 hingga Desember 2022, mencapai puncaknya pada 142.967 miliar rupiah sebelum sedikit menurun. Lonjakan signifikan pada Oktober dan November 2022 menunjukkan faktor musiman atau yang disebabkan oleh peristiwa. Pertumbuhan berlanjut pada tahun 2023, mencapai 184.629 miliar rupiah hingga Desember.

2.2. Extreme Learning Machines

Extreme Learning Machines (ELM) adalah sebuah konsep dalam pembelajaran mesin yang melibatkan penggunaan jaringan saraf tiruan dengan satu lapisan tersembunyi (*hidden layer*), di mana bobot ditetapkan secara acak dan langsung selama fase pembelajaran awal [4], [5]. Konsep ini dikembangkan sebagai alternatif untuk mengatasi keterbatasan metode pembelajaran konvensional yang memerlukan proses iteratif panjang dalam menentukan bobot. ELM berfungsi sebagai algoritma pelatihan yang dirancang khusus untuk jaringan saraf maju dengan satu lapisan tersembunyi (*Single Hidden Layer Feed-Forward Neural Networks* atau SLFN). Algoritma ini menunjukkan konvergensi yang jauh lebih cepat dibandingkan metode konvensional, sekaligus memberikan hasil kinerja yang menjanjikan [16]. Sampai saat ini, ELM semakin menarik perhatian para peneliti karena menawarkan solusi terhadap berbagai tantangan yang dihadapi oleh teknik alternatif lainnya [17].

Formulasi matematis ELM dapat dituliskan sebagai berikut. Misalkan terdapat himpunan data pelatihan $\{(x_i, t_i)\}_{i=1}^N$, dimana x_i vector input dengan panjang L dan t_i mewakili target yang akan diprediksi. Tujuan utama ELM adalah mempelajari fungsi $f(x)$ yang memetakan input x pada output y , dimana y adalah hasil prediksi yang dihasilkan oleh model yang ditawarkan [17], [18].

Model ELM terdiri dari satu lapisan tersembunyi dengan neuron yang disimbolkan dengan \mathbf{M} . Bobot antara lapisan masukan dan lapisan tersembunyi diberikan secara acak dan langsung. Misalkan bobot dan bias pada hidden layers disimbolkan dengan \mathbf{W} dan \mathbf{b} . Berikut adalah langkah-langkah prediksi menggunakan model ELM:

Step 1: Inisialisasi Bobot dan Bias

Bobot \mathbf{W} dan bias \mathbf{b} antara lapisan masukan dan lapisan tersembunyi diinisialisasi secara acak dengan nilai yang diambil dari distribusi tertentu.

Step 2: Menghitung Keluaran Lapisan Tersembunyi

Keluaran *hidden layer* \mathbf{H} diperoleh dengan mengalikan matriks input \mathbf{X} dengan bobot \mathbf{W} , menambahkan bias \mathbf{b} , lalu menerapkan fungsi aktivasi:

$$\mathbf{H} = g(\mathbf{XW} + \mathbf{b})$$

dimana \mathbf{X} adalah matriks input dengan dimensi $N \times L$, \mathbf{H} adalah matriks output dari *hidden layer* dengan dimensi $N \times M$.

Step 3: Menghitung Bobot Keluaran

Bobot keluaran diperoleh dengan mengambil *pseudo-inverse* dari \mathbf{H} dan mengalikannya dengan target \mathbf{t}

$$\mathbf{W}_{\text{output}} = \mathbf{H}^{\dagger} \mathbf{t}$$

dimana \mathbf{H}^{\dagger} adalah matriks *pseudo-inverse* dari \mathbf{H} .

Step 4: Memprediksi Keluaran Model

Keluaran model \mathbf{y} diperoleh dengan mengalikan keluaran dari *hidden layer* \mathbf{H} dengan bobot output:

$$\mathbf{y} = \mathbf{H} \mathbf{W}_{\text{output}}$$


Dengan metode ini, ELM dapat melakukan pelatihan dengan efisiensi tinggi tanpa memerlukan proses iteratif yang kompleks, menjadikannya alternatif yang menarik dalam berbagai aplikasi *machine learning*.

Dalam rangka mendapatkan hasil prediksi yang efektif serta evaluasi model yang tidak bias, data series nilai transaksi *e-money* di Indonesia dibagi menjadi 80% pada fase pelatihan (*training*) dan 20% pada fase pengujian (*testing*). Fase pelatihan mengoptimalkan parameter model, sementara fase pengujian menilai kinerja pada data yang tidak terlihat. Akurasi hasil peramalan diukur menggunakan nilai metrik seperti *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE), ME (Mean Error), MPE (Mean Percentage Error), dan MASE (Mean Absolute Scaled Error).

3. Hasil dan Pembahasan

3.1. Arsitektur Jaringan ELM

Gambar 2 menunjukkan arsitektur jaringan ELM. Melalui pemodelan yang cermat, konfigurasi model dioptimalkan untuk mencapai kinerja terbaik, sehingga meningkatkan akurasi prediksi dan mengatasi kompleksitas yang melekat dalam data transaksi *e-money*.



Gambar 2. Plot Arsitektur jaringan ELM

Gambar 2 menggambarkan arsitektur jaringan ELM, di mana lapisan tersembunyi menggunakan bobot proyeksi acak, sedangkan lapisan keluaran menerapkan *LASSO* untuk

estimasi bobot. Lapisan tersembunyi terdiri dari 24 *node*, dengan setiap neuron menerima masukan dari lapisan input dan menghasilkan keluaran yang dikirim ke lapisan output. ELM menetapkan bobot acak antara lapisan input dan lapisan tersembunyi, memungkinkan proses pembelajaran yang cepat tanpa memerlukan proses iteratif yang kompleks. Bobot ini tetap tidak berubah selama pelatihan. Lapisan keluaran terdiri dari satu *neuron* yang bertugas memprediksi variabel target.

Hasil model fitting menggunakan 24 node tersembunyi dan 20 kali pengulangan, serta menerapkan *first-order differencing* untuk membuat data menjadi stasioner. Dalam proses prediksi, model ini memanfaatkan lag univariat pada periode 1, 2, dan 10. Nilai prediksi akhir diperoleh dengan mengambil median dari hasil prediksi, sementara bobot keluaran diestimasi menggunakan metode *LASSO* untuk mencegah *overfitting*.

Arsitektur ini dipilih karena ELM memungkinkan pembelajaran yang sangat cepat dengan akurasi yang kompetitif, terutama pada data time series, berkat penetapan bobot acak di lapisan tersembunyi dan estimasi bobot keluaran menggunakan metode *LASSO* yang efektif dalam mengurangi risiko *overfitting*. Lapisan tersembunyi terdiri dari 24 node, dipilih berdasarkan pengujian awal untuk keseimbangan antara kompleksitas model dan performa prediksi. Lapisan keluaran hanya terdiri dari satu neuron untuk memprediksi variabel target, yaitu nilai transaksi e-money.

Model menggunakan lag 1, 2, dan 10 karena ketiga lag tersebut menunjukkan korelasi yang signifikan terhadap data masa kini berdasarkan hasil analisis autokorelasi dan partial autocorrelation function (ACF dan PACF). Lag 1 dan 2 menangkap pola jangka pendek, sedangkan lag 10 mempertimbangkan pola musiman atau siklus mingguan yang muncul pada data transaksi e-money. Nilai prediksi akhir diperoleh dengan mengambil median dari hasil prediksi 20 pengulangan model untuk meningkatkan stabilitas. Proses *first-order differencing* diterapkan terlebih dahulu untuk memastikan data bersifat stasioner sebelum pemodelan. Semua analisis dilakukan menggunakan software RStudio.

3.2. Accuracy Measures

Tabel berikut menyajikan hasil pengujian akurasi model peramalan menggunakan ELM. Metrik akurasi diperoleh berdasarkan data testing dalam rangka mengevaluasi kinerja generalisasi model terhadap data yang tidak digunakan saat pelatihan.

Tabel 1. *Accuracy Measures*

<i>Accuracy measures</i>	ELM
ME	0,000
RMSE	9234
MAE	7237
MPE	-0,396
MAPE	9,533
MASE	0,198

Berdasarkan Tabel 1, metrik evaluasi memberikan wawasan berharga mengenai akurasi prediksi dan kecenderungan model peramalan ELM. Nilai Mean Error (ME) sebesar 0,000 menunjukkan bahwa model tidak memiliki bias sistematis, dengan prediksi yang terdistribusi secara seimbang di sekitar nilai aktual. Dengan kata lain, nilai ME sebesar 0,000 menunjukkan tidak adanya bias sistematis pada model, yang berarti rata-rata kesalahan prediksi mendekati nol — hal ini bisa terjadi jika kesalahan negatif dan positif saling menyeimbangkan. Nilai RMSE sebesar 9234 dan MAE sebesar 7237 menunjukkan adanya deviasi absolut dan kuadrat yang moderat terhadap nilai aktual dalam satuan asli data. MAPE sebesar 9,533% mengindikasikan performa prediksi yang cukup baik secara

relatif. Sementara MASE sebesar 0,198 menandakan bahwa model memiliki kinerja jauh lebih baik dibandingkan model naive ($MASE < 1$).

Selanjutnya, *Root Mean Squared Error (RMSE)* sebesar 9234 mengindikasikan tingkat kesalahan prediksi yang cukup besar dalam satuan asli data. Selain itu, *Mean Absolute Scaled Error (MASE)* sebesar 0,198 menunjukkan bahwa kesalahan absolut model relatif kecil dibandingkan dengan metode peramalan dasar. Sementara *Mean Absolute Percentage Error (MAPE)* sebesar 9,533% mengindikasikan bahwa tingkat kesalahan prediksi model dalam persentase cukup rendah, yang menunjukkan performa yang cukup baik dalam meramalkan data.


3.3. Hasil Prediksi

Nilai perkiraan transaksi uang elektronik di Indonesia untuk 12 bulan ke depan menggunakan model ELM disajikan dalam Tabel 2 berikut.

Table 1. *Point forecasts*

<i>Point forecasts</i>	<i>ELM</i>
Feb-24	182.648
Mar-24	186.727
Apr-24	190.805
May-24	194.884
Jun-24	198.962
Jul-24	203.040
Aug-24	207.119
Sep-24	211.197
Oct-24	215.276
Nov-24	219.354
Dec-24	223.432
Jan-25	227.511

Visualisasi hasil peramalan disajikan dalam Gambar 3 di bawah ini untuk menyampaikan informasi secara cepat mengenai tren, pola, dan fluktuasi dalam data prediksi seiring waktu.



Gambar 3. Plot Arsitektur jaringan ELM

Hasil analisis peramalan menggunakan model ELM pada tabel 2 dan gambar 3 menunjukkan proyeksi yang menggambarkan tren peningkatan nilai transaksi uang elektronik di Indonesia untuk periode Februari 2024 hingga Januari 2025. Pada bulan Februari 2024, nilai transaksi diperkirakan sebesar 182.648, dan angka ini terus meningkat

secara konsisten setiap bulannya. Pada bulan Maret 2024, diperkirakan akan tercatat 186.727, diikuti oleh proyeksi 190.805 pada bulan April 2024. Proyeksi ini menunjukkan pola pertumbuhan yang stabil dengan nilai transaksi yang terus meningkat, mencapai 198.962 pada bulan Juni 2024 dan 203.040 pada bulan Juli 2024. Prediksi ini berlanjut dengan angka yang semakin tinggi, dengan 211.197 pada September 2024, 215.276 pada Oktober 2024, dan 219.354 pada November 2024. Di akhir periode peramalan, pada Desember 2024, nilai transaksi diperkirakan mencapai 223.432, dan pada Januari 2025, proyeksi terakhir menunjukkan angka 227.511. Secara keseluruhan, hasil peramalan ini menggambarkan tren pertumbuhan yang stabil dan meningkat dari bulan ke bulan, yang menunjukkan adanya ekspektasi positif terhadap pertumbuhan transaksi uang elektronik di Indonesia selama periode tersebut.

4. Kesimpulan

Penelitian ini menunjukkan bahwa model *Extreme Learning Machine* (ELM) dapat digunakan untuk meramalkan nilai transaksi uang elektronik di Indonesia dengan hasil yang cukup baik, meskipun masih terdapat ruang untuk perbaikan. Perbaikan dapat diarahkan pada optimalisasi jumlah node tersembunyi, pemilihan fitur lag yang lebih informatif, atau penggunaan model hybrid. Dengan pengembangan lebih lanjut, ELM berpotensi menjadi alat prediksi yang lebih akurat dan andal untuk data time series ekonomi seperti transaksi uang elektronik. Berdasarkan hasil peramalan, model ini menunjukkan tren pertumbuhan yang stabil dan positif sepanjang periode analisis dari Februari 2024 hingga Januari 2025, dengan prediksi yang terus meningkat setiap bulannya. Namun, meskipun model ELM menunjukkan tren yang baik, analisis metrik akurasi mengungkapkan beberapa area yang masih memerlukan perhatian. Nilai Mean Error (ME) sebesar 0,000 menunjukkan bahwa model tidak memiliki bias sistematis, yang berarti prediksi yang dihasilkan tidak cenderung terlalu tinggi atau terlalu rendah secara keseluruhan. Ini merupakan hasil yang positif karena menunjukkan bahwa model dapat memprediksi dengan distribusi yang seimbang. Secara keseluruhan, meskipun model ELM menunjukkan hasil yang cukup baik dalam meramalkan nilai transaksi uang elektronik, hasil ini menunjukkan bahwa masih ada potensi untuk memperbaiki akurasi prediksi di masa depan melalui peningkatan model dan analisis yang lebih mendalam terhadap variabel yang mempengaruhi transaksi tersebut.

Penelitian ini memiliki beberapa keterbatasan. Penelitian ini terbatas pada kerangka waktu dan kumpulan data tertentu, dan hasilnya dapat bervariasi jika diterapkan pada kumpulan data atau periode waktu yang berbeda. Oleh karena itu, penelitian mendatang disarankan untuk memperluas cakupan dengan menyertakan kumpulan data yang lebih luas dan menguji ketahanan temuan dalam berbagai konteks.

5. Daftar Pustaka

- [1] M. E. Hoque, P. Susanto, N. U. Shah, H. Khatimah, and A. Al Mamun, "Does perceived behavioral control mediate customers' innovativeness and continuance intention of e-money? The moderating role of perceived risk and e-security," *Int. J. Emerg. Mark.*, vol. 19, no. 12, pp. 4481–4502, Dec. 2024, doi: 10.1108/IJOEM-06-2022-0914.
- [2] Bank Indonesia, "Statistik Sistem Pembayaran dan Infrastruktur Pasar Keuangan (SPIP) Februari 2024-Payment System and Financial Market Infrastructure Statistics February 2024," 2024. [Online]. Available: <https://www.bi.go.id/id/statistik/ekonomi-keuangan/spip/Pages/SPIP-Februari-2024.aspx>.

- [3] M. R. H. Al-Dahhan, R. R. Al-Dahhan, and A. T. Radeef, "Multi-layer perceptron neural network mobile robot navigator in unknown environment," *Indones. J. Electr. Eng. Comput. Sci.*, 2023, doi: 10.11591/ijeecs.v3i1.i2.pp725-733.
- [4] J. Tang, C. Deng, and G. Bin Huang, "Extreme Learning Machine for Multilayer Perceptron," *IEEE Trans. Neural Networks Learn. Syst.*, 2016, doi: 10.1109/TNNLS.2015.2424995.
- [5] S. Ding, H. Zhao, Y. Zhang, X. Xu, and R. Nie, "Extreme learning machine: algorithm, theory and applications," *Artif. Intell. Rev.*, 2015, doi: 10.1007/s10462-013-9405-z.
- [6] S. Haykin, "Neural networks: a comprehensive foundation by Simon Haykin," *The Knowledge Engineering Review*. 1999.
- [7] J. P. Bharadiya, "Machine learning and AI in business intelligence: Trends and opportunities," *Int. J. Comput.*, vol. 48, no. 1, pp. 123–134, 2023, [Online]. Available: <https://ijcjournal.org/index.php/InternationalJournalOfComputer/article/view/2087>.
- [8] C. Maté and L. Jiménez, "Forecasting exchange rates with the iMLP: New empirical insight on one multi-layer perceptron for interval time series (ITS)," *Eng. Appl. Artif. Intell.*, vol. 104, p. 104358, Sep. 2021, doi: 10.1016/j.engappai.2021.104358.
- [9] F. Z. El hlouli, J. Riffi, M. A. Mahraz, A. El Yahyaouy, and H. Tairi, "Credit Card Fraud Detection Based on Multilayer Perceptron and Extreme Learning Machine Architectures," in *2020 International Conference on Intelligent Systems and Computer Vision (ISCV)*, Jun. 2020, pp. 1–5, doi: 10.1109/ISCV49265.2020.9204185.
- [10] Sediono, C. Andreas, M. F. F. Mardianto, E. Ana, and Suliyanto, "Forecasting the volume of electronic money transactions using ARIMAX-GARCH model and support vector regression," in *AIP Conference Proceedings*, 2023, vol. 2975, no. 1, p. 080013, doi: 10.1063/5.0187234.
- [11] J. J. Aduba and B. Asgari, "Analysing and forecasting the diffusion of electronic payments system in Nigeria," *Technol. Anal. Strateg. Manag.*, vol. 34, no. 10, pp. 1215–1233, Oct. 2022, doi: 10.1080/09537325.2021.1950675.
- [12] W. Rafdinal and W. Senalasari, "Predicting the adoption of mobile payment applications during the COVID-19 pandemic," *Int. J. Bank Mark.*, vol. 39, no. 6, pp. 984–1002, Aug. 2021, doi: 10.1108/IJBM-10-2020-0532.
- [13] S. L. Gbadamosi, N. I. Nwulu, and S. O. Akinola, "Exploring the effectiveness of a multilayer neural network model for gold price prediction," *Prz. Elektrotechniczny*, 2024, doi: 10.15199/48.2024.03.28.
- [14] M. E. Lokanan, "Predicting Money Laundering Using Machine Learning and Artificial Neural Networks Algorithms in Banks," *J. Appl. Secur. Res.*, 2024, doi: 10.1080/19361610.2022.2114744.
- [15] R. Albariqi and E. Winarko, "Prediction of Bitcoin Price Change using Neural Networks," in *2020 International Conference on Smart Technology and Applications (ICoSTA)*, Feb. 2020, pp. 1–4, doi: 10.1109/ICoSTA48221.2020.1570610936.
- [16] J. Wang, S. Lu, S. H. Wang, and Y. D. Zhang, "A review on extreme learning machine," *Multimed. Tools Appl.*, 2022, doi: 10.1007/s11042-021-11007-7.
- [17] G. Huang, G. Bin Huang, S. Song, and K. You, "Trends in extreme learning

- machines: A review,” *Neural Networks*. 2015, doi: 10.1016/j.neunet.2014.10.001.
- [18] G. Bin Huang, Q. Y. Zhu, and C. K. Siew, “Extreme learning machine: Theory and applications,” *Neurocomputing*, 2006, doi: 10.1016/j.neucom.2005.12.126.