

Akurasi Model Hybrid ARIMA-Artificial Neural Network dengan Model Non Hybrid pada Peramalan Peredaran Uang Elektronik di Indonesia

Muktar Redy Susila^{1,*}, Mochamad Jamil¹, Bambang Hadi Santoso¹

¹Program Studi Manajemen, Sekolah Tinggi Ilmu Ekonomi Indonesia (STIESIA) Surabaya, Kota Surabaya 60118, Indonesia

*Corresponding author. Email: muktarredysusila@stiesia.ac.id

ABSTRAK

Tujuan dari penelitian ini yaitu memodelkan uang elektronik di Indonesia menggunakan model hybrid dan membandingkan akurasinya dengan model non-hybrid. Model hybrid yang digunakan yaitu Autoregresif Integrated Moving Average (ARIMA)-Artificial Neural Network. Data yang digunakan yaitu jumlah peredaran uang elektronik periode bulanan Januari 2009 hingga Oktober 2021. Model ARIMA yang terbentuk dari data penelitian yaitu ARIMA (1,1,0) dengan additive outlier dan level shift outlier. Untuk pemodelan Artificial Neural Network dibatasi dengan menggunakan satu hidden layer dengan tiga neuron. Pada proses pemodelan dilakukan sebanyak 20 repetition. Diperoleh nilai repetition terkecil yaitu repetition ke 13 dengan nilai error yaitu 2,569. Pada penelitian ini diperoleh bahwa model hybrid ARIMA-Artificial Neural Network memiliki nilai Root Mean Squared Error (RMSE) in sample maupun out sample lebih kecil dibandingkan model non-hybrid. Berdasarkan hasil penelitian dapat disimpulkan bahwa dengan adanya penggabungan model ARIMA dengan Artificial Neural Network, dapat meningkatkan akurasi hasil fit data maupun hasil ramalan.

Kata Kunci:

Uang Elektronik; ARIMA, Artificial Neural Network; Hybrid

ABSTRACT

The purpose of this study is to model electronic money in Indonesia using a hybrid model and compare its accuracy with the non-hybrid model. The hybrid model used is Autoregressive Integrated Moving Average (ARIMA)-Artificial Neural Network. The data used is the amount of electronic money circulation for the monthly period January 2009 to October 2021. The ARIMA model formed from research data is ARIMA (1,1,0) with additive outliers and level shift outliers. For Artificial Neural Network modeling is limited by using one hidden layer with three neurons. In the modeling process, 20 repetitions were carried out. The smallest repetition value was obtained, namely the 13th repetition with an error value of 2.569. In this study, it was found that the ARIMA- Artificial Neural Network hybrid model had a smaller Root Mean Squared Error (RMSE) in sample and out sample than the non-hybrid model. Based on the results of the study, it can be concluded that by combining the ARIMA model with Artificial Neural Network, it can increase the accuracy of the data fit results and forecast results.

Keywords:

Electronic Money; ARIMA; Artificial Neural Network; Hybrid

Format Sitasi:

M. R. Susila, M. Jamil, and B. H. Santoso, "Akurasi Model Hybrid ARIMA-Artificial Neural Network dengan Model Non Hybrid pada Peramalan Peredaran Uang Elektronik di Indonesia", *Jambura J. Math.*, vol. 5, No. 1, pp. 46-58, 2023, doi: <https://doi.org/10.34312/jjom.v5i1.14889>

1. Pendahuluan

Kemajuan teknologi pada kurun waktu saat ini menunjukkan perkembangan yang pesat. Perkembangan teknologi tersebut memunculkan sistem pembayaran yang baru. Dahulu manusia melakukan suatu transaksi dengan sistem *barter*. Seiringnya perkembangan zaman, maka munculah uang yang digunakan sebagai alat pembayaran. Menurut Anam [1] berdasarkan bahannya, terdapat dua jenis uang yaitu uang kertas dan uang logam. Akan tetapi uang kertas dan logam tersebut kurang fleksibel. Untuk mengatasinya, maka munculah uang elektronik yang lebih fleksibel. Uang elektronik merupakan kartu berisikan saldo uang yang bisa digunakan sebagai transaksi pembayaran [2]. Pada periode Desember 2021 Bank Indonesia mencatat 59 perusahaan yang memperoleh izin usaha menyelenggarakan uang elektronik. Jumlah perusahaan tersebut merupakan salah satu indikator bahwa uang elektronik diminati oleh masyarakat Indonesia. Di Jakarta uang elektronik digunakan sebagai alat pembayaran jasa transportasi seperti *busway* dan Kereta Rel Listrik (KRL). Ada beberapa daerah yang sudah menggunakan uang elektronik untuk pembayaran jalan tol dan parkir. Menurut Tazkiyyaturrohmah [3], manfaat lain dari uang elektronik yaitu dapat digunakan sebagai pembayaran belanja di toko *offline*. Beberapa toko *offline* saat ini sudah menyediakan pembayaran secara elektronik.

Berdasarkan informasi dari bank Indonesia per Desember 2021, jumlah uang elektronik di Indonesia mengalami kenaikan setiap bulannya. Artinya setiap bulan jumlah uang elektronik yang beredar di Indonesia semakin bertambah. Hal tersebut didukung dengan fasilitas uang elektronik yang masih berkembang. Keuntungan uang elektronik di Indonesia bagi pemerintah yaitu memudahkan pemerintah untuk mengetahui uang yang beredar dimasyarakat, karena peredaran uang elektronik tercatat dalam suatu sistem *database*. Berbeda dengan uang kertas atau logam yang belum bisa tercatat secara otomatis dalam *database*. Kemudahan dalam mengetahui jumlah uang elektronik yang beredar dapat membantu pemerintah dalam mengendalikan inflasi di Indonesia. Peredaran uang elektronik berpengaruh terhadap pertumbuhan ekonomi [4], sehingga dengan adanya tren uang elektronik yang meningkat, maka diperlukan suatu analisis yang dapat digunakan untuk memodelkan maupun meramalkan peredaran uang elektronik di Indonesia. Hasil ramalan tersebut dapat digunakan oleh pemerintah untuk membuat kebijakan yang digunakan untuk stabilisasi perekonomian nasional. Peredaran uang elektronik yang berlebihan dapat menimbulkan inflasi, apabila kondisi tersebut tidak segera diatasi maka akan berdampak terhadap pertumbuhan ekonomi negara.

Hybrid ARIMA-Artificial Neural Network adalah gabungan antara model Model Autoregressive Integrated Moving Average (ARIMA) dengan Artificial Neural Network. Menurut Janah [5] cara kerja dari model hybrid yaitu dengan menjumlahkan model

linier dan non linier. ARIMA merupakan salah satu model yang digunakan untuk meramalkan masa depan dengan mempertimbangkan dari data historinya. Model tersebut menggunakan *input lag* dan *error* dari data dan model. Keunggulan dari model ARIMA yaitu dalam penentuan *input lag* dan *error* dapat menggunakan uji secara statistik. Menurut Fejriani, *et al.* [6], AR merupakan *input* untuk lag dan MA merupakan *input* untuk *error*. Menurut Wulandari dan Gernowo [7], model ARIMA merupakan model linier. Adapun kelemahan dari model ARIMA yaitu terdapat asumsi-asumsi yang harus dipenuhi seperti residual harus berdistribusi normal dan memenuhi kondisi *white noise* [8]. Menurut Suhartono *et al.* [9], *Artificial Neural Network* merupakan model non linier. Pada tahap pemodelan *Artificial Neural Network* diperlukan *input* yang nantinya akan diproses pada *hidden layer*. Pada *hidden layer* digunakan suatu fungsi untuk mendapatkan suatu nilai target yang disebut dengan *output*. Proses untuk mendapatkan nilai pembobot pada model *Artificial Neural Network* terjadi berulang-ulang hingga diperoleh nilai *error* yang paling kecil. Pada *hidden layer* bisa digunakan beberapa *neuron*. Adapun salah satu fungsi yang bisa digunakan pada *hidden layer* yaitu fungsi aktivasi *hyperbolic tangent*. Kekurangan dari *Artificial Neural Network* yaitu tidak adanya suatu pengujian untuk penentu *input lag* seperti pada model ARIMA. Kelebihan dari penggabungan kedua model tersebut yaitu dapat menangkap pola linier dan non linier dari suatu data [10].

Ada beberapa penelitian yang menunjukkan dengan penggabungan dua model akan mendapatkan hasil yang lebih optimal. Menurut Khandelwal *et al.* [11], model hybrid dapat meminimumkan *error* dari model. Adapun penelitian sebelumnya yang membuktikan bahwa model hybrid ARIMA-*Artificial Neural Network* dapat meminimalkan *error* yaitu pada penelitian Hasan dan Djakaria [12]. Pada penelitian tersebut, dilakukan perbandingan akurasi hasil ramalan dari model ARIMA, hybrid ARIMA-*Artificial Neural Network*, dan hybrid ARIMA-GARCH. Ketiga model tersebut digunakan untuk meramalkan nilai tukar petani di Gorontalo. Hasil perbandingan dari ketiga model menunjukkan bahwa model hybrid ARIMA-*Artificial Neural Network* merupakan model yang memiliki *error* paling kecil dibandingkan model lainnya. Penelitian lain yang mengkaji perbandingan model hybrid dilakukan oleh Tahyudin, *et al.* [13]. Pada penelitiannya, ditunjukkan bahwa model hybrid merupakan model yang memiliki akurasi yang paling tinggi untuk memodelkan *mortality* pasien COVID-19.

Penelitian ini bertujuan memodelkan peredaran uang elektronik di Indonesia dengan menggunakan model hybrid ARIMA-*Artificial Neural Network* dan membandingkan akurasinya dengan model non-hybrid. Dipilih model tersebut karena sudah banyak penelitian yang membuktikan bahwa model hybrid ARIMA-*Artificial Neural Network* dapat meminimalkan *error*. Diperlukan model yang memiliki akurasi yang tinggi untuk mengetahui banyaknya peredaran uang elektronik kedepannya. Angka-angka tersebut dapat digunakan sebagai pertimbangan pemerintah dalam membuat kebijakan untuk stabilisasi perekonomian negara.

2. Metode

2.1. Sumber Data

Data yang digunakan merupakan data *time series* jumlah peredaran uang elektronik periode bulanan di Indonesia yang bersumber dari web Bank Indonesia yaitu www.bi.go.id. Adapun periode amatan pada penelitian ini yaitu Januari 2009 hingga Oktober 2021.

2.2. Variabel Penelitian

Penelitian ini menggunakan variabel jumlah peredaran uang elektronik periode bulanan di Indonesia. Variabel tersebut berisikan data *time series*. Adapun simbol untuk jumlah peredaran uang elektronik periode bulanan yaitu Y_t , dengan Y merupakan jumlah peredaran uang elektronik dan t merupakan indeks waktu.

2.3. Langkah Analisis

Langkah-langkah analisis yang dilakukan dalam penelitian ini adalah sebagai berikut:

1. Mendiskripsikan data jumlah peredaran uang elektronik periode bulanan di Indonesia. Untuk mendiskripsikan data tersebut, digunakan *time series plot* untuk melihat pola data seperti pada [14] dan statistik deskriptif untuk melihat karakteristik data seperti yang terdapat pada [15].
2. Membagi data menjadi dua bagian yaitu data *in sample* dan data *out sample*.
3. Menguji stasioneritas data dalam varians dan *mean*. Salah satu metode yang bisa digunakan untuk uji stasioneritas data dalam varians yaitu uji Box-Cox [16]. Berbeda dengan uji Box-Cox, uji Dicky Fuller merupakan alat uji untuk menguji stasioneritas data dalam *mean* [17].
4. Melakukan pemodelan ARIMA data jumlah peredaran uang elektronik periode bulanan di Indonesia. Adapun model ARIMA dituliskan pada persamaan (1).

$$\phi_p(B)(1-B)^d Y_t = \mu + \theta_q(B)\varepsilon_t \quad (1)$$

dengan

p	= order <i>Autoregressive</i> (AR)
q	= order <i>Moving Average</i> (MA)
$\phi_p(B)$	= $1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$
ϕ	= besaran angka koefisien <i>Autoregressive</i> (AR)
$\theta_q(B)$	= $1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$
θ	= besaran koefisien <i>Moving Average</i> (MA)
$(1-B)^d$	= <i>differencing</i> order d
μ	= Konstanta
Y_t	= Series ke- t
ε_t	= error ke- t .

Model ARIMA harus memenuhi kondisi *error* harus berdistribusi normal. Apabila asumsi normal tersebut tidak terpenuhi maka solusi untuk mengatasinya yaitu dengan memasukan *outlier* pada model. Menurut Putri dan Suhartono [18], terdapat beberapa macam *outlier* yaitu *Additive Outlier* disingkat AO, *Innovational Outlier* disingkat IO, *Level Shift* disingkat LS, dan *Temporary Change* disingkat TC. Penelitian ini hanya fokus terhadap dua jenis *outlier* yaitu AO dan LS karena *outlier* ini sering terjadi pada data *time series*. Apabila model ARIMA pada persamaan (1) ditambahkan dua *outlier* yaitu AO dan LS maka diperoleh persamaan (2):

$$Y_t = \frac{\mu + \theta_q(B)}{\phi_p(B)(1-B)^d} \varepsilon_t + \omega_{AO} I_t^{(T)} + \frac{1}{(1-B)} \omega_{LS} I_t^{(T)} \quad (2)$$

dengan

$I_t^{(T)}$ untuk *Additive Outlier* (AO) yaitu:

$$I_t^{(T)} = \begin{cases} 1, & t = T \\ 0, & t \neq T \end{cases}$$

$I_t^{(T)}$ untuk *Level Shift* (LS) yaitu:

$$I_t^{(T)} = \begin{cases} 1, & t \geq T \\ 0, & t < T \end{cases}$$

dan ω merupakan besaran koefisien dari *outlier*. Selanjutnya dilakukan pemodelan ARIMA dengan tahapan berikut:

- (a) Melakukan indikasi model ARIMA menggunakan *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF).
 - (b) Melakukan estimasi parameter dan menguji parameter model ARIMA.
 - (c) Pengecekan asumsi *white noise error* model ARIMA dan harus terpenuhi.
 - (d) Pengecekan asumsi normalitas *error* model ARIMA. Apabila kondisi normalitas *error* tidak terpenuhi maka dilakukan deteksi *outlier*.
5. Melakukan pemodelan *error* dari ARIMA menggunakan *Artificial Neural Network*. Untuk menghitung output pada arsitektur *Multi Layer Perceptron* (MLP) dihitung dengan menggunakan persamaan (3):

$$\hat{\varepsilon}_t = f^o \left[\beta_0 + \sum_{j=1}^J \left(\beta_j f^h \left(\gamma_{j0} + \sum_{i=1}^I \gamma_{ji} \varepsilon_{i,t} \right) \right) \right] \quad (3)$$

dengan,

- \hat{E}_t = output
- β_0 = konstanta neuron pada *hidden layer*
- β_j = Pembobot neuron ke- j pada *hidden layer*
- f^h = fungsi aktivasi neuron pada *hidden layer*
- γ_{ji} = pembobot *input* yang menuju ke *hidden layer*
- γ_{0i} = konstanta *input* yang menuju ke *hidden layer*
- ε_i = variabel *input* dari model linier
- i = indeks variabel *input*
- j = indeks neuron
- t = indeks data *input-target*

Untuk mendapatkan *output* pada *output layer*, terdapat proses pada *input layer* yang menuju ke *hidden layer*. Pada *hidden layer* terdapat fungsi aktivasi yang digunakan untuk perhitungan data dari *input layer*. Adapun fungsi aktivasi yang digunakan yaitu fungsi aktivasi *hyperbolic tangent* [19], yang dinyatakan pada persamaan (4).

$$f^h(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{e^{2x} - 1}{e^{2x} + 1} = \frac{1 + e^{-2x}}{1 - e^{-2x}} \quad (4)$$

Menurut Zhang [20], untuk mendapatkan hybrid dari model ARIMA dan *Artificial Neural Network* yaitu dengan cara menjumlahkan model tersebut. Model ARIMA terbentuk dari data penelitian, sedangkan model *Artificial Neural Network* terbentuk dari *error* model ARIMA:

$$\hat{Y}_t = L_t + N_t \quad (5)$$

dengan L_t = nilai fit atau peramalan dari model ARIMA
 N_t = nilai fit atau peramalan dari *Artificial Neural Network*.

6. Membandingkan kebaikan model ARIMA dan Hybrid ARIMA-*Artificial Neural Network*.

Salah satu kriteria kebaikan model yang bisa digunakan yaitu *Root Mean Square Error* (RMSE) seperti yang dilakukan pada [21]. Pada penelitian ini digunakan kriteria RMSE *in sample* dan *out sample*.


7. Menyimpulkan hasil analisa dan pemodelan.

3. Hasil dan Pembahasan

Pada bab ini dilakukan deskripsi data, membagi data *in sample* dan *out sample*, dan melakukan uji stasioneritas data. Tahap-tahap tersebut dilakukan sebelum dilakukan pemodelan non-hybrid dan hybrid ARIMA- *Artificial Neural Network*. Model non-hybrid yang digunakan pada penelitian ini yaitu ARIMA.

3.1. Deskripsi Data Jumlah Peredaran Uang Eletronik Periode Bulanan di Indonesia

Pada awal tahun 2009 uang eletronik yang beredar di Indonesia tidak sebanyak seperti saat ini. Periode Januari 2009 jumlah uang elektronik yang beredar yaitu sebanyak 576.264. Periode Januari 2018 peredaran uang elektronik mengalami kenaikan yang signifikan dibandingkan periode sebelumnya. Tren kenaikan tajam terus terjadi setelah periode Januari 2018. Pada periode Oktober 2021 jumlah uang elektronik yang beredar mencapai 544.192.781. Pertambahan periode Oktober 2021 terhadap periode Januari 2009 yaitu 543.616.517.



Gambar 1. *Time series plot* jumlah uang elektronik yang beredar di Indonesia

Untuk lebih mendalam terkait peredaran jumlah uang elektronik di Indonesia disajikan statistik deskriptif pada Tabel 1. Berdasarkan Tabel 1 diperoleh informasi bahwa rata-

rata peredaran uang elektronik setiap bulannya yaitu 108.243.557. Untuk nilai paling rendah yaitu terletak pada periode Januari 2009 dan yang paling tinggi yaitu terletak pada periode Oktober 2021.

Tabel 1. Statistik deskriptif peredaran jumlah uang elektronik di Indonesia

Statistik Deskriptif	Jumlah Uang Elektronik Beredar
Rata-rata	108.243.557
St. Dev	147.173.721
Minimal	576.264
Maksimal	544.192.781

Nilai standard deviasi dari peredaran uang elektronik yaitu sebesar 147.173.721. Angka tersebut merupakan simpangan data terhadap rata-ratanya.

3.2. Data in Sample dan out Sample

Untuk data *in sample* menggunakan data periode Januari 2009 hingga Desember 2020 dan data *out sample* menggunakan data periode Januari 2021 hingga Oktober 2021. Data *in sample* merupakan data yang digunakan sebagai pemodelan dan data *out sample* digunakan untuk melihat akurasi dari model.

3.3. Uji Stasioneritas Data

Salah satu syarat dalam pemodelan ARIMA yaitu data harus memenuhi kondisi stasioner dalam varians dan mean. Pada sub bab ini dilakukan pengujian dari kedua syarat tersebut. Untuk data yang diuji stasioneritas dalam varians dan mean yaitu data *in sample*. Tabel 2 merupakan hasil uji stasioneritas dalam varians menggunakan uji Box-Cox. Hasil uji Box-Cox menunjukkan bahwa data peredaran uang elektronik belum memenuhi kondisi stasioner dalam varians karena nilai *rounded* sebesar 0,12. Data dikatakan sudah memenuhi stasioner dalam varians apabila nilai *rounded* sebesar 1. Sehingga untuk memenuhi kondisi tersebut dilakukan transformasi $X^{0,12}$.

Tabel 2. Uji stasioneritas data dalam varians

Variabel	<i>Rounded Value</i>	Transformasi
Y_t	0,12	$Y^{0,12}$

Untuk uji stasioneritas data dalam *mean* digunakan uji Dickey Fuller. Pada Tabel 3 disajikan hasil Dicky fuller dari data yang sudah dilakukan proses *differencing* 1. Proses *differencing* 1 dilakukan karena hasil uji Dicky Fuller untuk data sebelum dilakukan proses *differencing* 1 tidak memenuhi kondisi stasioner dalam *mean*. Pada Tabel 3 menunjukkan bahwa semua nilai $prob < \tau$, $Pr < \rho$, dan $Pr > F$ kurang dari 0,05. Sehingga dapat disimpulkan data sudah stasioner dalam *mean*.

3.4. Pemodelan ARIMA

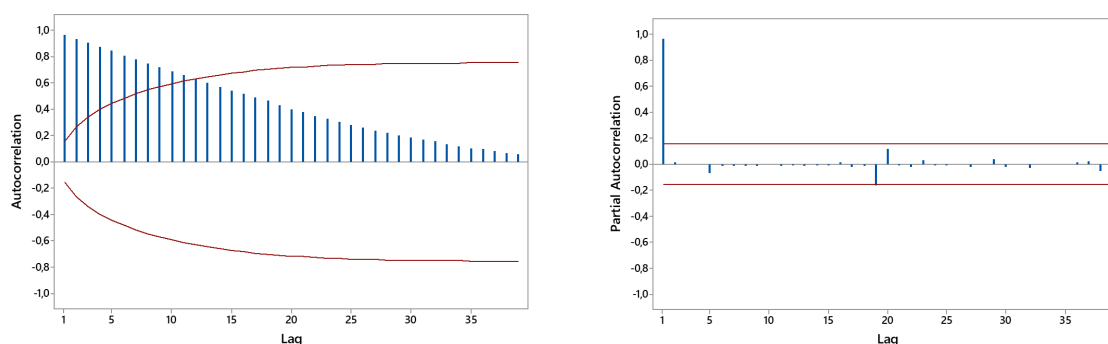
Terdapat beberapa tahapan pada pemodelan ARIMA yaitu penentuan order ARIMA, melakukan estimasi parameter, pengecekan asumsi, dan menuliskan model ARIMA yang sesuai.

Tabel 3. Uji stasioneritas data dalam *mean*

Tipe	Lags	Rho	Pr < Rho	Tau	Pr < Tau	F	Pr > F
Zero Mean	0	-124,360	0,001	-11,52	0,001		
	1	-79,704	0,001	-6,90	0,001		
Single Mean	0	-159,857	0,001	-14,87	0,001	110,74	0,001
	1	-162,959	0,001	-9,87	0,001	48,77	0,001
Trend	0	-160,017	0,001	-14,80	0,001	109,89	0,001
	1	-162,759	0,001	-9,81	0,001	48,35	0,001

3.4.1. Penentuan order ARIMA

Penentuan order ARIMA dilakukan untuk menentukan order p dan q persamaan (1). Untuk menentukan order ARIMA yang terbentuk, digunakan ACF dan PACF. Terdapat beberapa macam pola dari ACF dan PACF telah dibahas oleh Wei [17].

**Gambar 2.** ACF dan PACF

Dapat dilihat pada Gambar 2 pola yang terbentuk dari ACF yaitu *dies down* dan pola PACF yang terbentuk yaitu *cut off after lag 1*. Menurut Wei [17] model ARIMA yang terbentuk berdasarkan ACF dan PACF tersebut yaitu AR(1).

3.4.2. Estimasi Parameter Model ARIMA

Berdasarkan hasil indikasi model ARIMA menggunakan ACF dan PACF, menunjukkan order ARIMA yang terbentuk yaitu ARIMA (1,1,0). Akan tetapi dengan model ARIMA (1,1,0) diperoleh asumsi normalitas dari *error* yang tidak terpenuhi. Pada pemodelan ARIMA dimasukkan *Additive Outlier* dan *Level Shift Outlier*. Tabel 4 menunjukkan hasil estimasi parameter dengan uji t untuk masing-masing variabel dan *lag* yang signifikan dengan taraf alfa 0,05. Terdapat 16 *outlier* yang dimasukkan pada model. Terdapat 8 *additive outlier* (AO) dan 8 *level shift outlier* (LS).

3.4.3. Pengecekan Asumsi Model ARIMA

Asumsi pertama yang harus dipenuhi yaitu *error* harus berdistribusi normal. Adapun statistik uji yang digunakan yaitu uji Kolmogorov-Smirnov. Hasil dari uji Kolmogorov-Smirnov diperoleh nilai statistik 0,067 dan nilai p -value dengan angka 0,115. Dari hasil *output* tersebut, dapat disimpulkan yaitu residual sudah memenuhi asumsi berdistribusi normal karena nilai p -value lebih besar dari 0,05 seperti yang juga dilakukan pada [22].

Untuk asumsi selanjutnya yaitu *error* harus memenuhi kondisi *white noise*. Uji Ljung Box

Tabel 4. Hasil estimasi parameter model ARIMA dengan outlier

Variabel	Estimate	Standard Error	t Value	P-value
Konstanta	0,042	0,004	9,310	0,000
Y_{t-1}	0,673	0,066	10,120	0,000
AO1	-0,403	0,017	-23,870	0,000
AO107	0,373	0,009	43,500	0,000
AO136	0,265	0,009	30,900	0,000
LS84	-0,295	0,015	-20,120	0,000
LS63	-0,228	0,015	-15,550	0,000
LS60	0,223	0,015	15,170	0,000
LS18	0,085	0,015	5,770	0,000
LS3	0,097	0,017	5,830	0,000
AO103	0,050	0,009	5,830	0,000
AO120	0,041	0,009	4,780	0,000
AO36	0,040	0,009	4,650	0,000
AO133	0,032	0,009	3,760	0,000
LS7	-0,054	0,015	-3,700	0,000
LS127	0,064	0,015	4,220	0,000
AO128	0,031	0,009	3,470	0,000
LS5	0,049	0,015	3,310	0,001

merupakan salah satu uji yang bisa digunakan untuk mengetahui apakah *error* sudah memenuhi kondisi *white noise*. Adapun hasil uji Ljung Box disajikan pada Tabel 5.

Tabel 5. Uji Ljung Box

To Lag	Chi-Square	DF	P-Value
6	4,190	6	0,652
12	6,990	12	0,858
18	11,600	18	0,867
24	18,200	24	0,793

Berdasarkan Tabel 5 diperoleh bahwa hingga lag 24 semua nilai *p-value* lebih besar dari 0,05, sehingga dapat dikatakan bahwa residual sudah memenuhi kondisi *white noise*.

3.4.4. Model ARIMA(1,1,0) dengan Outlier AO dan LS

Adapun model ARIMA yang sesuai untuk data jumlah peredaran uang elektronik periode bulanan di Indonesia diberikan pada persamaan (6).

$$\hat{Y}_t = 0,042 \frac{1}{(1 - 0,673)(1 - B)} \varepsilon_t - 0,403I_t^{(1)} + 0,373I_t^{(107)} + 0,265I_t^{(136)} + 0,050I_t^{(103)} \quad (6)$$

$$+ 0,041I_t^{(120)} + 0,040I_t^{(36)} + 0,032I_t^{(133)} + 0,031I_t^{(128)} - \frac{0,295}{(1 - B)} I_t^{(84)} - \frac{0,228}{(1 - B)} I_t^{(63)}$$

$$+ \frac{0,223}{(1 - B)} I_t^{(60)} + \frac{0,085}{(1 - B)} I_t^{(18)} + \frac{0,097}{(1 - B)} I_t^{(3)} - \frac{0,054}{(1 - B)} I_t^{(7)} + \frac{0,064}{(1 - B)} I_t^{(128)}$$

$$+ \frac{0,049}{(1 - B)} I_t^{(5)}.$$


3.5. Pemodelan Hybrid ARIMA-Artificial Neural Network

Setelah didapatkan model ARIMA untuk data jumlah peredaran uang eletronik periode bulanan di Indonesia, maka didapatkan *error* dari model tersebut. Hasil ramalan dari model ARIMA dijadikan komponen linier. Adapun *error* dari model ARIMA dimodelkan dengan model *Artificial Neural Network* yang dijadikan komponen non linier.

Tabel 6. Repetition model *Artificial Neural Network*

Repetition	Error	Repetition	Error
1	2,606	11	2,595
2	2,625	12	2,640
3	2,577	13	2,569
4	2,652	14	2,646
5	2,599	15	2,582
6	2,603	16	2,610
7	2,630	17	2,611
8	2,603	18	2,646
9	2,602	19	2,608
10	2,597	20	2,585

Error dari model ARIMA pada waktu ke t dijadikan nilai target. Untuk *error* model ARIMA pada waktu ke $t - 1$ dijadikan sebagai *input*. Untuk pemodelan *Artificial Neural Network* dibatasi dengan menggunakan satu *hidden layer* dengan tiga *neuron*, belum tentu dengan jumlah *neuron* yang banyak dapat diperoleh akurasi yang lebih baik [23]. Pada proses pemodelan dilakukan sebanyak 20 *repetition*. Dari 20 *repetition* tersebut dipilih *error* yang paling kecil. Berdasarkan Tabel 6, diperoleh nilai *repetition* terkecil yaitu *repetition* ke 13 dengan nilai *error* yaitu 2,569. Berikut arsitektur *Artificial Neural Network* yang terbentuk berdasarkan *repetition* ke 13.



Gambar 3. Arsitektur *Artificial Neural Network* 1-3-1

Berdasarkan Gambar 3, didapatkan model *Artificial Neural Network* 1-3-1 pada persamaan (7).

$$\hat{E}_t = 0,083 - 0,183 f_1^h(\cdot) + 0,225 f_2^h(\cdot) + 0,099 f_3^h(\cdot), \tag{7}$$

dimana penjabaran untuk masing-masing *neuron hidden layer* adalah sebagai berikut:

$$f_1^h(\cdot) = \frac{e^{2(0,569+1,309E_{t-1})} - 1}{e^{2(0,569+1,309E_{t-1})} + 1},$$

$$f_2^h(\cdot) = \frac{e^{2(2,706+2,360E_{t-1})} - 1}{e^{2(2,706+2,360E_{t-1})} + 1},$$

$$f_3^h(\cdot) = \frac{e^{2(-2,166+7,486E_{t-1})} - 1}{e^{2(-2,166+7,486E_{t-1})} + 1}.$$

Selanjutnya, dengan menjumlahkan model pada persamaan (6) dengan persamaan (7), diperoleh model hybrid yang dinyatakan pada persamaan (8).

$$\hat{Y}_t = L_t + N_t \tag{8}$$

dengan,

$$L_t = 0,042 \frac{1}{(1 - 0,673)(1 - B)} \varepsilon_t - 0,403I_t^{(1)} + 0,373I_t^{(107)} + 0,265I_t^{(136)} + 0,050I_t^{(103)}$$

$$+ 0,041I_t^{(120)} + 0,040I_t^{(36)} + 0,032I_t^{(133)} + 0,031I_t^{(128)} - \frac{0,295}{(1 - B)} I_t^{(84)} - \frac{0,228}{(1 - B)} I_t^{(63)}$$

$$+ \frac{0,223}{(1 - B)} I_t^{(60)} + \frac{0,085}{(1 - B)} I_t^{(18)} + \frac{0,097}{(1 - B)} I_t^{(3)} - \frac{0,054}{(1 - B)} I_t^{(7)} + \frac{0,064}{(1 - B)} I_t^{(128)}$$

$$+ \frac{0,049}{(1 - B)} I_t^{(5)}.$$

$$N_t = 0,083 - 0,183f_1^h(\cdot) + 0,225f_2^h(\cdot) + 0,099f_3^h(\cdot)$$

dan

$$f_1^h(\cdot) = \frac{e^{2(0,569+1,309E_{t-1})} - 1}{e^{2(0,569+1,309E_{t-1})} + 1},$$

$$f_2^h(\cdot) = \frac{e^{2(2,706+2,360E_{t-1})} - 1}{e^{2(2,706+2,360E_{t-1})} + 1},$$

$$f_3^h(\cdot) = \frac{e^{2(-2,166+7,486E_{t-1})} - 1}{e^{2(-2,166+7,486E_{t-1})} + 1}.$$

3.6. Perbandingan Nilai RMSE Model ARIMA dengan Hybrid ARIMA-Artificial Neural Network

Setelah diperoleh nilai *fit* maupun nilai ramalan dari model ARIMA dan hybrid ARIMA-Artificial Neural Network, maka langkah selanjutnya yaitu membandingkan kedua model. Untuk melihat model mana yang paling sesuai, maka digunakan nilai RMSE *in sample* maupun *out sample* pada Tabel 7.

Berdasarkan Tabel 7 diperoleh informasi bahwa model hybrid ARIMA-Artificial Neural Network memiliki nilai RMSE *in sample* dan RMSE *out sample* lebih kecil dibandingkan model ARIMA. Sehingga dapat disimpulkan bahwa dengan adanya penggabungan

Tabel 7. Nilai RMSE

Model	RMSE <i>in Sample</i>	RMSE <i>out Sample</i>
ARIMA	1.883.485	20.818.642
Hybrid ARIMA- <i>Artificial Neural Network</i>	1.851.134	20.775.382

model ARIMA dengan model *Artificial Neural Network*, dapat meningkatkan akurasi hasil *fit* data maupun hasil ramalan.

4. Kesimpulan

Hasil penelitian menunjukkan bahwa jumlah peredaran uang elektronik periode bulanan di Indonesia cenderung mengalami kenaikan setiap bulannya. Pada periode Oktober 2021 jumlah uang elektronik yang beredar mencapai 544.192.781. Jumlah pertambahan jumlah uang elektronik yang beredar periode Oktober 2021 dari periode Januari 2009 yaitu 543.616.517. Model ARIMA yang terbentuk yaitu ARIMA (1,1,0) dengan penambahan *Additive Outlier* (AO) dan *Level Shift* (LS). Untuk model *Artificial Neural Network* digunakan tiga *neuron* pada *hidden layer* dan dilakukan *repetition* sebanyak 20. Nilai optimal diperoleh pada *repetition* 13. Dari kedua model yang digunakan dapat ditunjukkan bahwa model hybrid ARIMA-*Artificial Neural Network* memiliki nilai RMSE *in sample* dan RMSE *out sample* yang lebih kecil dibandingkan model ARIMA.

Penelitian ini membuktikan bahwa penggabungan dua model menjadi model hybrid ARIMA-*Artificial Neural Network*, dapat meningkatkan tingkat akurasi model. Hal ini dapat menjadi acuan bagi penelitian selanjutnya untuk mencoba menggunakan model non linier lainnya, seperti *Support Vector Machine* (SVM), *Adaptif Neuro Fuzzy Inference System* (ANFIS) ataupun model lainnya.

Referensi

- [1] M. Choiril Anam, "E-money (Uang Elektronik) Dalam Perspektif Hukum Syari'ah," *Qawānīn Journal of Economic Syaria Law*, vol. 2, no. 1, pp. 95–112, jan 2018, doi: 10.30762/q.v2i1.1049.
- [2] J. Syamsu, D. Oldisan, and Y. Efendi, "Persepsi Masyarakat Terhadap Implementasi Metode Pembayaran Menggunakan Kartu E-Money (BRIZZI) pada Bus Trans Padang," *Public Adm. Bus. Rural Development Plan*, vol. 4, no. 1, pp. 1–8, 2022.
- [3] R. Tazkiyyaturrohmah, "Eksistensi Uang Elektronik Sebagai Alat Transaksi Keuangan Modern," *Muslim Heritage*, vol. 3, no. 1, pp. 23–44, jun 2018, doi: 10.21154/muslimheritage.v3i1.1240.
- [4] A. P. Wijaya, "Pengaruh Penggunaan Uang Elektronik, Jumlah Uang Beredar, dan Inflasi Terhadap Pertumbuhan Ekonomi Indonesia," in *Prosiding Seminar Nasional & Call for Paper STIE AAS*, 2021, pp. 206–212.
- [5] S. N. Janah, W. Sulandari, and S. B. Wiyono, "Penerapan Model Hybrid ARIMA backpropagation Untuk Peramalan Harga Gabah Indonesia," *Media Statistika*, vol. 7, no. 2, pp. 63–69, dec 2014, doi: 10.14710/medstat.7.2.63-69.
- [6] F. Fejriani, M. Hendrawansyah, L. Muharni, S. F. Handayani, and S. Syaharuddin, "Forecasting Peningkatan Jumlah Penduduk Berdasarkan Jenis Kelamin Menggunakan Metode ARIMA," *Geogr. J. Kajian, Penelit. dan Pengemb. Pendidik.*, vol. 8, no. 1, pp. 27–36, 2020, doi: 10.31764/geography.v8i1.2261.
- [7] R. A. Wulandari and R. Gernowo, "Metode Autoregressive Integrated Movingaverage (ARIMA) Dan Metode Adaptive Neuro Fuzzy Inference System (ANFIS) dalam Analisis Curah Hujan," *Berkala Fisika*, vol. 22, no. 1, pp. 41–48, 2019.
- [8] H. Panjaitan, A. Prahutama, and S. Sudarno, "Peramalan Jumlah Penumpang Kereta Api

- Menggunakan Metode ARIMA, Intervensi dan ARFIMA (Studi Kasus: Penumpang Kereta Api Kelas Lokal Ekonomi DAOP IV Semarang)," *Jurnal Gaussian*, vol. 7, no. 1, pp. 96–109, feb 2018, doi: 10.14710/j.gauss.v7i1.26639.
- [9] S. Suhartono, D. E. Ashari, D. D. Prastyo, H. Kuswanto, and M. H. Lee, "Deep Neural Network for Forecasting Inflow and Outflow in Indonesia," *Sains Malaysiana*, vol. 48, no. 8, pp. 1787–1798, aug 2019, doi: 10.17576/jsm-2019-4808-26.
- [10] T.O. Olatayo and K. I. Ekerikevwe, "Performance Measures for Evaluating the Accuracy of Time Series Hybrid Model Using High Frequency Data," *Britain International of Exact Sciences (BloEx) Journal*, vol. 4, no. 3, pp. 244–259, sep 2022, doi: 10.33258/bioex.v4i3.760.
- [11] I. Khandelwal, R. Adhikari, and G. Verma, "Time Series Forecasting Using Hybrid ARIMA and ANN Models Based on DWT Decomposition," *Procedia Computer Science*, vol. 48, pp. 173–179, 2015, doi: 10.1016/j.procs.2015.04.167.
- [12] I. K. Hasan and Ismail Djakaria, "Perbandingan Model Hybrid ARIMA-NN dan Hybrid ARIMA-GARCH untuk Peramalan Data Nilai Tukar Petani di Provinsi Gorontalo," *Jurnal Statistika dan Aplikasinya*, vol. 5, no. 2, pp. 155–165, dec 2021, doi: 10.21009/JSA.05204.
- [13] I. Tahyudin, R. Wahyudi, W. Maulana, and H. Nambo, "The mortality modeling of covid-19 patients using a combined time series model and evolutionary algorithm," *International Journal of Advances in Intelligent Informatics*, vol. 8, no. 1, pp. 69–83, mar 2022, doi: 10.26555/ijain.v8i1.669.
- [14] M. R. Susila, M. Jamil, and B. H. Santoso, "Analisis Dampak COVID-19 dan Faktor-Faktor yang Mempengaruhi Indeks Saham Bank Jatim Menggunakan Pendekatan Regresi Time Series," *Jambura Journal of Mathematics*, vol. 4, no. 2, pp. 220–231, jun 2022, doi: 10.34312/jjom.v4i2.13401.
- [15] M. R. Susila, R. C. Putri, and D. Arini, "Pemodelan Regresi Spasial Investasi Luar Negeri yang Masuk ke Indonesia," *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, vol. 14, no. 4, pp. 543–556, dec 2020, doi: 10.30598/barekengvol14iss4pp543-556.
- [16] D. N. Gujarati and D. C. Porter, *Basic Econometrics*, 5th ed. New York: McGraw-Hill Education, 2008.
- [17] W. W. S. Wei, *Multivariate Time Series Analysis and Applications*, 1st ed. New York: John Wiley & Sons Inc, 2019.
- [18] I. K. Putri and S. Suhartono, "Deteksi Outlier pada Model ARIMA Musiman Ganda untuk Peramalan Beban Listrik Jangka Pendek di Jawa Timur," *J. Sains dan Seni ITS*, vol. 4, no. 1, pp. D31–D36, 2015, doi: 10.12962/j23373520.v4i1.8837.
- [19] I. Prayoga, S. Suhartono, and S. P. Rahayu, "Hierarchical Forecasting Method Based on ARIMAX and Recurrent Neural Network for Motorcycle Sales Prediction," *Int. J. Appl. Math. Stat.*, vol. 5, no. 3, pp. 116–124, 2015.
- [20] G. Zhang, "Time series forecasting using a hybrid ARIMA and neural network model," *Neurocomputing*, vol. 50, pp. 159–175, jan 2003, doi: 10.1016/S0925-2312(01)00702-0.
- [21] M. R. Susila, "Spatio-Temporal Analysis of Rupiah Loans Provided by Commercial Banks And Rural Banks," *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, vol. 16, no. 3, pp. 1003–1012, sep 2022, doi: 10.30598/barekengvol16iss3pp1003-1012.
- [22] M. R. Susila and F. A. Pradhani, "Analisis Pengaruh PDRB Per Kapita dan Jumlah Tenaga Kerja Terhadap Jumlah Pendapatan Pajak Daerah Provinsi di Indonesia," *Jurnal Ilmiah Akuntansi dan Keuangan (JIaku)*, vol. 1, no. 1, pp. 72–87, apr 2022, doi: 10.24034/jiaku.v1i1.4996.
- [23] P. Wibowo, "Pengaruh Perbedaan Jumlah Hidden Layer dalam Jaringan Syaraf Tiruan Terhadap Prediksi Kebutuhan Captopril dan Paracetamol pada Rumah Sakit," *Media Apl.*, vol. 11, no. 2, pp. 118–131, 2019, doi: 10.33488/2.ma.2019.2.207.



This article is an open-access article distributed under the terms and conditions of the [Creative Commons Attribution-NonCommercial 4.0 International License](https://creativecommons.org/licenses/by-nc/4.0/). Editorial of JJoM: Department of Mathematics, Universitas Negeri Gorontalo, Jln. Prof. Dr. Ing. B.J. Habibie, Moutong, Tilongkabila, Kabupaten Bone Bolango, Provinsi Gorontalo 96554, Indonesia.