

## MODEL PERAMALAN NILAI TUKAR MATA UANG MENGUNAKAN METODE *HYBRID* GLARANN (EXCHANGE RATES FORECASTING MODEL USING GLARANN HYBRID METHOD)

YOGYA ARDI WINATA\*, SUBANAR

**Abstract.** The GLARANN hybrid method is a combination of the Generalized Linear Autoregressive (GLAR) model which includes a linear model and an Artificial Neural Network (ANN) which is classified as a nonlinear model. The idea of the GLARANN hybrid method is to use the advantages of each model, the GLAR model in detecting linear patterns and ANN in detecting nonlinear patterns in time series data. The purpose of this study was to determine the procedure for preparing a forecasting model of the GLARANN hybrid method, as well as its application and effectiveness. The application of the GLARANN hybrid method is forecasting the rupiah exchange rate (IDR) against several foreign currencies, namely the American dollar (USD), euro (EUR), Japanese yen (JPY), Hong Kong dollar (HKD), Australian dollar (AUD), and dollar Singapore (SGD), with export value as exogenous variable. The forecast results show that the GLARANN hybrid method is effective in forecasting AUD based on the RMSE, MAE, MAPE and NMSE values. However, it is not effective in forecasting HKD, SGD, and USD. In EUR and JPY forecasting, the GLAR method is the most effective method. Meanwhile, the GLARANN hybrid method is only more effective than ANN based on RMSE and NMSE. *Keywords:* hybrid method, GLAR model, neural network, forecasting, exchange rates.

**Abstrak.** Metode *hybrid* GLARANN merupakan gabungan dari model *Generalized Linear Autoregression* (GLAR) yang termasuk model linear dan *Artificial Neural Network* (ANN) yang digolongkan dalam model nonlinear. Gagasan metode *hybrid* GLARANN adalah menggunakan kelebihan dari masing-masing model, yaitu model GLAR dalam mendeteksi pola linear dan ANN dalam mendeteksi pola nonlinear pada data runtun waktu. Tujuan penelitian ini adalah untuk mengetahui prosedur penyusunan model peramalan metode *hybrid* GLARANN, serta aplikasi dan efektifitasnya. Aplikasi metode *hybrid* GLARANN yaitu pada peramalan nilai tukar rupiah (IDR) terhadap beberapa mata uang asing, yaitu dollar Amerika (USD), euro (EUR), yen Jepang (JPY), dollar Hongkong (HKD), dollar Australia (AUD), dan dollar Singapura (SGD), dengan nilai ekspor sebagai variabel eksogen. Hasil peramalan menunjukkan metode *hybrid* GLARANN efektif dalam peramalan AUD berdasarkan nilai RMSE, MAE, MAPE dan NMSE. Namun tidak efektif pada peramalan HKD, SGD, dan USD. Pada peramalan EUR dan JPY, model GLAR merupakan metode yang paling efektif. Sedangkan, metode *hybrid* GLARANN hanya lebih efektif daripada ANN berdasarkan RMSE dan NMSE.

*Kata-kata kunci:* Metode *hybrid*, model GLAR, *neural network*, peramalan, nilai tukar mata uang.

## 1. PENDAHULUAN

Nilai tukar mata uang disebut juga dengan kurs (*exchange rate*). Secara sederhana kurs dapat diartikan sebagai nilai mata uang suatu negara diukur dengan mata uang negara lain. Terdapat tiga jenis kurs, yaitu kurs beli, kurs jual, dan kurs tengah. Nilai kurs sering sekali mengalami perubahan secara fluktuatif, mengalami kenaikan nilai (apresiasi) maupun penurunan nilai (depresiasi).

Nilai tukar mata uang ditentukan oleh mekanisme pasar dalam menjaga keseimbangan antara permintaan dan penawaran mata uang. Terdapat beberapa faktor yang mempengaruhi nilai mata uang yaitu, perbedaan tingkat inflasi, tingkat suku bunga, kegiatan ekspor-impor, kebijakan pemerintah, kondisi politik, dan lain sebagainya.

Model peramalan mata uang yang pertama dikenalkan adalah *Random Walk* (RW) di dalam Meese dan Rogoff [14]. Beberapa penelitian lain tentang peramalan nilai tukar mata uang diantaranya, Wu[18], El Shazly dan El Shazly [10], dan Carriero et al [8].

Sebagaimana yang telah disebutkan di atas, bahwa nilai tukar mata uang dapat dipengaruhi faktor yang lain atau eksternal. Salah satu model data runtun waktu yang dapat menangkap pengaruh variabel lain (variabel eksogen) adalah Model *Generalized Linear Autoregression* (GLAR). Model GLAR merupakan model peramalan klasik dengan pendekatan linear yang merupakan bentuk spesial dari model *Vector Autoregressive* (VAR) dengan beberapa perbedaan. Sebagaimana model peramalan klasik dengan pendekatan linear, model GLAR memiliki keterbatasan dalam membaca pola data runtun waktu yang tidak selalu linear karena mempunyai volatilitas dan *noisy* yang tinggi.

Seiring berkembangnya riset dan teknologi, para peneliti dan praktisi ekonomi mengembangkan model peramalan nonlinear, yaitu *Artificial Neural Network* (ANN). ANN adalah suatu model yang arsitekturnya terilhami dari sistem saraf pada otak manusia. Kelebihan ANN dibandingkan dengan metode peramalan klasik adalah dapat membaca pola data yang bersifat nonlinear, tidak membutuhkan asumsi distribusi data dan *missing*, serta inkonsistensi data dan *noisy* tidak menjadi masalah [11]. Selain itu ANN dapat melakukan *training* (pelatihan) data yang kemudian menjadi acuan dalam melakukan peramalan [9].

Dalam kurun waktu beberapa tahun terakhir, model *hybrid* (gabungan) antara ANN dengan model peramalan klasik dikembangkan untuk meningkatkan akurasi peramalan. Gagasan utama dalam menggabungkan dua metode dalam peramalan adalah untuk menggunakan kelebihan masing-masing metode dalam mendeteksi pola data. ARIMA merupakan model klasik yang sangat populer. Zhang[20] menkonstruksi *hybrid* antara model ARIMA dengan ANN. Abdulkadir et al[7] melakukan *hybrid* antara Kalman Filter dan *Non-linear Autoregressive Neural Network* (NARX) dalam peramalan data Bursa Malaysia KLCI. Khashei et al[13] melakukan *hybrid* model ARIMA dan *Probabilistic Neural Networks* (PNNs) dengan aplikasi pada tiga jenis data, salah satunya data nilai tukar mata uang GBP/USD. Hasil dari peramalan ketiga data menunjukkan bahwa *hybrid* model menghasilkan akurasi peramalan lebih baik dibandingkan

model ARIMA. Wang et al[17] melakukan *hybrid* ESM, ARIMA, dan BPNN pada indeks harga saham. Hasil peramalan menunjukkan bahwa model *hybrid* lebih baik dari model klasik.

Berdasarkan uraian di atas, penulis mengajukan suatu integrasi antara model GLAR dan ANN dalam peramalan nilai tukar mata uang, yang selanjutnya disebut metode *hybrid* GLARANN. Pendekatan yang digunakan adalah dengan menggunakan GLAR dan ANN untuk mendeteksi pola data linear dan nonlinear sebagai model gabungan. Tujuan penelitian ini adalah untuk mengetahui prosedur penyusunan model peramalan metode *hybrid* GLARANN, serta aplikasi dan efektifitasnya.

## 2. MODEL VECTOR AUTOREGRESSIVE (VAR)

*Vector Autoregressive* (VAR) merupakan suatu model runtun waktu multivariat. Model VAR digunakan untuk memodelkan persamaan dari beberapa variabel endogen secara simultan. Setiap variabel endogen dijelaskan oleh lag (*past value*)-nya dan lag dari variabel endogen lainnya.

Model VAR( $p$ ) dinyatakan sebagai

$$\mathbf{y}_t = \mathbf{v} + \mathbf{A}_1 \mathbf{y}_{t-1} + \mathbf{A}_2 \mathbf{y}_{t-2} + \cdots + \mathbf{A}_p \mathbf{y}_{t-p} + \mathbf{u}_t, \quad t = 0, \pm 1, \pm 2, \dots, \quad (2.1)$$

dengan  $\mathbf{y}_t = (y_{1t}, y_{2t}, \dots, y_{kt})$  variabel random berukuran  $(k \times 1)$ ,  $\mathbf{v} = (v_1, v_2, \dots, v_k)$  merupakan intersep dari  $\mathbf{y}_t$ ,  $\mathbf{A}_l$  matriks koefisien dari  $y_{t-l}$  berukuran  $(k \times k)$  dengan  $l = 1, 2, \dots, p$ , dan  $\mathbf{u}_t = (u_{1t}, u_{2t}, \dots, u_{kt})$  berdistribusi independen *white noise* dengan matriks varian kovarian  $\Sigma$ .

**Estimasi Model VAR( $p$ ).** Diberikan sampel data runtun waktu  $\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_T$ ,  $T$  sampel pada setiap  $k$  variabel. Diasumsikan terdapat presampel  $\mathbf{y}_{-p+1}, \dots, \mathbf{y}_0$ . Model VAR( $p$ ) pada Persamaan (2.1) akan diestimasi dengan *multivariate least squares* (MLS).

Menurut Lütkepohl[4], untuk menyederhanakan model pada Persamaan (2.1) dibuat partisi matriks

$$\begin{aligned} \mathbf{Y} &:= [\mathbf{y}_1 | \mathbf{y}_2 | \dots | \mathbf{y}_T] && (k \times T) \\ \mathbf{B} &:= [\mathbf{v} | \mathbf{A}_2 | \dots | \mathbf{A}_p] && (k \times (kp + 1)) \\ \mathbf{Z} &:= [\mathbf{Z}_0 | \mathbf{Z}_1 | \dots | \mathbf{Z}_{T-1}] && ((kp + 1) \times T) \\ \mathbf{U} &:= [\mathbf{u}_1 | \mathbf{u}_2 | \dots | \mathbf{u}_T] && (k \times T) \end{aligned} \quad (2.2)$$

dengan  $\mathbf{Z}_t = (1, \mathbf{y}_t, \dots, \mathbf{y}_{t-p+1})$  matriks berukuran  $((kp + 1) \times 1)$ .

Untuk  $t = 1, 2, \dots, T$  model VAR( $p$ ) pada Persamaan (2.1) dapat ditulis sebagai

$$\mathbf{Y} = \mathbf{BZ} + \mathbf{U}. \quad (2.3)$$

Estimator untuk  $\mathbf{B}$  dinyatakan sebagai


$$\hat{\mathbf{B}} = \mathbf{YZ}'(\mathbf{ZZ}')^{-1}. \quad (2.4)$$

### 3. DASAR-DASAR *NEURAL NETWORK*

*Neural network* merupakan sistem pengolahan informasi yang arsitekturnya terilhami dari jaringan saraf biologis. *Neural network* dicirikan pada tiga hal utama, yaitu arsitektur, algoritma pelatihan (*training algorithm*), dan fungsi aktivasi [1]. Pada *neural network* terdapat elemen pengolahan informasi yang disebut neuron atau unit, dengan setiap neuron memiliki aktivasi dan saling terhubung melalui koneksi dengan bobot tertentu.

*Neural network* secara sederhana dinyatakan pada Gambar 1. Secara matematis dapat dinyatakan dinyatakan

$$\begin{aligned} y_{in_j} &= \sum_{i=0}^n x_i w_{ij} \\ &= w_{0j} + \sum_{i=1}^n x_i w_{ij} \\ &= b_j + \sum_{i=1}^n x_i w_{ij}. \end{aligned}$$



GAMBAR 1. *Neural network* dengan bias

Aktivasi  $y_j$  dari neuron  $Y_j$  merupakan input net yang dikenai fungsi aktivasi  $f$ , yaitu

$$\begin{aligned} y_j &= f(y_{in_j}) \\ &= f\left(b_j + \sum_{i=1}^n x_i w_{ij}\right). \end{aligned}$$

**3.1. Arsitektur *Neural Network*.** Secara umum *neural network* terdiri dari tiga lapisan, yaitu lapisan input (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan output (*output layer*). Berdasarkan lapisan yang terlibat, arsitektur jaringan pada *neural network* biasa dikelompokkan menjadi dua jenis, yaitu *neural network* dengan lapisan tunggal (*single-layer*) dan *neural network* dengan lapisan jamak (*multi-layer*). Jaringan lapisan tunggal terdiri dari satu koneksi terbobot. Contoh algoritma pelatihan dengan arsitektur lapisan tunggal adalah Hebb *net*, ADALINE (*adaptive linear neuron*), Hopfield, dan perceptron. Jaringan lapisan jamak merupakan jaringan dengan satu atau lebih lapisan tersembunyi yang menghubungkan antara lapisan input dan lapisan output, dimana antar lapisan terdapat koneksi terbobot. Contoh algoritma pelatihan yang menggunakan arsitektur lapisan jamak adalah MADALINE (*multilayer ADALINE*), *neocognitron*, dan *backpropagation*.

**3.2. Algoritma Pelatihan.** Algoritma pelatihan merupakan metode yang digunakan untuk menentukan bobot. Penentuan bobot penting dalam membedakan karakteristik dari *neural network*. Menurut Haykin [3], terdapat dua algoritma pelatihan yaitu pelatihan terbimbing (*supervised*) dan pelatihan tidak terbimbing (*unsupervised*).

**3.3. Fungsi Aktivasi.** Sebagaimana diilustrasikan pada contoh di atas, suatu aktivasi dari output merupakan penjumlahan dari sinyal input terbobot yang dikenai suatu fungsi. Pada input net, fungsi yang mengenaikannya adalah fungsi identitas. Pada sebagian besar kasus, fungsi yang digunakan adalah fungsi nonlinear. Berikut beberapa jenis fungsi aktivasi.

- (1) Fungsi identitas

$$f(x) = x, \text{ untuk setiap } x. \quad (3.1)$$

- (2) Fungsi step biner (dengan *threshold*  $\theta$ )

Pada jaringan lapisan tunggal fungsi step digunakan untuk mengkonversi net input yang bernilai kontinu menjadi output berupa sinyal biner (0 dan 1) atau bipolar (-1 dan 1). Fungsi step dinyatakan sebagai

$$\text{fungsi } \textit{threshold} f(x) = \begin{cases} 1 & \text{jika } x \geq \theta, \\ 0 & \text{jika } x < \theta. \end{cases} \quad (3.2)$$

dengan  $\theta$  adalah suatu nilai ambang tertentu atau disebut dengan *threshold*. Fungsi step disebut juga dengan fungsi *threshold*.

- (3) Fungsi sigmoid

Terdapat dua jenis fungsi sigmoid yaitu fungsi sigmoid biner dan fungsi sigmoid bipolar. Fungsi sigmoid biner dinyatakan sebagai

$$f(x) = \frac{1}{1 + \exp[-x]}, \quad (3.3)$$

dengan

$$f'(x) = f(x)[1 - f(x)]. \quad (3.4)$$

Fungsi sigmoid bipolar dinyatakan sebagai

$$g(x) = \frac{2}{1 + \exp[-x]} - 1, \quad (3.5)$$

dengan

$$g'(x) = \frac{1}{2}[1 + g(x)][1 - g(x)]. \quad (3.6)$$

#### 4. BACKPROPAGATION

*Backpropagation* merupakan salah satu algoritma pelatihan terbimbing (*supervised*) pada *neural network* yang dicirikan dengan meminimalkan jumlah kuadrat eror dari output yang dihasilkan jaringan. Algoritma *Backpropagation* biasanya cocok digunakan pada *neural network* jenis *feedforward*.

Pelatihan pada jaringan dengan *backpropagation* melibatkan tiga fase, yaitu *feedforward* (fase maju), *backpropagation* (fase mundur), dan penyesuaian (memperbarui) bobot jaringan. Algoritma pelatihan *backpropagation* terdapat dalam Fausett[1].

#### 5. MODEL GENERALIZED LINEAR AUTOREGRESSION (GLAR)

Model *Generalized Linear Autoregression* (GLAR) pertama kali diperkenalkan oleh Shephard[15]. Model GLAR termasuk model linear yang menghubungkan variabel endogen dengan lag dari variabel endogen dan variabel eksogen. Model GLAR merupakan model VAR yang dinyatakan dalam bentuk yang lain [19].

Untuk melihat perbedaan model GLAR dan model VAR dapat dilihat pada proses berikut. Dari Persamaan (2.1) model VAR( $p$ ) dengan dua variabel endogen,  $y_1$  dan  $y_2$ , dengan memandang  $y_1$  sebagai  $y$  dengan lag order  $r$  dan  $y_2$  sebagai  $x$  dengan lag order  $s$ , diperoleh persamaan

$$\begin{aligned} y_t &= v + \sum_{l=1}^r a_l y_{t-l} + \sum_{m=1}^s b_m x_{t-m} + \varepsilon_t \\ x_t &= v' + \sum_{l=1}^r c_l y_{t-l} + \sum_{m=1}^s d_m x_{t-m} + \varepsilon_t' \end{aligned}$$

Didefinisikan  $L$  adalah operator lag yang berdistribusi random, dengan  $Ly_t = y_{t-1}$ ,  $L^2 y_t = y_{t-2}$ , dan seterusnya. Model umum GLAR untuk  $y_t$  [19] dinyatakan sebagai

$$y_t = v + A(L)y_{t-1} + B(L)x_{t-1} + \varepsilon_t \quad (5.1)$$

dengan

$$\begin{aligned} A(L) &= A_0 - A_1 L - A_2 L^2 - \dots - A_r L^r \text{ dan} \\ B(L) &= B_0 - B_1 L - B_2 L^2 - \dots - B_s L^s, \end{aligned}$$

merupakan lag order polinomial dari variabel endogen  $y$  dan variabel eksogen  $x$ ,  $y_t$  menyatakan nilai variabel endogen pada waktu ke- $(t)$ ,  $v$  sebagai konstanta,  $x_{t-1}$  menyatakan nilai dari variabel eksogen yang bersesuaian, dan  $\varepsilon_t$  merupakan eror pada waktu ke- $(t)$  yang diasumsikan berdistribusi independen dan identik dengan rata-rata nol dan variansi konstan,  $\varepsilon_t \sim IID(0, \sigma^2)$ . Pada pembahasan selanjutnya lag order  $r = s = p$ , dengan  $p$  merupakan lag order dari model GLAR dan dituliskan sebagai  $GLAR(p)$ .

**Prosedur Model GLAR.** Prosedur model GLAR tidak berbeda dengan prosedur metode Box-Jenkins [2]. Terdapat lima langkah prosedur model GLAR.

- (1) Menguji stasioneritas data, dengan uji *Augmented Dickey-Fuller* (ADF).
- (2) Spesifikasi model. Pemilihan lag model berdasarkan nilai AIC yang paling kecil.

$$AIC(p) = \log \det(\tilde{\Sigma}_{\mathbf{u}}(p)) + \frac{2}{T}pk^2, \quad (5.2)$$

dengan  $\tilde{\Sigma}_{\mathbf{u}}(p) = T^{-1} \sum_{t=1}^T \hat{\mathbf{u}}_t \hat{\mathbf{u}}_t'$  merupakan estimator untuk matriks varians kovarians eror untuk model lag ke- $p$ ,  $\hat{\mathbf{u}}_t'$  residual dari model VAR pada waktu ke- $t$ ,  $T$  ukuran sampel, dan  $k$  banyaknya variabel.

- (3) Estimasi parameter. Untuk mengestimasi parameter pada model GLAR, akan digunakan *ordinary least square* (OLS).

Estimasi model GLAR dengan OLS berdasarkan hasil estimasi VAR dengan MLS pada Persamaan (2.4).

Misalkan  $\mathbf{b} = \text{vec}(\mathbf{B}')$  dan  $b_j'$  merupakan baris ke- $j$  dari matriks  $\mathbf{B}$  pada Persamaan (2.2), dimana  $b_j$  memuat semua parameter dari persamaan ke- $j$ . Maka,  $\mathbf{b}' = (\mathbf{b}_1', \mathbf{b}_2', \dots, \mathbf{b}_k')$ . Selanjutnya, diberikan data runtun waktu untuk setiap variabel ke- $j$ ,  $\mathbf{y}_{(j)} = (y_{j1}, y_{j2}, \dots, y_{jT})$ , sehingga

$$\text{vec}(\mathbf{Y}') = \begin{bmatrix} \mathbf{y}_{(1)} \\ \vdots \\ \mathbf{y}_{(k)} \end{bmatrix},$$

dengan  $\mathbf{Y}$  mengacu pada Persamaan (2.3).

Model untuk persamaan variable ke- $j$

$$\mathbf{y}_{(j)} = \mathbf{Z}'\mathbf{b}_j + \varepsilon_{(j)}$$

dengan  $\varepsilon_{(j)} = (\varepsilon_{j1}, \varepsilon_{j2}, \dots, \varepsilon_{jT})$ . Untuk persamaan ke-1

$$\mathbf{y}_{(1)} = \mathbf{Z}'\mathbf{b}_1 + \varepsilon_{(1)}$$

dengan  $\varepsilon_{(1)} = (\varepsilon_{11}, \varepsilon_{12}, \dots, \varepsilon_{1T})$ . Model GLAR pada Persamaan (5.1) dapat dinyatakan sebagai

$$\mathbf{y} = \mathbf{Z}'\mathbf{b}_y + \varepsilon \quad (5.3)$$

dengan  $\mathbf{y} = (y_1, y_2, \dots, y_T)$ ,  $\mathbf{b}_y$  memuat semua parameter dari Persamaan (5.1), dan  $\varepsilon = (\varepsilon_1, \varepsilon_2, \dots, \varepsilon_T)$ . Sehingga, estimator OLS untuk Persamaan (5.3) adalah

$$\hat{\mathbf{b}}_y = (\mathbf{Z}\mathbf{Z}')^{-1}\mathbf{Z}\mathbf{y}. \quad (5.4)$$

- (4) Uji Diagnosa (*Diagnostic checking*). Uji Diagnosa dilakukan dengan uji Portmanteau [5]. Statistik uji yang digunakan

$$Q_h = T \sum_{j=1}^h \text{tr}(\widehat{\mathbf{C}}_j' \widehat{\mathbf{C}}_0^{-1} \widehat{\mathbf{C}}_j \widehat{\mathbf{C}}_0^{-1}), \quad (5.5)$$

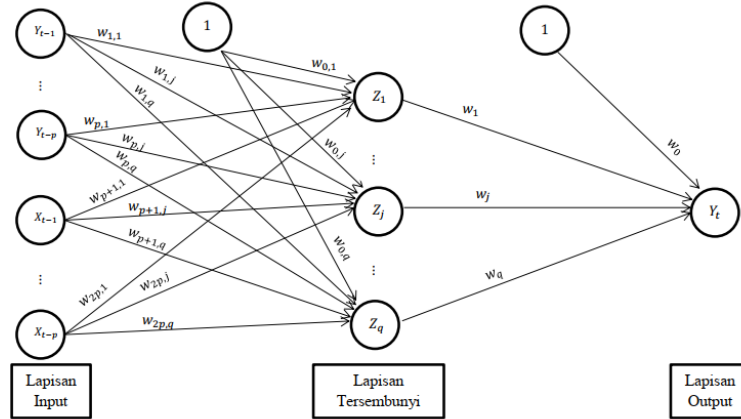
dengan  $\widehat{\mathbf{C}}_j = T^{-1} \sum_{t=i+1}^T \widehat{\mathbf{u}}_t \widehat{\mathbf{u}}_{t-i}'$ . Kriteria keputusan,  $H_0$  ditolak jika  $Q_h > \chi_{(k^2 h - k^2 p)}^2$ .

- (5) Peramalan menggunakan model.

## 6. ARTIFICIAL NEURAL NETWORK (ANN)

*Artificial neural Network* (ANN) merupakan salah satu model nonlinear. Menurut Khashei dan Bijari[12], terdapat tiga hal yang membedakan ANN sebagai model peramalan yaitu, ANN hanya membutuhkan sedikit asumsi prior pada model, ANN dapat melakukan generalisasi dari data sampel, dan ANN memiliki fungsi pendekatan yang universal.

Arsitektur ANN terdiri dari tiga lapisan yang secara berurutan yaitu lapisan input, lapisan tersembunyi, dan lapisan output. Pada setiap lapisan terdapat satu atau beberapa neuron yang setiap neuron terhubung dengan neuron pada lapisan berikutnya. Dalam pembahasan ini jenis jaringan yang digunakan adalah jenis *feedforward* pada data runtun waktu. Dimisalkan akan dibentuk jaringan untuk mengetahui hubungan antara variabel endogen  $Y_t$  dengan lag dari variabel endogen ( $Y_{t-1}, \dots, Y_{t-r}$ ) dan variabel eksogen ( $X_{t-1}, \dots, X_{t-s}$ ). Dalam pembahasan ini  $Y_t$  sebagai output dengan aktivasi  $y_t$ . Lag dari variabel endogen dan eksogen sebagai input dengan  $r = s = p$ , aktivasi input dinyatakan sebagai  $\mathbf{X} = (y_{t-1}, \dots, y_{t-p}, x_{t-1}, \dots, x_{t-p})$ . Arsitektur dari jaringan dari model ANN dengan satu lapisan tersembunyi dengan  $q$  neuron dapat dilihat pada gambar berikut.



GAMBAR 2. Arsitektur ANN  $2p - q - 1$



Secara matematis, arsitektur ANN pada Gambar 2 di atas dapat dinyatakan sebagai

$$y_t = f\left(w_0 + \sum_{j=1}^q w_j \cdot g\left(w_{0j} + \sum_{i=1}^p w_{ij} y_{t-i} + \sum_{i=p+1}^{2p} w_{ij} x_{t+p-i}\right)\right) + \varepsilon_t, \quad (6.1)$$

dengan

- $x_{t+p-i}$  : aktivasi input variabel eksogen  $X_t$  pada lag ke- $(i - p)$ , ( $i = p + 1, \dots, 2p$ );
- $y_{t-i}$  : aktivasi input variabel endogen  $Y_t$  pada lag ke- $i$ , ( $i = 1, \dots, p$ );
- $w_0$  : bobot bias neuron lapisan output;
- $w_j$  : bobot yang menghubungkan neuron lapisan tersembunyi ke- $j$  dengan neuron lapisan output ( $j = 1, \dots, q$ );
- $w_{0j}$  : bobot bias neuron lapisan tersembunyi ke- $j$  ( $j = 1, \dots, q$ );
- $w_{ij}$  : bobot yang menghubungkan neuron lapisan input ke- $i$  dengan neuron lapisan tersembunyi ke- $j$  ( $i = 1, \dots, 2p$  dan  $j = 1, \dots, q$ );
- $f$  : fungsi aktivasi neuron lapisan output;
- $g$  : fungsi aktivasi neuron lapisan tersembunyi;
- $\varepsilon_t$  : error dari  $y_t$ .

Model di atas dapat dinyatakan sebagai

$$y_t = f(y_{t-1}, \dots, y_{t-p}, x_{t-1}, \dots, x_{t-p}, \mathbf{w}), \quad (6.2)$$

dengan  $\mathbf{w}$  adalah parameter model yang memuat semua bobot pada arsitektur ANN ( $w_{ij}, w_{0j}, w_j, w_0; i = 1, \dots, 2p$  dan  $j = 1, \dots, q$ ).

Prosedur pembentukan ANN terdiri dari enam langkah sebagai berikut.

- (1) Normalisasi data.
- (2) Menentukan arsitektur dan parameter jaringan. Diberikan pasangan input dan target, yaitu  $\mathbf{X} = (Y_{t-1}, \dots, Y_{t-p}, X_{t-1}, \dots, X_{t-p})$  dan  $t = Y_t$  sebanyak  $T$  data pelatihan. Parameter jaringan ANN, yaitu jumlah neuron tersembunyi  $q$ , *learning rate*  $\alpha$ , banyaknya iterasi  $M$ , target error  $e$ . Penentuan arsitektur ANN dilakukan dengan *trail and error*.
- (3) Inisiasi semua bobot secara acak, yaitu  $w_{ij}, w_{0j}, w_j, w_0; (i = 1, \dots, 2p$  dan  $j = 1, \dots, q)$ .
- (4) Melakukan pelatihan *training*. Pelatihan dilakukan dengan algoritma *backpropagation*. Hasil dari pelatihan adalah arsitektur ANN yang digunakan untuk simulasi pengujian dengan parameter model  $\mathbf{w}$ . Pembaruan bobot untuk  $w_{ij}$  dinyatakan

$$w_{ij}^{(k)} = w_{ij}^{(k-1)} + \Delta w_{ij} \quad (6.3)$$

dengan,

$$\Delta w_{ij} = -\alpha \frac{\partial E}{\partial w_{ij}}. \quad (6.4)$$

$E$  merupakan jumlah kuadrat eror, yang dinyatakan sebagai

$$E = \frac{1}{2}(t - \hat{y}_t)^2.$$

Pembaruan bobot ANN  $w_{ij}$ ,  $w_{0j}$ ,  $w_j$  dan  $w_0$  berdasarkan model pada Persamaan (6.1) adalah sebagai berikut.

Pembaruan bobot untuk  $w_0$

$$\Delta w_0 = \alpha(t - \hat{y}_t)f'(Y_t).$$

Pembaruan bobot untuk  $w_j$

$$\Delta w_j = \alpha(t - \hat{y}_t)f'(Y_t)g(Z_j).$$

Pembaruan bobot untuk  $w_{0j}$

$$\Delta w_{0j} = \alpha(t - \hat{y}_t)f'(Y_t) \sum_{j=1}^q w_j g'(Z_j).$$

Pembaruan bobot untuk  $w_{ij}$

$$\Delta w_{ij} = \alpha(t - \hat{y}_t)f'(Y_t) \sum_{j=1}^q w_j g'(Z_j)y_{t-i} \quad \text{untuk } i = 1, \dots, p$$

dan

$$\Delta w_{ij} = \alpha(t - \hat{y}_t)f'(Y_t) \sum_{j=1}^q w_j g'(Z_j)x_{t+p-i} \quad \text{untuk } i = p + 1, \dots, 2p$$

dengan  $\alpha$  merupakan *learning rate*.

- (5) Memilih model, berdasarkan nilai *mean square erroe* (MSE) terkecil maupun kecepatan untuk mencapai target eror yang ditentukan.
- (6) Melakukan peramalan dengan data tes yang telah disiapkan.

## 7. METODE *HYBRID* GLARANN

Metode *hybrid* GLARANN merupakan gabungan dari model GLAR yang termasuk model linear dan ANN yang digolongkan dalam model nonlinear. Gagasan metode GLARANN adalah menggunakan kelebihan dari masing-masing model, yaitu model GLAR dalam mendeteksi pola linear dan ANN dalam mendeteksi pola nonlinear pada data runtun waktu.

Dalam pembahasan metode *hybrid* GLARANN terdapat beberapa batasan yaitu, pola pada data runtun waktu dapat dipisah menjadi komponen linear dan komponen nonlinear, residual pada eror model GLAR diasumsikan hanya memuat hubungan nonlinear, dan hubungan antara komponen linear dan nonlinear adalah penjumlahan.

**Prosedur Metode hybrid GLARANN.** Metode *hybrid* GLARANN dibagi menjadi dua tahap. Tahap pertama menggunakan model GLAR untuk mendapatkan komponen linear. Tahap kedua, menggunakan komponen eror dari model GLAR sebagai input ANN untuk memperoleh komponen nonlinear. Selanjutnya dilakukan penjumlahan antara komponen linear dan komponen nonlinear. Berikut prosedur dari metode *hybrid* GLARANN.

- (1) Membangun model GLAR. Menggunakan model GLAR untuk mendapatkan komponen linear, dinotasikan sebagai  $\hat{L}_t$ . Komponen linear dapat dinyatakan sebagai

$$\hat{L}_t = \hat{v} + \hat{A}(L)y_{t-1} + \hat{B}(L)x_{t-1}, \quad (7.1)$$

dengan  $\hat{L}_t$  menyatakan hasil estimasi untuk variabel endogen  $y_t$ ,  $\hat{v}$  sebagai konstanta,  $\hat{A}(L)$  dan  $\hat{B}(L)$  merupakan hasil estimasi lag order polinomial sebanyak  $p$  dari variabel  $y$  dan  $x$ .

- (2) Menghitung residual model GLAR. Dari model GLAR kemudian akan dihitung residual dari  $y_t$  yaitu  $e_t = \hat{L}_t - y_t$ , dengan  $e_t$  menyatakan residual dari variabel endogen  $y_t$ . Selanjutnya, sebanyak  $p$  lag order dari  $e_t$  yaitu  $(e_{t-1}, \dots, e_{t-p})$  akan digunakan sebagai input ANN untuk memperoleh komponen nonlinear.
- (3) Uji nonlinearitas residual model GLAR. Digunakan uji Terasvirta. Hipotesis uji nonlinearitas dinyatakan sebagai berikut.

$H_0$  : Hubungan antara lag ke- $p$  dengan data ke- $t$  bersifat linear.

$H_1$  : Hubungan antara lag ke- $p$  dengan data ke- $t$  bersifat non-linear.

Terdapat dua pendekatan statistik uji, yaitu uji  $\chi^2$  dan uji  $F$ . Prosedur uji nonlinearitas terdapat pada [16].

- (4) Membangun arsitektur ANN. Langkah berikutnya adalah dengan sebanyak  $p$  input lag order dari  $e_t$  yaitu  $(e_{t-1}, \dots, e_{t-p})$  dan target  $e_t$  dilakukan prosedur ANN untuk memperoleh komponen nonlinear  $\hat{N}_t$ . Secara matematis komponen nonlinear pada waktu ke- $t$  dinyatakan sebagai

$$\hat{N}_t = f(e_{t-1}, \dots, e_{t-p}), \quad (7.2)$$

dengan  $f$  merupakan suatu fungsi aktivasi output pada ANN.

- (5) Menghitung output metode *hybrid* GLARANN. Output metode *hybrid* GLARANN diperoleh dari penjumlahan komponen linear hasil dari metode GLAR dan komponen nonlinear hasil dari ANN,

$$\hat{y}_t = \hat{L}_t + \hat{N}_t. \quad (7.3)$$

$\hat{y}_t$  menyatakan output dari metode *hybrid* GLARANN pada waktu ke- $t$ .

Hasil dari  $\hat{y}_t$  selanjutnya dilakukan evaluasi untuk melihat akurasi dari metode dengan kriteria yang telah ditentukan.

## 8. KRITERIA EVALUASI HASIL PERAMALAN

Berikut empat jenis kriteria evaluasi keakuratan hasil peramalan sebagai perbandingan.

- (1) *Normalized Mean Square Error* (NMSE). Diberikan sebanyak  $T$  pasangan nilai sebenarnya dan nilai hasil peramalan,  $y_t$  dan  $\hat{y}_t$ . NMSE merupakan normalisasi dari MSE, yaitu membagi MSE dengan variansinya, dinyatakan sebagai

$$NMSE = \frac{\sum_{t=1}^T (y_t - \hat{y}_t)^2}{\sum_{t=1}^T (y_t - \bar{y})^2} = \frac{1}{\sigma^2} \frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_t)^2, \quad (8.1)$$

dengan  $\sigma^2$  dan  $\bar{y}$  merupakan variansi dan rata-rata dari  $y_t$ ,  $t = 1, 2, \dots, T$ .

- (2) *Root Mean Square Error* (RMSE), merupakan akar dari MSE, dinyatakan sebagai

$$RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_t)^2}. \quad (8.2)$$

- (3) *Mean Absolute Error* (MAE), dinyatakan sebagai

$$MAE = \frac{1}{T} \sum_{t=1}^T |y_t - \hat{y}_t|. \quad (8.3)$$


- (4) *Mean Absolute Percentage Error* (MAPE), dinyatakan sebagai

$$MAPE = \frac{1}{T} \sum_{t=1}^T \left| \frac{y_t - \hat{y}_t}{y_t} \right|. \quad (8.4)$$

## 9. APLIKASI MODEL *HYBRID GLARANN*

Pada bagian ini dilakukan studi kasus pada peramalan nilai tukar rupiah (IDR) terhadap beberapa mata uang asing, yaitu dollar Amerika (USD), euro (EUR), yen Jepang (JPY), dollar Hongkong (HKD), dollar Australia (AUD), dan dollar Singapura (SGD). Data diakses dari laman <https://www.bi.go.id/id/moneter/kalkulator-kurs/>. Kurs yang digunakan adalah kurs tengah secara bulanan. Nilai kurs yang digunakan adalah 1, kecuali JPY menggunakan nilai kurs 100 sebagaimana yang digunakan oleh Bank Indonesia. Selanjutnya, variabel di atas tersebut disebut dengan variabel endogen. Variabel eksogen model GLAR menggunakan data nilai ekspor (bulanan dengan satuan juta USD) yang diakses dari Badan Pusat Statistik (BPS) pada laman <https://www.bps.go.id/>. Data yang digunakan dari Januari 2007 sampai dengan Desember 2018 (144 sampel). Data tersebut dibagi menjadi dua, yaitu data pelatihan, Januari 2007 sampai Desember 2016 (120 sampel), dan data pengujian, Januari 2017 sampai Desember 2018 (24 sampel).

9.1. **Kurs AUD.** Pada tahap pertama menggunakan model GLAR, data kurs AUD stasioner pada *differencing* pertama dengan lag signifikan model sebanyak 2 lag, sehingga modelnya dinyatakan sebagai GLAR(2). Pada tahap selanjutnya, dipilih 2 lag dari residual hasil peramalan kurs AUD menggunakan model GLAR(2) sebagai input ANN. Hasil uji nonlinearitas menunjukkan lag 1 ( $p\text{-value}=0,0192$ ) dan lag 2 ( $p\text{-value}=0,0009$ ) memiliki hubungan nonlinear terhadap residual kurs AUD. Dengan *trial and error* diperoleh arsitektur terbaik residual AUD adalah 2-10-1 dengan  $\alpha = 0,1$ . Hasil dari tahap pertama dan kedua dijumlahkan sebagai output dari metode *hybrid* GLARANN. Untuk peramalan kurs AUD menggunakan ANN diperoleh arsitektur terbaik 4-11-1 dengan  $\alpha = 0,2$ . Perbandingan hasil peramalan kurs AUD terhadap nilai aktual dapat dilihat pada Gambar 3. Evaluasi hasil peramalan kurs AUD dapat dilihat pada Tabel 1.




GAMBAR 3. Perbandingan Hasil Peramalan Kurs AUD terhadap Nilai Aktual

Model	RMSE	MAE	MAPE	NMSE
GLAR(2)	138,3053	113,0801	1,0911	0,2764
GLARANN	114,7705	97,5181	0,9370	0,1903
ANN (4-11-1)	169,0155	130,4762	1,2495	0,4128

TABEL 1. Evaluasi Hasil Peramalan Kurs AUD.

Tabel 1 menunjukkan bahwa metode *hybrid* GLARANN lebih efektif dibanding ANN maupun GLAR. Hal tersebut dapat dilihat dari nilai RMSE, MAE, MAPE, dan NMSE yang paling kecil. Sedangkan, ANN tidak lebih efektif daripada GLAR. Hal tersebut menandakan bahwa ANN berhasil menangkap pola nonlinear pada residual kurs AUD dengan baik.

9.2. **Kurs EUR.** Pada pembentukan model GLAR data kurs EUR didapatkan, data stasioner pada *differencing* pertama dengan lag signifikan model sebanyak 2 lag, sehingga modelnya dinyatakan sebagai GLAR(2). Pada tahap selanjutnya, dipilih 2 lag dari residual hasil peramalan kurs EUR menggunakan model GLAR(2) sebagai input ANN. Hasil uji nonlinearitas menunjukkan lag 1 (p-value=0,4334) dan lag 2 (p-value=0,5697) memiliki hubungan linear terhadap residual kurs EUR. Arsitektur ANN terbaik untuk residual EUR adalah 2-13-1 dengan  $\alpha = 0,1$ . Hasil dari model GLAR dan ANN residual kurs EUR dijumlahkan sebagai output dari metode *hybrid* GLARANN. Untuk peramalan kurs EUR menggunakan ANN diperoleh arsitektur terbaik 4-12-1 dengan  $\alpha = 0,2$ . Hasil peramalan dan nilai aktual kurs EUR dapat dilihat pada Gambar 4. Evaluasi hasil peramalan kurs EUR dapat dilihat pada Tabel 2.



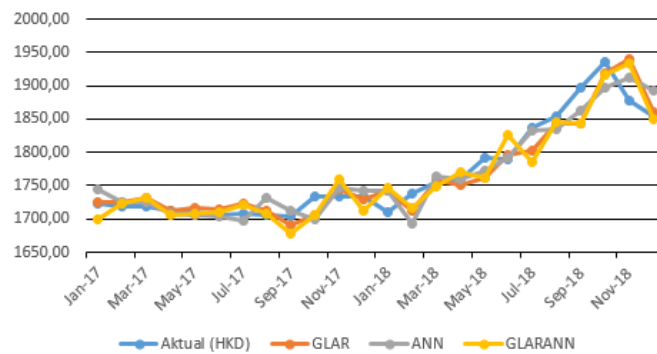
GAMBAR 4. Perbandingan Hasil Peramalan Kurs EUR terhadap Nilai Aktual

TABEL 2. Evaluasi Hasil Peramalan Kurs EUR.

Model	RMSE	MAE	MAPE	NMSE
GLAR(2)	261,1006	188,0371	1,1638	0,0642
GLARANN	292,4516	225,2223	1,4013	0,0806
ANN (4-12-1)	593,4406	469,4722	2,9364	0,3318

Tabel 2 menunjukkan bahwa model GLAR adalah model paling efektif dalam meramalkan kurs EUR. Sedangkan, metode *hybrid* GLARANN lebih efektif daripada ANN. Hal tersebut bisa jadi dikarenakan residual kurs EUR menunjukkan hubungan linear, sehingga ANN tidak efektif untuk menangkap pola nonlinear pada data residual kurs EUR.

9.3. **Kurs HKD.** Pada tahap pertama menggunakan model GLAR, data kurs HKD stasioner pada *differencing* pertama dengan lag signifikan model sebanyak 3 lag, sehingga modelnya dinyatakan sebagai GLAR(3). Pada tahap selanjutnya, dipilih 3 lag dari residual hasil peramalan kurs HKD menggunakan model GLAR(3) sebagai input ANN. Hasil uji nonlinearitas pada lag yang bersesuaian menunjukkan lag 1 (p-value=0,0003), lag 2 (p-value=0,0002), dan lag 3 (p-value=0,0001) memiliki hubungan nonlinear terhadap residual kurs HKD. Hasil *trial and error* diperoleh arsitektur ANN terbaik untuk residual HKD adalah 3-14-1 dengan  $\alpha = 0,1$ . Hasil dari tahap pertama dan kedua dijumlahkan sebagai output dari metode *hybrid* GLARANN. Untuk peramalan kurs HKD menggunakan ANN diperoleh arsitektur terbaik 6-119-1 dengan  $\alpha = 0,1$ . Hasil peramalan dan nilai aktual kurs HKD dapat dilihat pada Gambar 5. Evaluasi hasil peramalan kurs HKD dapat dilihat pada Tabel 3.



GAMBAR 5. Perbandingan Hasil Peramalan Kurs HKD terhadap Nilai Aktual


Model	RMSE	MAE	MAPE	NMSE
GLAR(3)	23,0240	16,9400	0,9426	0,1101
GLARANN	26,5883	21,1088	1,1799	0,1469
ANN (6-19-1)	22,5134	17,8154	0,9958	0,1053

TABEL 3. Evaluasi Hasil Peramalan Kurs HKD.

Evaluasi hasil peramalan pada Tabel 3 di atas menunjukkan bahwa metode *hybrid* GLARANN tidak efektif dalam peramalan kurs HKD, dengan nilai RSME, MAE, MAPE, dan NMSE dibandingkan model yang lain. Peramalan dengan ANN menunjukkan hasil yang efektif daripada model GLAR berdasarkan nilai RMSE (22,5234) dan NMSE (0,1053). Akan tetapi, berdasarkan nilai MAE dan MAPE, model GLAR lebih efektif daripada ANN. Hal ini dapat saja terjadi, mengacu dari pernyataan Yu et al[6], bahwa pendekatan ANN dalam peramalan mata uang tidak selalu lebih baik. Terdapat tiga kemungkinan hasil kesimpulan, yaitu (1) hasil peramalan ANN lebih baik daripada model yang lain, (2) hasil peramalan ANN lebih buruk daripada model

yang lain, dan (3) hasil peramalan ANN campuran, kadang lebih baik dan kadang lebih buruk pada kondisi yang lain.

9.4. **Kurs JPY.** Pada tahap pertama menggunakan model GLAR, data kurs JPY stasioner pada *differencing* pertama dengan lag signifikan model sebanyak 2 lag, sehingga modelnya dinyatakan sebagai GLAR(2). Pada tahap selanjutnya, dipilih 2 lag dari residual hasil peramalan kurs JPY menggunakan model GLAR(2) sebagai input ANN. Hasil uji nonlinearitas menunjukkan lag 1 ( $p\text{-value}=0,0973$ ) memiliki hubungan linear terhadap residual kurs JPY, sedangkan lag 2 ( $p\text{-value}=0,002$ ) memiliki hubungan non-linear. Arsitektur ANN terbaik untuk residual JPY adalah 2-15-1 dengan  $\alpha = 0, 1$ . Hasil dari tahap pertama dan kedua dijumlahkan sebagai output metode *hybrid* GLARANN. Untuk peramalan kurs JPY menggunakan ANN diperoleh arsitektur terbaik 4-13-1 dengan  $\alpha = 0, 2$ . Hasil peramalan kurs JPY terhadap nilai aktual dapat dilihat pada Gambar 6. Evaluasi hasil peramalan kurs JPY dapat dilihat pada Tabel 4.



GAMBAR 6. Perbandingan Hasil Peramalan Kurs JPY terhadap Nilai Aktual


Tabel 4 menunjukkan bahwa, model GLAR adalah model yang lebih efektif dalam peramalan kurs JPY dilihat dari RMSE, MAE, MAPE, dan NMSE yang lebih kecil dibandingkan pada metode *hybrid* GLARANN dan ANN. Metode *hybrid* GLARANN lebih efektif daripada ditinjau dari nilai RMSE dan NMSE, sedangkan berdasarkan nilai MAE dan MAPE, ANN lebih efektif dalam peramalan kurs JPY daripada metode *hybrid* GLARANN.

Model	RMSE	MAE	MAPE	NMSE
GLAR(2)	248,0011	186,9607	1,5184	0,2088
GLARANN	298,0673	240,1488	1,9563	0,3016
ANN (4-13-1)	323,0960	207,9452	1,6756	0,3543

TABEL 4. Evaluasi Hasil Peramalan Kurs JPY.



9.5. **Kurs SGD.** Pada tahap pertama menggunakan model GLAR, data kurs SGD stasioner pada *differencing* pertama dengan lag signifikan model sebanyak 2 lag, sehingga modelnya dinyatakan sebagai GLAR(2). Pada tahap selanjutnya, dipilih 2 lag dari residual hasil peramalan kurs SGD menggunakan model GLAR(2) sebagai input ANN. Hasil uji nonlinearitas menunjukkan lag 1 ( $p\text{-value}=0,006$ ) dan lag 2 ( $p\text{-value}=0,0185$ ) memiliki hubungan nonlinear terhadap residual kurs SGD. Arsitektur terbaik residual SGD adalah 2-13-1 dengan  $\alpha = 0,1$ . Hasil dari tahap pertama dan kedua dijumlahkan sebagai output metode *hybrid* GLARANN. Untuk peramalan kurs SGD menggunakan ANN diperoleh arsitektur terbaik 4-13-1 dengan  $\alpha = 0,2$ . Hasil peramalan kurs SGD terhadap nilai aktual dapat dilihat pada Gambar 7. Evaluasi hasil peramalan kurs SGD dapat dilihat pada Tabel 5.



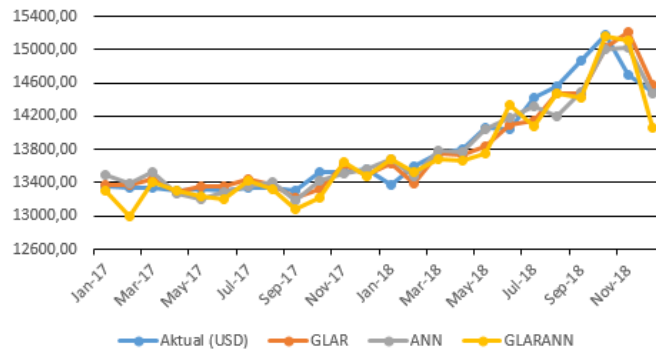
GAMBAR 7. Perbandingan Hasil Peramalan Kurs SGD terhadap Nilai Aktual

Berdasarkan Tabel 4, menunjukkan bahwa ANN merupakan model yang paling efektif dalam peramalan kurs SGD dilihat dari RMSE, MAE, MAPE, dan NMSE yang lebih kecil dibandingkan pada metode *hybrid* GLARANN dan model GLAR. Nilai RMSE, MAE, MAPE, dan NMSE untuk metode *hybrid* GLARANN lebih besar daripada model GLAR. Hal tersebut mengindikasikan pola nonlinear pada residual SGD tidak dapat ditangkap ANN dengan baik.

Model	RMSE	MAE	MAPE	NMSE
GLAR(2)	100,1320	68,6313	0,6617	0,0422
GLARANN	141,2002	89,5936	0,8619	0,0839
ANN (4-13-1)	72,7653	58,0712	0,5682	0,0223

TABEL 5. Evaluasi Hasil Peramalan Kurs SGD.

9.6. **Kurs USD.** Pada tahap pertama menggunakan model GLAR, data kurs USD stasioner pada *differencing* pertama dengan lag signifikan model sebanyak 3 lag, sehingga modelnya dinyatakan sebagai GLAR(3). Pada tahap selanjutnya, dipilih 3 lag dari residual hasil peramalan kurs USD menggunakan model GLAR(3) sebagai input ANN. Hasil uji nonlinearitas pada lag yang bersesuaian menunjukkan lag 1 (p-value=0,0035), lag 2 (p-value=0,0002), dan lag 3 (p-value=0,0004) memiliki hubungan nonlinear terhadap residual kurs USD. Hasil *trial and error* diperoleh arsitektur ANN terbaik untuk residual USD adalah 3-14-1 dengan  $\alpha = 0,1$ . Hasil dari tahap pertama dan kedua dijumlahkan sebagai output dari model *hybrid* GLARANN. Untuk peramalan kurs USD menggunakan ANN diperoleh arsitektur terbaik 6-18-1 dengan  $\alpha = 0,2$ . Hasil peramalan kurs USD terhadap nilai aktual dapat dilihat pada Gambar 8. Evaluasi hasil peramalan kurs USD dapat dilihat pada Tabel 6.



GAMBAR 8. Perbandingan Hasil Peramalan Kurs USD terhadap Nilai Aktual

Model	RMSE	MAE	MAPE	NMSE
GLAR(3)	179,4798	129,8730	0,9215	0,0974
GLARANN	232,7722	183,4318	1,3126	0,1639
ANN (6-18-1)	164,2908	118,4708	0,8433	0,0816

TABEL 6. Evaluasi Hasil Peramalan Kurs USD.

Berdasarkan Tabel 6 di atas, menunjukkan bahwa metode *hybrid* GLARAN tidak lebih efektif dari model GLAR dan ANN. Dalam hal ini, ANN merupakan model yang paling efektif untuk peramalan kurs USD yaitu dengan RMSE (164,2908), MAE (118,4708), MAPE (0,8433), dan NMSE (0,0816), lebih kecil dibanding model yang lain.

## 10. PENUTUP

10.1. **Kesimpulan.** Berdasarkan pembahasan di atas, dapat diambil kesimpulan sebagai berikut.:

- (1) Metode *hybrid* GLARANN adalah gabungan antara metode GLAR dan ANN. Prosedur metode *hybrid* GLARANN adalah sebagai berikut.
  - (a) Membangun model GLAR untuk memperoleh komponen linear ( $\hat{L}$ ).
  - (b) Menghitung residual dari model GLAR.
  - (c) Uji nonlinearitas residual model GLAR terhadap lag yang bersesuaian.
  - (d) Membangun arsitektur ANN untuk memperoleh komponen nonlinear ( $\hat{N}$ ).
  - (e) Menghitung output metode *hybrid* GLARANN, yaitu dengan menjumlahkan komponen linear ( $\hat{L}$ ) dan komponen nonlinear ( $\hat{N}$ ) yang dinyatakan sebagai

$$\hat{y}_t = \hat{L}_t + \hat{N}_t.$$

- (2) Metode *hybrid* GLARANN diaplikasikan pada peramalan nilai tukar rupiah (IDR) terhadap beberapa mata uang asing, yaitu dollar Amerika (USD), euro (EUR), yen Jepang (JPY), dollar Hongkong (HKD), dollar Australia (AUD), dan dollar Singapura (SGD), dengan nilai ekspor sebagai variabel eksogen.
- (3) Metode *hybrid* GLARANN menunjukkan hasil yang efektif pada peramalan kurs AUD daripada metode GLAR dan ANN. Sebaliknya, metode *hybrid* GLARANN tidak efektif pada peramalan kurs HKD, kurs SGD, dan kurs USD. Pada peramalan kurs EUR dan kurs JPY, metode GLAR merupakan metode yang paling efektif. Sedangkan, metode *hybrid* GLARANN hanya lebih efektif daripada ANN berdasarkan RMSE dan NMSE. Pada kurs EUR dan kurs JPY terdapat residual yang memiliki pola hubungan linear pada lag yang bersesuaian.

10.2. **Saran.** Metode *hybrid* GLARANN yang dibahas dalam penelitian ini menggunakan asumsi penjumlahan antara komponen linear hasil dari model GLAR dan komponen nonlinear hasil dari pengolahan residual ANN. Untuk pengembangan lebih lanjut, dapat dilakukan perubahan asumsi dengan menjadikan metode GLAR sebagai metode penentuan input untuk ANN dengan input berupa variabel endogen dan residual variabel endogen. Selain itu, aplikasi metode *hybrid* GLARANN dapat dilakukan pada data yang lain atau menambah jumlah variabel eksogen.

## Referensi

- [1] Fausett, L., *Fundamentals of Neural Networks Architectures, Algorithms, and Application*, Prentice Hall, New Jersey, 1994.
- [2] Gujarati, D.N., *Basic Econometrics Fourth Edition*, The McGraw-Hill Company, New York, 2003.
- [3] Haykin, S., *Neural Networks and Learning Machines*, Pearson prentice Hall, New Jersey, 2009.
- [4] Lütkepohl, H., *Introduction to Multiple Time Series Analysis*, Springer-Verlag Berlin Heidelberg, New York, 1991.
- [5] Lütkepohl, H., dan Krätzig, M., *Applied Time Series Econometrics*, Cambridge University Press, New York, 2004.

- [6] Yu, L., Wang, S., dan Lai, K. K., *Foreign-Exchange-Rate Forecasting With Artificial Neural Networks*, Springer Science+Business Media, New York., 2007.
- [7] Abdulkadir, S. J., Suet, P. Y., Maran, M., dan Fong, W. L., Hybridization of Ensemble Kalman Filter and Non-linear Autoregressive Neural Network for Financial Forecasting, *Springer International Publishing Switzerland*, 72-81, 2014.
- [8] Carriero, A., Kapetanios, G., dan Marcellino, M., Forecasting Exchange Rates With A Large Bayesian VAR, *International Journal of Forecasting*, 25, 400-417, 2009.
- [9] De Matos, G., Neural Networks for Forecasting Exchange Rate, *Thesis*, The University of Manitoba, Canada, 1994.
- [10] El Shazly, M.R. dan El Shazly, H.E., Forecasting Currency Prices Using a Genetically Evolved Neural Network Architecture, *International Review of Financial Analysis*, 8(1), 67-82, 1999.
- [11] Galeshchuk, S., Neural Networks Performance in Exchange Rate Prediction, *Neurocomputing*, 172, 446-452, 2016.
- [12] Khashei, M. dan Bijari, M., An Artificial Neural Network ( $p, d, q$ ) Model for Timeseries Forecasting, *Expert Systems with Applications*, 37, 479-489, 2010.
- [13] Khashei, M., Mehdi B., dan Gholam, A. R. A., Hybridization of Autoregressive Integrated Moving Average (ARIMA) with Probabilistic Neural Networks (PNNs), *Computers and Industrial Engineering*, 63, 37-45, 2012.
- [14] Meese, R. dan Rogoff, K., Empirical Exchange Rate Models of The Seventies: Do They Fit Out of Sample?, *Journal of International Economics*, 14, 3-24, 1983.
- [15] Shephard, N., Generalized Linear Autoregressions, *Economics Working Paper*, 8, Nuffield College, Oxford, 1985.
- [16] Suhartono, Feedforward Neural Network untuk Pemodelan Time Series, *Disertasi*, Universitas Gadjah Mada, 2007.
- [17] Wang, J. J., Jian, Z. W., Zhe, G. Z., dan Shu, P. G., Stock Index Forecasting Based on Hybrid Model, *Omega*, 40, 758-766, 2012.
- [18] Wu, B., Model-Free Forecasting for Nonlinear Time Series (with Application to Exchange Rates), *Computational Statistics and Data Analysis*, 19, 433-459, 1995.
- [19] Yu, L., Wang, S., dan Lai, K. K., A Novel Nonlinear Ensemble Forecasting Model Incorporating GLAR and ANN For Foreign Exchange Rates, *Computers and Operations Research*, 32, 2523-2541, 2005.
- [20] Zhang, G.P., Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model, *Neurocomputing*, 50, 159-175, 2003.

YOGYA ARDI WINATA\* (Penulis Korespondensi)

Departemen Matematika, Fakultas MIPA, Universitas Gadjah Mada, Indonesia.  
yogya.ardi.w@mail.ugm.ac.id

SUBANAR

Departemen Matematika, Fakultas MIPA, Universitas Gadjah Mada, Indonesia.  
subanar@ugm.ac.id