

PREDIKSI *INFLOW* DAN *OUTFLOW* UANG KARTAL DI PROVINSI BALI DENGAN METODE *NEURO-FUZZY*

I Kadek Mentik Yusmantara^{1§}, G. K. Gandhiadi², Luh Putu Ida Harini³

¹Program Studi Matematika, Fakultas MIPA – Universitas Udayana [Email: mentikyusmantara@gmail.com]

²Program Studi Matematika, Fakultas MIPA – Universitas Udayana [Email: gandhiadi@unud.ac.id]

³Program Studi Matematika, Fakultas MIPA – Universitas Udayana [Email: ballidah@unud.ac.id]

[§]Corresponding Author

ABSTRACT

In this paper, we present a novel approach to data-driven neuro-fuzzy modeling, which aims to create accurate monthly inflow and outflow forecast of money (M0) in Bali Province. The data is monthly time series included some religious ceremony identification variables and a monthly dummy variable from January 2011 to March 2019. Well known, Bali Province has unique cultures, the only one province which Hinduism majority religion in Indonesia, and listed as top tourism destination in the world. The neuro-fuzzy models were created using ANFIS architecture and sliding window time series analysis, then simulated using walk forward validation, interpreted using MAPE, and NRMSE. Based on the simulation of the last 24 months, the model of inflow obtained MAPE 23.33% (worth considering) and NRMSE 18.68% (accurate). Meanwhile, the model of outflow obtained MAPE 19.24% (accurate) and NRMSE 8.71% (very accurate). These models and their pieces of information could assist the central bank in Bali Province to prepare cash for money (M0) outflow and managed technic for counting money (M0) inflow.

Keywords: *forecast, inflow and outflow, money, neuro-fuzzy, religious*

1. PENDAHULUAN

Inflow dan *outflow* uang kartal (M0) merupakan dua indikator peredaran uang (M1) di tingkat wilayah. Transaksi penyimpanan uang kartal masyarakat dan perbankan ke bank sentral disebut *inflow* uang kartal, sedangkan transaksi penarikan uang kartal masyarakat dan perbankan dari bank sentral disebut *outflow* uang kartal. Sebagai indikator peredaran uang di tingkat wilayah, *inflow* dan *outflow* turut memengaruhi keberlangsungan sistem pembayaran pada sektor rumah tangga, kestabilan perekonomian, proses penciptaan uang, beserta *clean money policy*. Prediksi peredaran uang yang menjadi agenda bulanan bank sentral dan peserta operasi moneter untuk mendukung kegiatan transaksi operasi pasar terbuka merupakan salah satu upaya untuk menjaga kestabilan uang beredar (Bank Indonesia, 2013).

Berdasarkan data penduduk menurut agama tahun 2019 yang diperoleh langsung dari kantor Perwakilan Wilayah Kementerian Agama Provinsi Bali terdapat 85,29% penduduk

Hindu; 12,08% penduduk Islam; 0,7% penduduk Budha; 1,07% penduduk Kristen; 0,86% penduduk Katolik; dan 0,02% penduduk Konghucu dari 4.592.853 penduduk Provinsi Bali. Sehingga dapat diketahui perayaan hari raya agama Hindu dirayakan oleh sebagian besar penduduk provinsi Bali. Selain itu aktivitas masyarakat Provinsi Bali dapat dipengaruhi oleh hari raya Idul Fitri karena termasuk dalam hari libur nasional dan merupakan hari raya yang dirayakan oleh hampir sebagian besar masyarakat selain Hindu. Perbedaan karakteristik keagamaan di Provinsi Bali dibandingkan Provinsi lainnya di Indonesia memerlukan suatu model khusus yang dapat memprediksi aliran *inflow* dan *outflow* uang kartal. Berdasarkan pertimbangan pengaruh hari raya dan pola bulanan dapat dilakukan suatu studi untuk membuat model prediksi *inflow* dan *outflow* uang kartal di Provinsi Bali.

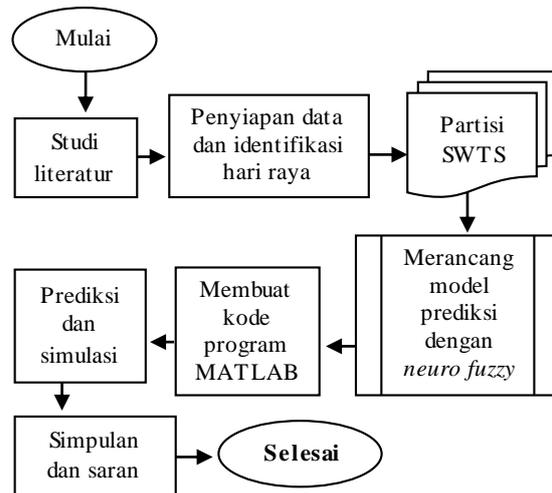
Neuro-fuzzy merupakan salah satu metode yang dapat digunakan untuk membentuk model *inflow* dan *outflow* uang kartal sebagai gabungan dari metode *neural network* dan

logika *fuzzy*. *Neural network* merupakan salah satu metode yang dapat digunakan untuk memprediksi kasus-kasus deret waktu. *Neural network* yang menggunakan arsitektur standar *multilayer perceptron* untuk pemodelan berbasis data dengan banyak variabel sering menyajikan konvergensi *error* yang tidak stabil, sehingga pemilihan jumlah iterasi pembelajaran (*epoch*) pada arsitektur *multilayer perceptron* sangat menentukan keakuratan proses pembelajaran. Salah satu sistem *neuro-fuzzy* yang dapat dijadikan alternatif yaitu *adaptive neural fuzzy inference system* (ANFIS) adalah sistem yang menggunakan *multi-layer feedforward network* dengan metode pembelajaran terawasi untuk membuat model berdasarkan sistem *fuzzy* Tagaki-Sugeno. ANFIS dapat memberikan konvergensi *error* yang lebih stabil untuk kompleksitas jaringan yang sama, sehingga keakuratan proses pembelajaran dapat terjaga dengan lebih baik karena perbedaan konvergensi absolut lebih stabil dan mengecil mendekati konvergensi *error*-nya (Navarro, *et al.*, 2013).

Studi ini bertujuan untuk membentuk pendekatan baru menggunakan identifikasi hari raya dan pola bulanan dalam pemodelan *neuro-fuzzy* berbasis data, yang bertujuan untuk membuat prediksi *inflow* dan *outflow* uang kartal bulanan yang akurat di Provinsi Bali. Hasil studi ini diharapkan dapat membantu perbankan khususnya bank sentral memajemen aliran uang kartal dan sebagai referensi terkait menjaga kestabilan uang beredar.

2. METODE PENELITIAN

Data yang digunakan dalam studi ini adalah deret waktu dua variabel yaitu *inflow* dan *outflow* uang kartal sebanyak 99 data dengan interval bulanan dari Januari 2011 sampai dengan Maret 2019 dari Divisi Sistem Pembayaran dan Pengelolaan Uang Rupiah Bank Indonesia Provinsi Bali. Gambar 1 berikut merupakan diagram alir analisis data sebagai garis besar metode dalam studi ini.



Gambar 1. Diagram Alir Analisis Data

2.1 Penyiapan Data

Identifikasi variabel hari raya dan *dummy* bulan dilakukan menggunakan program BalaBali Kalender (BalaBali, 2012).

Tabel 1. Identifikasi Variabel Hari Raya dan *Dummy* Bulan

Variabel	Identifikasi	Perhitungan
a	<i>Inflow</i>	Data BI
b	<i>Outflow</i>	Data BI
g	Galungan dan Kuningan	28 hari (Sudah termasuk rentetannya)
f	Idul Fitri	28 hari (dua hari puncak yaitu H1 dan H2)
n	Nyepi	14 hari (sudah termasuk rentetannya)
s	Saraswati dan Pagerwesi	7 hari (sudah termasuk keduanya)
m	Bulan	Nama bulan

Data bulan ke $-i$ dari 1 – 99 dapat dirumuskan ke dalam bentuk vektor baris sebagai variabel x_i .

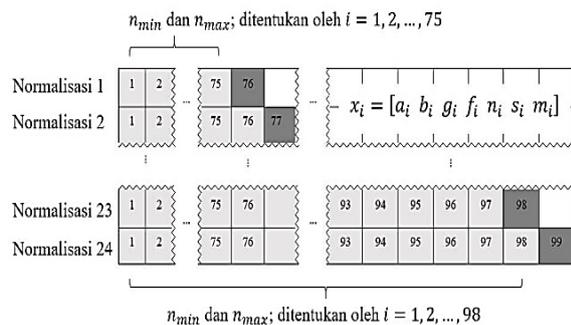
$$x_i = [a_i \ b_i \ g_i \ f_i \ n_i \ s_i \ m_i] \tag{1}$$

Data tersebut selanjutnya diproses menggunakan kode program MATLAB 2016a pada subbab berikut.

2.2 Simulasi Walk Forward Validation

Pembagian data *test* dan *train* untuk tiap prediksi dalam simulasi *inflow* dan *outflow* uang kartal di Provinsi Bali menggunakan metode *walk forward validation*. Metode ini mengizinkan penggunaan data aktual yang dibandingkan untuk *test* sebelumnya dalam data *train* untuk melakukan *test* berikutnya secara urut berdasarkan deret waktu yang ditentukan. Simulasi yang diujikan pada setiap model yang dirancang yaitu 24 bulan terakhir.

2.3 Normalisasi Data



Gambar 2. Normalisasi dalam Simulasi Walk Forward Validation

Gambar 2 menunjukkan normalisasi data dalam simulasi *walk forward validation* selama 24 bulan terakhir. Proses normalisasi hanya diterapkan pada data *inflow* (a_i) dan *outflow* (b_i). Data *inflow* dan *outflow* baik *test* maupun *train* dinormalkan berdasarkan masing-masing nilai minimal dan maksimal kolom *inflow* dan *outflow* dalam data *train*. Normalisasi dilakukan untuk membentuk data simulasi yang lebih menghindari hasil prediksi negatif atau terlampau besar.

2.4 Sliding Window Time Series Analysis

Konsep *sliding window time series analysis* (SWTS) digunakan untuk mempersiapkan data berdasarkan catatan waktu dan prediksi yang telah ditentukan, kemudian diproses untuk menghasilkan suatu prediksi baru (Mozaffari, et al., 2014). Didefinisikan nilai panjang segmen sebagai variabel l yang menunjukkan seberapa banyak deret waktu sebelumnya sebagai banyak input partisi yang dipasangkan dengan partisi output sebagai deret waktu berikutnya.

$$P = [I \ O] \quad (2)$$

$$\begin{bmatrix} y_1 & y_2 & \dots & y_l & a_{1+l} & b_{1+l} \\ y_2 & y_3 & \dots & y_{l+1} & a_{2+l} & b_{2+l} \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ y_{(99-l)-1} & y_{(99-l)} & \dots & y_{97} & a_{98} & b_{98} \\ \underbrace{y_{(99-l)}}_I & \underbrace{y_{(99-l)+1}}_I & \dots & y_{98} & \underbrace{a_{99}}_O & \underbrace{b_{99}}_O \end{bmatrix} \quad (3)$$

$$y_i = [a_i \ b_i] \quad (4)$$

diperoleh matriks P yang terdiri dari matriks I sebagai partisi *input*, O sebagai partisi *output*. Matriks P yang memuat hari raya dan bulan didefinisikan sebagai berikut.

$$P = \begin{bmatrix} I & H & M & O \\ \text{input} & & & \text{output} \end{bmatrix} \quad (5)$$

dengan H menyatakan nilai variabel hari raya di bulan yang diprediksi, dan M menyatakan *dummy* bulan di bulan yang diprediksi. Dapat didefinisikan *state space* matriks dari suatu proses prediksi deret waktu dengan suatu *intelligent predictor* ψ (Mozaffari, et al., 2014). *State space* berikut merupakan matriks data yang akan disesuaikan berdasarkan model yang dibuat.

$$\text{output} = \psi(\text{input}) \quad (6)$$

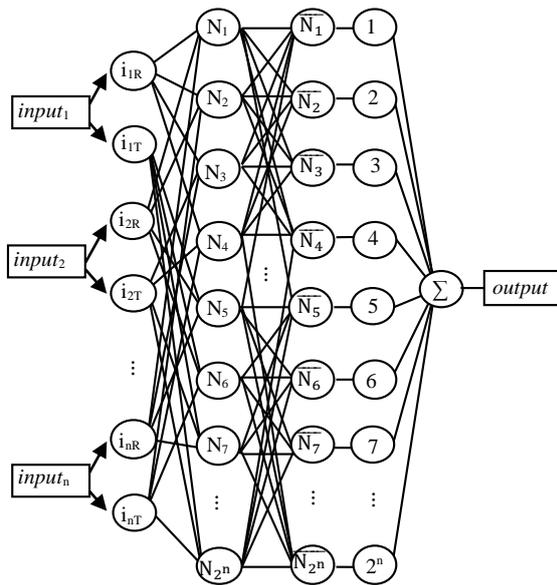
$$y_{i+l} = \psi([y_{i-1} \ y_{i-2} \ \dots \ y_{i-l} \ H_{i+l} \ M_{i+l}])$$

$$[a_{i+l} \ b_{i+l}] =$$

$$\psi([y_{i-1} \ y_{i-2} \ \dots \ y_{i-l} \ g_{i+l} \ f_{i+l} \ n_{i+l} \ s_{i+l} \ m_{i+l}]) \quad (7)$$

2.5 Arsitektur ANFIS

Arsitektur ANFIS untuk memprediksi *inflow* dan *outflow* uang kartal di Provinsi Bali terdiri dari lima layer menggunakan *rule base* Sugeno yang dijalankan dengan algoritme pembelajaran *hybrid*. Tiap variabel input difuzzikan dengan 2 variabel linguistik, yaitu RENDAH dan TINGGI. Arsitektur ini dihasilkan menggunakan MATLAB 2016a yaitu *Fuzzy Logic Toolbox* dan proses pembelajaran *hybrid* dijalankan menggunakan *syntax* "genfis1" untuk menghasilkan arsitektur ANFIS *grid partition*. Konfigurasi proses pembelajaran menggunakan nilai *epoch* 30.



Gambar 3. Arsitektur ANFIS grid partition

i. Layer 1: Fuzzifikasi

Fuzzifikasi tiap *input* sebagai premis aturan *fuzzy* dengan dua fungsi keanggotaan *generalized bell*.

$$\mu(x) = \frac{1}{1 + \left| \frac{x-c}{a} \right|^{2b}}; b = 1 \tag{8}$$

ii. Layer 2: Aturan fuzzy (hidden layer)

Tiap input pada penelitian ini difuzzikan ke dalam dua variabel linguistik, sehingga aturan fuzzy yang dibentuk arsitektur *grid partition* menggunakan MATLAB adalah sebanyak 2^n . Dalam hal ini *layer* dua berisi neuron sebanyak 2^n , dengan n menyatakan jumlah kolom *input* yang dihubungkan dengan operator AND untuk membentuk aturan *fuzzy*.

iii. Layer 3: Normalised Fire Strength

Tiap *neuron* pada *layer* tiga menghitung *normalised fire strength* tiap α – predikat pada *layer* dua yang terhubung dengannya.

$$\bar{w}_i = \frac{w_i}{\sum_{i=1}^{2^n} w_i}; i = 1, 2, \dots, 2^n \tag{9}$$

iv. Layer 4: Defuzzifikasi

Layer empat merupakan proses defuzzifikasi dengan menggunakan *consequent parameter* yang bersesuaian dengan aturan *fuzzy* sugeno pada *layer* dua.

$$\vartheta_i = \bar{w}_i f_i; i = 1, 2, \dots, 2^n \tag{10}$$

$$f_i = c_{1_i} input1_i + c_{2_i} input2_i + \dots + c_{n_i} inputn + c_{n+1_i} \tag{11}$$

v. Layer 5: Output keseluruhan

Tiap sinyal yang menuju tiap neuron pada *layer* lima akan dihitung *output*-nya berupa jumlahnya pada masing-masing *neuron*.

$$\vartheta_{1,2} = \sum_i^n \bar{w}_i f_i; n = 1, 2, 3, \dots, 2^n \tag{12}$$

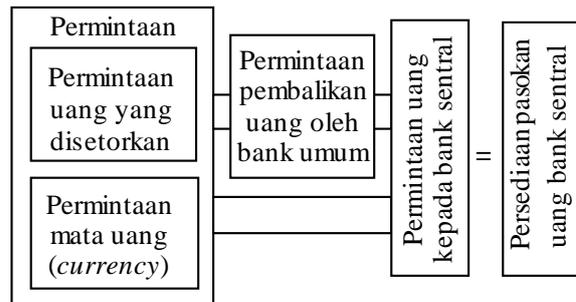
2.6 Denormalisasi

Proses denormalisasi mengembalikan nilai output prediksi dan output aktual yang dinormalkan ke bentuk sebelumnya. Denormalisasi dilakukan pada setiap prediksi dalam satu kesatuan simulasi *walk forward validation* berdasarkan parameter nilai minimal dan maksimal tiap kolom data *train*.

2.7 Simulasi dan Evaluasi Performa Prediksi

Evaluasi simulasi dilakukan berdasarkan perhitungan MAPE dan NRMSE. Interpretasi akurasi model yaitu kurang dari 10% sangat akurat, dari 10% hingga 20% akurat, lebih dari 20% hingga 50% wajar, dan lebih dari 50% tidak akurat (Lewis, 1982).

3. HASIL DAN PEMBAHASAN



Gambar 4. Skema Permintaan dan Persediaan Pasokan Uang di Bank Sentral (Chinn & University of Wisconsin, 2011)

Perancangan model prediksi disesuaikan berdasarkan Gambar 3 yaitu skema permintaan dan persediaan uang di bank sentral sebagai gambaran bagaimana sistem keuangan berlangsung antara masyarakat, bank umum, dan bank sentral. Sistem keuangan tersebut menunjukkan adanya saling keterkaitan antara *inflow* dan *outflow* uang kartal yang dilakukan oleh suatu bank umum dengan bank sentral. Sehingga dapat dibuat model *inflow* menggunakan data *outflow* dan model *outflow* menggunakan data *inflow*.

3.1 Rancangan Model Prediksi *Inflow* dan *Outflow* Uang Kartal di Provinsi Bali

Berikut *state space* matriks dari rancangan model *inflow* dan *outflow* uang kartal di Provinsi Bali berdasarkan skema Gambar 3 (Chinn & University of Wisconsin, 2011) dan data yang telah disiapkan.

$$output = \psi(input)$$

$$Y_{outflow} = F(p_i(inflow), \exists \sum (HR \times b), d_{bulan})$$

$$Y_{inflow} = F(p_i(outflow), \exists \sum (HR \times b), d_{bulan}) \quad (13)$$

Kemudian model dianalisis dalam sistem ANFIS untuk menghasilkan model yang akurat berdasarkan nilai *mean average percentage error* (MAPE) dan *normalized root mean square error* (NRMSE).

3.2 Analisis Model *Inflow* dan *Outflow* Uang Kartal di Provinsi Bali

Berikut analisis model prediksi *inflow* dan *outflow* uang kartal di Provinsi Bali. Model disimulasikan secara *walk forward validation* dari prediksi data 24 bulan terakhir.

i. Penentuan partisi

Penentuan partisi (*p*) SWTS untuk melihat panjang segmen (*l*) data *input* yang akurat sebagai indikator utama dalam suatu *output*.

$$output = \psi(input)$$

$$Y_{inflow} = F(p_i(outflow))$$

$$Y_{outflow} = F(p_i(inflow)) \quad (14)$$

Tabel 2. *Error* Simulasi Berdasarkan Panjang Segmen Tiap Partisi

(l)	Prediksi <i>Outflow</i>		Prediksi <i>Inflow</i>	
	MAPE	NRMSE	MAPE	NRMSE
1	38,25%	23,42%	29,95%	20,93%
2	33,09%	21,90%	25,23%	18,54%
3	37,42%	22,86%	28,71%	18,39%
4	69,58%	83,93%	31,09%	20,40%

Tabel 2 menunjukkan *error* simulasi *inflow* dan *outflow* uang kartal di Provinsi Bali dengan menyesuaikan panjang segmen (*l*) tiap partisi. Hasil menunjukkan terpilih *l* adalah dua untuk menghasilkan *error* yang minimum. Dalam langkah ini ditemukan banyaknya *input segmen* 3 dan 4 membuat jaringan tidak memprediksi

dengan baik karena ditemukan output negatif dan terlampau tinggi dalam simulasinya.

ii. Penambahan Variabel Hari Raya dan Pembobotan Diskrit

Penambahan variabel hari raya dalam model terpilih (i), bertujuan untuk meningkatkan performa prediksi *inflow* dan *outflow* uang kartal di Provinsi Bali. Tabel 3 menunjukkan hasil simulasi model dengan hari raya tunggal untuk variabel *g*, *f*, *n*, dan *s*.

Tabel 3. *Error* Simulasi Model Terpilih (i) dengan Tambah Variabel Hari Raya

HR	Prediksi <i>Outflow</i>		Prediksi <i>Inflow</i>	
	MAPE	NRMSE	MAPE	NRMSE
<i>g</i>	29,87%	21,01%	27,57%	19,38%
<i>f</i>	27,40%	15,75%	32,65%	23,09%
<i>n</i>	32,52%	22,08%	28,64%	19,93%
<i>s</i>	41,90%	33,86%	30,71%	23,04%

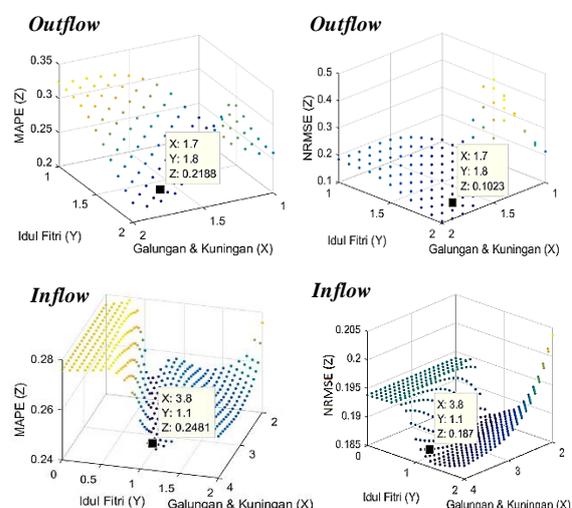
Tabel 3 menunjukkan penggunaan salah satu hari raya tidak seluruhnya meningkatkan akurasi model.

$$output = \psi(input) \quad (15)$$

$$Y_{inflow} = F(p_2(outflow), \exists \sum (HR \times b))$$

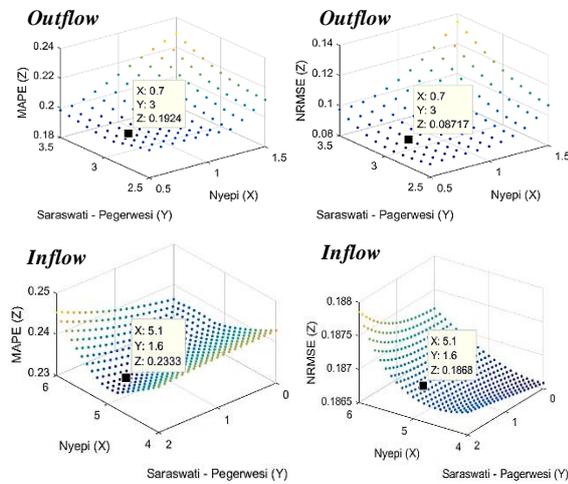
$$Y_{outflow} = F(p_2(inflow), \exists \sum (HR \times b))$$

Pembobotan diskrit digunakan sebagai alternatif untuk penggabungan semua identifikasi hari raya ke dalam model. Sehingga variabel yang terbentuk tidak terlalu mempengaruhi kompleksitas jaringan ANFIS dan mampu menggambarkan semua kejadian hari raya yang diidentifikasi.



Gambar 5. Pengujian *Error* Simulasi dengan Pembobotan Diskrit Hari Raya Galungan, Kuningan, dan Idul Fitri dalam Model

Gambar 5 menunjukkan grafik pengujian *error* simulasi dengan pembobotan diskrit berjarak 0,1 untuk hari raya Galungan, Kuningan, dan Idul Fitri yang mampu meningkatkan keakuratan model. Pada gambar dipilih titik diskrit yang menghasilkan MAPE terkecil, karena hampir sebagian besar nilai NRMSE lebih kecil dari MAPE.



Gambar 6. Pengujian *Error* Simulasi dengan Penambahan dan Pembobotan Diskrit Hari Raya Nyepi, Saraswati, dan Pagerwesi

Gambar 6 menunjukkan grafik pengujian *error* simulasi dengan pembobotan diskrit berjarak 0,1 untuk Nyepi, Saraswati, dan Pagerwesi dari model terpilih di Gambar 5. Pada gambar dipilih titik diskrit yang menghasilkan MAPE terkecil, karena hampir sebagian besar nilai NRMSE lebih kecil dari MAPE.

Sehingga diperoleh model berikut dengan performa prediksi *outflow* yaitu MAPE 19,24% dan NRMSE 8,71% sedangkan *inflow* yaitu MAPE 23,33% dan NRMSE 18,68%.

$$Y_{inflow} = F(p_2(outflow), (H_{gk} \times 1,7 + H_{if} \times 1,8 + H_n \times 0,7 + H_{sp} \times 3))$$

$$Y_{outflow} = F(p_2(inflow), (H_g \times 3,8 + H_f \times 1,1 + H_n \times 5,1 + H_s \times 1,6)) \quad (16)$$

iii. Penambahan *Dummy* Bulan

Variabel *dummy* sebelum diproses oleh ANFIS akan diproses terlebih dahulu dengan algoritme *mean encoding*. Nilai tiap data nominal 1 – 12 akan berubah menjadi rata-rata *output* per nama bulan dalam data *training* untuk meminimalkan kompleksitas model.

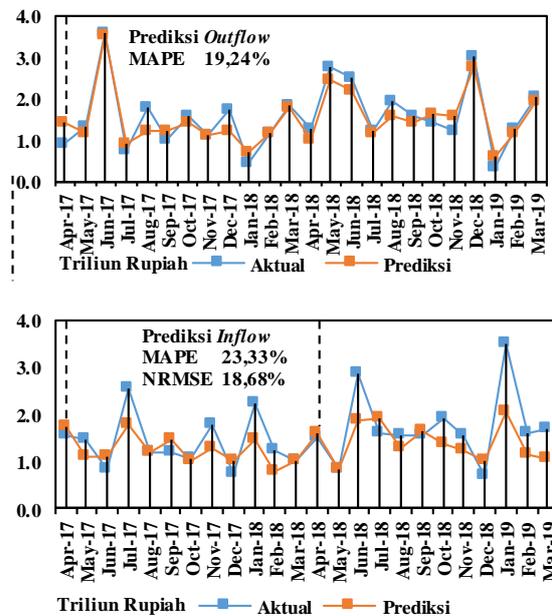
Tabel 4. Perbandingan *Error* Simulasi Model Berdasarkan Variabel yang Digunakan

M	Variabel Input	MAPE	NRMSE
Prediksi Outflow	-	33,09%	21,90%
	Bulan	33,74%	20,59%
	Hari raya, bulan	26,73%	11,11%
	Hari raya	19,24%	8,71%
Prediksi Inflow	-	25,23%	18,54%
	Bulan	24,25%	18,38%
	Hari raya, bulan	26,92%	18,03%
	Hari raya	23,33%	18,68%

Tabel 4 menunjukkan simulasi model yang menggunakan variabel *dummy* bulan dalam studi ini, tidak lebih akurat dibandingkan model yang hanya menggunakan variabel hari raya dengan pembobotannya.

iv. Pemilihan Model dan Grafik Simulasinya

Model *inflow* dan *outflow* di Provinsi Bali terpilih dalam penelitian ini yaitu model yang menggunakan variabel hari raya dengan pembobotannya. Pemilihan berdasarkan simulasi prediksi 24 bulan terakhir secara *walk forward validation* dan nilai *error* terkecil. Berikut hasil simulasi model terpilih yang ditunjukkan Gambar 7.



Gambar 7. Simulasi Prediksi *Inflow* dan *Outflow* Uang Kartal di Provinsi Bali

4. KESIMPULAN DAN SARAN

4.1 Kesimpulan

Model *neuro-fuzzy* dalam studi ini dapat digunakan untuk memprediksi *inflow* dan *outflow* uang kartal di Provinsi Bali adalah model yang menggunakan variabel hari raya dengan pembobotannya. Berdasarkan simulasi 24 bulan terakhir, performa prediksi *inflow* diperoleh MAPE 23,33% (patut dipertimbangkan) dan NRMSE 18,68% (akurat). Sedangkan performa prediksi *outflow* diperoleh MAPE 19,24% (akurat) dan NRMSE 8,71% (sangat akurat). Jadi, metode *neuro-fuzzy* dapat digunakan sebagai model prediksi *inflow* dan *outflow* uang kartal di Provinsi Bali secara bulanan.

4.2 Saran

Adapun beberapa saran dari hasil penelitian ini yang dapat diteliti lebih lanjut.

1. Konsep *sliding window time series analysis* mengizinkan segmentasi untuk partisi *output*, sehingga membuka celah penelitian prediksi *inflow* dan *outflow* uang kartal untuk beberapa bulan ke depan.
2. Penelitian ini hanya menggunakan 4 variabel hari raya keagamaan, disarankan menambah hari raya yang mungkin dapat meminimalkan *error*.
3. Penelitian ini menggunakan beberapa hari raya sekaligus, disarankan untuk melakukan penelitian lebih lanjut yang fokus ke hari raya Galungan dan Kuningan sebagai hari raya besar penduduk mayoritas untuk menemukan hal baru di dalamnya.
4. Hari raya Idul Fitri merupakan hari raya penduduk minoritas di Provinsi Bali dan memberikan efek paling signifikan terhadap prediksi *outflow* uang kartal. Hal ini merupakan hal yang menarik untuk diteliti lebih lanjut di lingkup perbankan sekaligus masyarakat, karena arus uang kartal di masyarakat dilakukan oleh bank sebagai pihak yang secara langsung berkomunikasi dengan bank sentral.
5. Arsitektur standar ANFIS *grid partition* dapat menghasilkan *output* negatif atau terlalu tinggi saat dimensi variabel *input* lebih dari 3 walaupun sudah dinormalisasi. Hal ini dapat diteliti lebih lanjut untuk menemukan solusi arsitektur ANFIS yang dapat menerima input variabel yang lebih

banyak untuk memprediksi *inflow* dan *outflow* uang kartal di Provinsi Bali.

6. Penelitian ini tidak menemukan model yang akurat untuk memprediksi *inflow* dan *outflow* uang kartal di Provinsi Bali dengan menggunakan variabel *dummy* bulan. Disarankan melakukan penelitian lebih lanjut terkait hal ini.

DAFTAR PUSTAKA

- BalaBali, 2012. *BalaBali Kalender*. [Online] Available at: <http://www.balabali.com/id/balabali-kalender-id> [Diakses 13 10 2019].
- Bank Indonesia, 2013. *Sistem Pembayaran - Bank Sentral Republik Indonesia*. [Online] Available at: <https://www.bi.go.id/id/sistem-pembayaran/Contents/Default.aspx> [Diakses 10 06 2019].
- Chinn, M. & University of Wisconsin, 2011. *Economics 302 Section 001: Intermediate Macroeconomic Theory*. [Online] Available at: https://www.ssc.wisc.edu/~mchinn/web302_s11.html [Diakses 02 07 2020].
- Lewis, C., 1982. *Industrial and business forecasting methods*. London: Butterworths.
- Mozaffari, L., Mozaffari, A. & L. Azad, N., 2014. Vehicle speed prediction via a sliding-window time series analysis and an evolutionary least learning machine: A case study on San Francisco urban roads. *Engineering Science and Technology, an International Journal (ELSEVIER)*, pp. 1-13.
- Navarro, R. I., Dalmases, O. L. & Akhi-Elarab, F. N., 2013. *Annex1: Introduction to Neural Networks and Adaptive Neuro-Fuzzy Inference Systems (ANFIS)*, Barcelona: Universitat Politècnica de Catalunya.