



PEMODELAN PRAKIRAAN KAS PEMERINTAH

Iskandar

Tasmanian School of Business & Economic, University of Tasmania, Australia

Alamat Korespondensi: iskandar.iskandar@utas.edu.au

INFORMASI ARTIKEL

Diterima Pertama
9 Agustus 2017

Dinyatakan Diterima
7 Desember 2017

KATA KUNCI:

Pengelolaan Kas Pemerintah, Model Prakiraan Kas Pemerintah, *Autoregressive Integrated Moving Average*, Jaringan Syaraf Tiruan.

KLASIFIKASI JEL:
H68.

ABSTRAK

Government cash management refers to the strategies for managing government money to fulfil government obligations effectively. Failure to manage cash effectively risks of undermining the implementation of government policies. The Greek crisis in 2010 is an example of a government inability to manage resources effectively. Despite the importance of effective government cash management, the literature on effective cash forecasting, as one of effective government cash management pillars in the public sector is scarce. This paper addresses this shortcoming by developing a government cash forecasting model with an accuracy that meets acceptable levels of materiality for the cash managers. Using Indonesian government expenditure data in a case study, we utilise Autoregressive Integrated Moving Average (ARIMA) and Artificial Neural Network (ANN) to build cash forecasting models. The results provide evidence that the ANN method is superior than the ARIMA model to build a government cash forecasting model.

Pengelolaan Kas Pemerintah mengacu pada serangkaian strategi yang dilakukan oleh pemerintah dalam mengelola uang pemerintah secara efektif dalam rangka memenuhi kewajiban pemerintah. Kegagalan dalam mengelola uang pemerintah secara efektif berisiko mengganggu pelaksanaan kebijakan pemerintah. Krisis yang dialami Yunani di tahun 2010 merupakan salah satu contoh dampak yang dapat ditimbulkan dari tidak berhasilnya suatu pemerintahan mengelola sumber daya keuangan yang mereka milik secara efektif. Terlepas dari pentingnya mengelola kas pemerintah secara efektif, literatur tentang bagaimana menyusun prakiraan kas yang efektif – sebagai salah satu pilar Pengelolaan Kas Pemerintah – bagi sektor publik masih langka. Penelitian ini bertujuan untuk mengisi kesenjangan dalam literatur dengan memperkenalkan salah satu cara menyusun model prakiraan kas pemerintah dengan tingkat akurasi yang memenuhi harapan Pengelola Kas pemerintah. Dengan menggunakan data historis harian pengeluaran pemerintah Indonesia sebagai sebuah studi kasus, penelitian ini menggunakan *Autoregressive Integrated Moving Average* (ARIMA) dan Jaringan Syaraf Tiruan (JST) untuk menyusun model prakiraan kas. Penelitian ini menunjukkan bahwa penggunaan metode Jaringan Syaraf Tiruan (JST) dapat menjadi alternatif dalam menyusun model prakiraan kas pemerintah dengan tingkat akurasi model prakiraan kas yang lebih tinggi dibandingkan menggunakan ARIMA model.

1. PENDAHULUAN

Pengelolaan Kas Pemerintah adalah serangkaian strategi yang diambil oleh pemerintah untuk memastikan sejumlah uang tersedia untuk memenuhi kewajiban pemerintah pada saat uang tersebut dibutuhkan dengan cara yang paling efektif (Storkey, 2003). Hal ini membutuhkan kolaborasi antara pemerintah dan pengambil kebijakan lainnya. Oleh karena itu, kebijakan pemerintah terkait pengelolaan kas dan kebijakan lainnya di bidang keuangan harus sejalan (Williams, 2010). Peran pemerintah yang semakin penting dalam menyediakan layanan publik menjadikan fungsi pengelolaan kas semakin sentral dalam perekonomian suatu negara (Widodo, Sihombing, Budhisusetyo, & Harjowiryo, 2014). Kegagalan dalam menyediakan dana guna membiayai kebutuhan pemerintah dapat mengganggu kemampuan pemerintah memberikan pelayanan publik. Penarikan pinjaman yang tidak diantisipasi sebelumnya untuk menutupi pengeluaran pemerintah menyebabkan peningkatan beban pemerintah dan mempengaruhi kredibilitas pemerintah. Krisis yang dialami Yunani pada tahun 2010 adalah salah satu contoh dimana pemerintah gagal mengelola kas mereka secara efektif yang menyebabkan membengkaknya biaya pinjaman (*cost of borrowing*) guna menutupi pengeluaran pemerintah. Krisis tersebut tidak hanya berdampak pada kondisi dalam negeri Yunani, tetapi juga berpotensi menular pada sistem perekonomian yang lebih luas (Arghyrou & Tsoukalas, 2011; Kouretas & Vlamis, 2010). Ini menggambarkan pentingnya Pengelolaan Kas Pemerintah yang efektif pada suatu perekonomian.

Penelitian di bidang Pengelolaan Kas Pemerintah seperti Storkey (2003), Mu (2006), Lienert (2009), dan Williams (2009) menekankan pentingnya memprediksi kebutuhan dana untuk membiayai kegiatan pemerintah sebagai unsur yang harus dipenuhi guna mewujudkan Pengelolaan Kas Pemerintah yang efektif. Meski demikian, Mu (2006) berpendapat bahwa kemampuan negara berkembang dalam memprediksi kebutuhan dana dimaksud masih rendah. Untuk memperkuat sistem pengelolaan kas mereka, negara berkembang perlu menganalisis pola permintaan dana dan menyusun model prakiraan kas yang dapat diandalkan (Mu, 2006). Secara umum, terdapat dua pendekatan dalam menyusun model prakiraan kas pemerintah dilihat dari informasi yang digunakan, yaitu: (1) pendekatan *bottom-up* yang memanfaatkan informasi yang disampaikan instansi pemerintah – dalam hal ini satuan kerja sebagai pengguna anggaran terkecil (*spending unit*) – kepada Pengelola Kas, dan (2) pendekatan *top-down* menggunakan informasi yang dimiliki Pengelola

Kas berupa data historis yang tersimpan dalam sebuah database (Williams, 2009, 2010).

Beberapa penelitian tentang prakiraan kas pemerintah telah dilakukan, tetapi sebagian besar hanya sebagai pelengkap bagi topik utama Pengelolaan Kas Pemerintah. Storkey (2003) membahas tentang penggunaan teknologi dalam mengembangkan sistem pengelolaan dan prakiraan kas pemerintah. Mu (2006) menekankan pentingnya membangun sistem prakiraan kas sebagai pilar mewujudkan Pengelolaan Kas Pemerintah yang efektif. Lienert (2009) dan Williams (2009) mengusulkan langkah-langkah penyempurnaan Pengelolaan Kas Pemerintah, dengan prakiraan kas menjadi salah satu yang terpenting. Minimnya literatur yang berfokus pada pengembangan model prakiraan kas pemerintah menjadi motivasi dituliskannya penelitian ini. Penelitian ini diharapkan dapat memperkenalkan salah satu cara dalam menyusun model prakiraan kas yang digunakan oleh Pemerintah dan sektor publik lainnya.

Penelitian ini secara spesifik ditujukan untuk mengembangkan model prakiraan kas pemerintah, dengan tingkat akurasi yang memenuhi harapan Pengelola Kas Pemerintah. Untuk mencapai tujuan tersebut, penulis menggunakan pendekatan *top-down* yang dipaparkan oleh Williams (2009, 2010) dengan menggunakan informasi dari data historis pengeluaran seluruh instansi pengguna anggaran pemerintah Indonesia sebagaimana akan dijelaskan pada bagian berikutnya. Temuan penelitian ini akan memberikan kontribusi yang bermanfaat bagi penelitian di bidang Pengelolaan Kas Pemerintah, terutama bagi pengembangan model prakiraan kas yang merupakan elemen kunci dalam mencapai Pengelolaan Kas Pemerintah yang efektif. Kemampuan pemerintah yang lebih baik untuk memproyeksikan kebutuhan dana mereka secara lebih tepat akan meningkatkan kemampuan mereka dalam mengelola kas secara efektif sehingga beban yang timbul akibat pinjaman dapat dihindari.

Bagian selanjutnya pada penelitian ini ditulis dengan sistematika sebagai berikut. Kerangka teori yang melandasi penelitian ini disajikan pada Bagian 2. Bagian 3 menjelaskan metode yang akan digunakan untuk membangun pemodelan prakiraan kas pemerintah pada penelitian ini. Bagian 4 menyajikan hasil dan diskusi. Kesimpulan disajikan pada Bagian 5 dan Bagian 6 berisi implikasi dan keterbatasan penelitian.

2. KERANGKA TEORI

Berdasarkan Peraturan Menteri Keuangan Nomor 127/PMK.02/2015, pengeluaran pemerintah di Indonesia dikelompokkan menjadi berbagai jenis belanja penyelenggaraan pemerintah pusat sebagai berikut: Belanja Pegawai,

Belanja Barang dan Jasa, Belanja Modal, Belanja Pembayaran Kewajiban Utang, Belanja Subsidi, Belanja Hibah, Belanja Bantuan Sosial, dan Belanja Lain-lain. Belanja Pegawai adalah kompensasi terhadap pegawai pemerintah seperti gaji dan biaya personil lainnya. Belanja Barang dan Jasa mencakup biaya operasional satuan kerja instansi pemerintah. Belanja Modal digunakan untuk memperoleh aset baru atau memperbaiki aset yang ada. Belanja Pembayaran Kewajiban Utang merupakan pengeluaran pemerintah untuk pembayaran bunga atas utang dan biaya lainnya yang terkait dengan utang pemerintah. Belanja Subsidi diberikan kepada perusahaan negara, instansi pemerintah, dan pihak lain untuk mempertahankan daya beli masyarakat atas suatu produk. Belanja Hibah adalah transfer pemerintah ke negara lain, organisasi internasional, pemerintah daerah, dan masyarakat yang bersifat tidak wajib, sukarela, tidak mengikat, dan tidak perlu dibayar kembali. Bantuan sosial terdiri dari transfer uang, barang, atau jasa kepada masyarakat untuk melindungi dari kemungkinan terjadinya risiko sosial dan meningkatkan kesejahteraan masyarakat. Belanja Lain-lain mencakup pengeluaran bencana alam, bencana sosial, dan kejadian tak terduga lainnya (Menteri Keuangan, 2015).

Jenis pengeluaran tersebut di atas dapat dikelompokkan menjadi Pengeluaran Terjadwal dan Pengeluaran Tidak Terjadwal. Pengeluaran Terjadwal – termasuk di dalamnya Belanja Pegawai, Belanja Pembayaran Kewajiban Utang, Belanja Subsidi, Belanja Hibah – mengacu pada waktu dan jumlah pengeluaran yang dapat diprediksi dengan baik. Pada kebanyakan kasus, waktu dan jumlah pengeluaran rutin terlebih dahulu ditetapkan oleh suatu peraturan sehingga besaran dan waktu dana dimaksud diperlukan dapat diketahui secara pasti sebelumnya oleh Pengelola Kas Pemerintah. Sebaliknya, pada Pengeluaran Tidak Terjadwal, waktu dan jumlah uang yang dibutuhkan bervariasi pada setiap periode sehingga sulit bagi Pengelola Kas Pemerintah menentukan dengan pasti sebelum satuan kerja mengajukan perintah pembayaran atas pengeluaran dimaksud. Jenis belanja ini mencakup Belanja Barang dan Jasa, Belanja Modal, dan Belanja Bantuan Sosial.

Pengeluaran Tidak Terjadwal sepenuhnya menjadi kewenangan satuan kerja dalam menentukan waktu dan jumlah dana yang diperlukan. Belanja Barang dan Jasa terkait erat dengan kegiatan operasional satuan kerja. Hanya satuan kerja yang bersangkutan yang mengetahui kapan Belanja Barang dan Jasa diperlukan guna menunjang kegiatan operasional satker berkenaan. Pada beberapa kegiatan pengadaan, satuan kerja perlu menyalurkan Belanja Modal mereka

dengan tahapan-tahapan dalam proses pengadaan – mulai dari pengumuman pengadaan hingga serah terima pekerjaan – yang sepenuhnya di bawah kontrol satuan kerja. Beberapa kegiatan, karena sifat pekerjaannya, harus menunggu sampai waktu tertentu agar dapat berjalan dengan baik (misalnya pekerjaan di bidang pertanian yang dipengaruhi oleh cuaca dan musim). Karakteristik unik yang dimiliki oleh Pengeluaran Tidak Terjadwal – yaitu Pengelola Kas Pemerintah tidak dapat melakukan intervensi terhadap keputusan satuan kerja terkait jumlah dan waktu pengeluaran tersebut dilakukan – dapat mempengaruhi tingkat akurasi proyeksi kebutuhan kas yang telah direncanakan sebelumnya. Usaha memitigasi Pengeluaran Tidak Terjadwal perlu dilakukan dengan sungguh-sungguh guna menjamin tingkat akurasi kebutuhan kas pemerintah memenuhi harapan Pengelola Kas Pemerintah. Untuk alasan tersebut, penelitian ini berfokus pada Pengeluaran Tidak Terjadwal dalam mengembangkan model prakiraan kas pemerintah.

Pemerintah Indonesia dianggap telah berhasil melakukan reformasi Pengelolaan Kas Pemerintah kearah yang lebih baik (Widodo, et al., 2014). Meski demikian, sistem prakiraan kas pemerintah Indonesia secara umum masih menganut pendekatan *bottom-up* dimana tingkat akurasi yang dihasilkan tidak memenuhi harapan Pengelola Kas yang antara lain disebabkan beratnya beban satuan kerja dalam menyampaikan laporan pemutakhiran perencanaan kas berjalan (Widodo, et al., 2014). Lebih lanjut Widodo, et al., (2014) mengusulkan penggunaan pendekatan *top-down* untuk mengeksplorasi data historis guna meningkatkan akurasi prakiraan kas pemerintah. Penelitian ini diarahkan untuk menyusun model prakiraan kas pemerintah berdasarkan pendekatan *top-down* dengan memanfaatkan metode dan teknik prakiraan yang tersedia.

Autoregressive Integrated Moving Average (ARIMA) merupakan salah satu teknik yang paling sering digunakan dalam prakiraan data *time series*. ARIMA merupakan generalisasi model *Autoregressive Moving Average* (ARMA) yang diperkenalkan oleh Box dan Jenkins (1976). Penelitian terbaru seperti Mondal, Shit, dan Goswami (2014), Ariyo, Adewumi, dan Ayo (2014), dan Iqbal dan Naveed (2016) menunjukkan bahwa model ARIMA dapat memberikan akurasi yang baik dalam memproses data *time series*. Ariyo, et al. (2014) membuktikan bahwa kemampuan model ARIMA dalam menghasilkan tingkat akurasi yang memadai, sebanding dengan teknik prakiraan lainnya.

Meski dapat diterapkan dalam hampir semua prakiraan data *time series*, model ARIMA dianggap tidak dapat menangkap pola nonlinieritas yang terkandung dalam data (P. G. Zhang, 2003). Sebuah studi eksperimental oleh G. P. Zhang, Patuwo, dan

Hu (2001) mengemukakan bahwa model Jaringan Syaraf Tiruan (JST) dapat memberikan prediksi yang lebih baik pada data nonlinear. Sejumlah penelitian terkini, seperti Acuna, Ramirez, dan Curilem (2012); Dandekar dan Ranade (2015); Kamini, Ravi, Prinzie, dan Van den Poel (2013); Mishra dan Dehuri (2014); Venkatesh, Ravi, Prinzie, dan Van den Poel (2014), menggunakan JST sebagai metode dalam menyusun model prakiraan kas. Penelitian tersebut mendukung keunggulan metode JST dalam menyusun model prakiraan kas dibandingkan metode prakiraan lainnya.

Untuk mencapai tujuan penelitian, penulis menggunakan ARIMA dan JST sebagai metode dalam menyusun model prakiraan. Guna mengkonfirmasi metode terbaik dalam mengembangkan model prakiraan kas pemerintah, kinerja prakiraan masing-masing model dibandingkan melalui suatu proses evaluasi prakiraan.

3. METODOLOGI PENELITIAN

3.1. Data

Penelitian ini menggunakan data harian pengeluaran seluruh satuan kerja instansi pemerintah pusat pada tahun anggaran 2009–2015. Data tersebut diperoleh dari database Direktorat Jenderal Perbendaharaan, Departemen Keuangan Republik Indonesia selaku Pengelola Kas Pemerintah. Total Pengeluaran Tidak Terjadwal merupakan hasil agregasi data harian Belanja Barang dan Jasa, Belanja Modal, dan Belanja Bantuan Sosial.

Total Pengeluaran Tidak Terjadwal disajikan dalam bentuk logaritma natural, LT . Untuk menghindari *overfitting* data terhadap model yang dihasilkan, penelitian ini membagi data menjadi dua set data, yaitu data pelatihan (*training data*) sebanyak 1228 observasi (2009–2013) yang digunakan untuk menyusun model dan data pengujian (*testing set*) sebanyak 488 observasi (2014–2015) yang digunakan untuk menguji kinerja model prakiraan yang dihasilkan. Pemilihan *testing set* dengan periode 2 tahun dimaksudkan untuk melihat kinerja model dalam memprediksi perubahan pola pengeluaran pemerintah pada setiap tahunnya dalam periode observasi.

3.2. ARIMA Model

ARIMA merupakan model statistik yang mengeksplorasi nilai lampau suatu data *time series* dan residual model untuk memprediksi nilai masa depan data *time series* dimaksud. Salah satu keunggulan model ARIMA adalah penggunaannya dalam memprediksi nilai masa depan data *time series* tidak memerlukan landasan teori tertentu

berkenaan dengan hubungan antar variable yang digunakan (Gujarati & Porter, 2009).

ARIMA diperoleh dari bentuk umum model ARMA (Mondal, dkk, 2014). ARMA (p, q) memiliki persamaan matematik sebagai berikut:

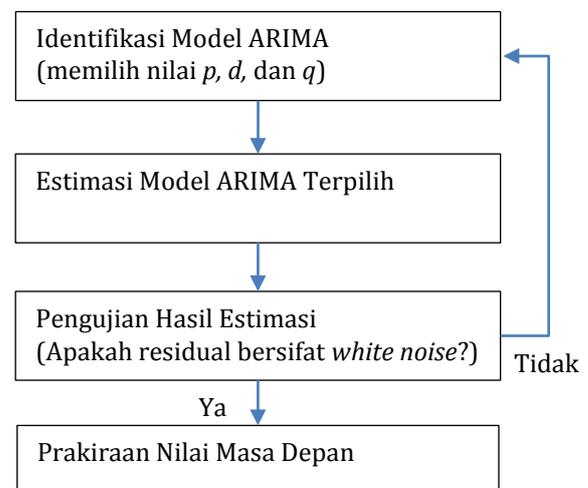
$$Y_t = \theta + \alpha_1 Y_{t-1} + \alpha_2 Y_{t-2} + \dots + \alpha_p Y_{t-p} + \varepsilon_t + \beta_1 \varepsilon_{t-1} + \beta_2 \varepsilon_{t-2} + \dots + \beta_q \varepsilon_{t-q} \quad 1)$$

dimana,

- Y_t : data pada saat t
- ε_t : residual pada saat t
- θ : konstanta
- α, β : koefisien

Untuk memastikan analisis yang dihasilkan *robust*, data time series harus bersifat stasioner. Jika data yang digunakan tidak stasioner, maka perlu dilakukan proses *differencing* sebanyak d kali sampai data yang dimaksud stasioner atau biasa disebut *integrated* pada orde d ($I(d)$). Jika data *time series* pada Persamaan 1 adalah $I(d)$, maka kita peroleh bentuk formal model ARIMA menjadi $ARIMA(p, d, q)$, di mana p , merupakan orde *autoregressive* (AR), d , merupakan proses *differencing*, dan q , merupakan orde *moving average* (MA). Nilai p, d , dan q akan mempengaruhi model ARIMA yang digunakan. Misalnya, dengan data time series stasioner ($d=0$), model $ARIMA(p, 0, q)$ akan menjadi $ARMA(p, q)$, $ARIMA(p, 0, 0)$ menjadi $AR(p)$, dan $ARIMA(0, 0, q)$ menjadi $MA(q)$ (Gujarati & Porter, 2009)

Lebih lanjut Gujarati dan Porter (2009) menjelaskan metode ARIMA dilakukan dalam empat langkah, seperti yang ditunjukkan pada Gambar 1. Identifikasi model ARIMA dilakukan dengan menggunakan pengujian stasioner dan



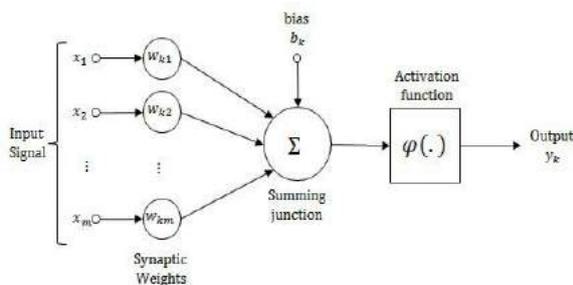
Sumber: Gujarati dan Porter (2009)

Gambar 1 Prosedur ARIMA

pengujian *correlogram* dari *Autocorrelation Function* (ACF), dan *Partial Autocorrelation Function* (PACF). Setelah model ARIMA diperoleh langkah selanjutnya adalah melakukan estimasi terhadap model ARIMA tersebut. Jika residual yang dihasilkan bersifat acak dan tidak berkorelasi satu dengan yang lainnya atau *white noise*, maka model ARIMA terpilih adalah model yang terbaik. Jika residual yang dihasilkan tidak *white noise*, maka perlu dipertimbangkan model ARIMA lainnya. Jika terdapat lebih dari satu model dengan residual bersifat *white noise*, maka model terbaik dipilih menggunakan metode pemilihan model semisal *Akaike Information Criterion* (AIC), *Schwarz Bayesian Criteria* (SBC), dan lainnya. Langkah terakhir adalah melakukan prakiraan nilai masa depan berdasarkan model ARIMA terpilih. Dalam penelitian ini, variabel *LT* dianalisis mengikuti prosedur ARIMA sebagaimana disebut di atas.

3.3. Jaringan Syaraf Tiruan

JST adalah model komputasi yang menirukan sistem saraf pada mahluk hidup sebagai suatu sistem pengolahan informasi (G. Zhang, Patuwo, & Hu, 1998). JST merupakan bagian dari metode *Machine Learning* yang memanfaatkan kemampuan unit komputer untuk mempelajari sinyal yang diterima (input) guna menghasilkan keluaran (output) berdasarkan pengalaman, contoh, dan/atau analogi dari sinyal yang diterima sebelumnya (Negnevitsky, 2005). Komponen utama dalam membangun suatu JST adalah neuron, koneksi, dan algoritma pembelajaran (Yildiz & Yezegel, 2010). Neuron merupakan unit pengolahan informasi yang terdiri dari serangkaian konektor, biasa disebut sinapsis, yang menghubungkan signal dari input ke output maupun ke neuron lainnya. Setiap sinapsis memiliki bobot yang merepresentasikan seberapa kuat suatu signal mempengaruhi sistem yang ada. Bobot masing-masing sinapsis ditentukan melalui tahapan berulang hingga diperoleh nilai yang paling optimal. Proses iterasi inilah yang disebut sebagai algoritma pembelajaran (Haykin, 1999). Gambar 2 menunjukkan salah satu bentuk neuron pada JST.



Sumber: Haykin (1999)

Gambar 2 Neuron

Dalam sebuah neuron *k*, data input x_j pada sinapsis *j* dikalikan dengan bobot sinapsis w_{kj} . Total dari perkalian tersebut ditambah dengan bias b_k menjadi sebuah nilai yang disebut *linear combiner* v_k . Bias tersebut berfungsi untuk menaikkan atau menurunkan signal input sebelum dilakukan perhitungan menggunakan fungsi aktivasi $\varphi(\cdot)$ (Haykin, 1999). Keluaran neuron y_k selanjutnya dapat digunakan oleh neuron lain sebagai masukan (Butler, 2006). Neuron *k* dapat ditulis dalam persamaan matematika sebagai berikut:

$$y_k = \varphi(v_k) \tag{2}$$

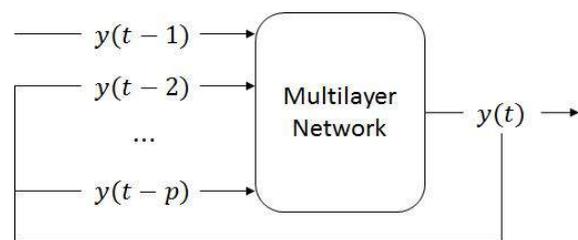
dimana,

$$v_k = \sum_{j=1}^m w_{kj} x_j + b_k$$

Pada implementasinya, arsitektur yang digunakan dalam membangun JST sangat beragam. Variasi ini ditentukan dari bagaimana neuron-neuron pada sebuah JST saling berhubungan. Pada penelitian ini penulis menggunakan *Nonlinear Autoregressive Neural Network* (NARNN) (Ruiz, Cuéllar, Calvo-Flores, & Jiménez, 2016). NARNN dapat dinyatakan dalam persamaan matematika sebagai berikut:

$$y_t = \varphi(y_{t-1}, y_{t-2}, \dots, y_{t-p}) + \varepsilon_t \tag{3}$$

dimana y_t merupakan nilai variabel *y* pada waktu *t*, *p* merupakan lag masa lalu (*time delay*) yang menentukan jumlah input pada NARNN, $\varphi(\cdot)$ merupakan fungsi aktivasi, dan ε_t merupakan residual. Arsitektur NARNN dapat dilihat pada Gambar 3.



Sumber: (Ruiz, et al., 2016)

Gambar 3 Arsitektur NARNN

Pada JST, beberapa neuron dapat berkumpul membentuk lapisan (*layer*). NARNN terdiri dari beberapa lapisan yang menghubungkan antara lapisan input (*input layer*) dan lapisan output (*output layer*). Lapisan penghubung tersebut dikenal dengan nama lapisan tersembunyi (*hidden layer*). Penentuan lapisan tersembunyi dan jumlah neuron per lapisan ditentukan dengan cara *trial dan error* hingga diperoleh hasil yang diinginkan. Meski demikian, perlu diingat bahwa semakin banyak jumlah neuron akan meningkatkan

kompleksitas jaringan. Di sisi lain, semakin sedikit jumlah neuron akan membatasi kemampuan komputasi dan kinerja jaringan (Ruiz, et al., 2016). Algoritma pembelajaran Levenberg-Marquardt (LM) *Backpropagation* merupakan algoritma pembelajaran yang paling umum digunakan pada NARNN karena kecepatan komputasi yang dimilikinya (Ayala & Coelho, 2016; Dudek, 2016; Ebtehaj & Bonakdari, 2016; Wang, Chau, Qiu, & Chen, 2015).

3.4. Metode evaluasi prakiraan

Pemilihan model terbaik dilakukan dengan melakukan evaluasi terhadap kinerja tiap-tiap model. Mengikuti penelitian Khanelwal, Adhikari, dan Verma (2015), kinerja tiap-tiap model dievaluasi dengan berdasarkan pada pengukuran nilai *Mean Square Error* (MSE). Nilai MSE yang rendah menunjukkan kesesuaian antara model dan data yang tinggi. Persamaan matematika MSE adalah sebagai berikut:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \tag{4}$$

dimana y_t merupakan nilai aktual dan \hat{y}_t adalah nilai prakiraan.

4. HASIL PENELITIAN

Penelitian ini mengajukan dua model prakiraan kas pemerintah untuk menginvestigasi cara terbaik untuk memprediksi kebutuhan kas pemerintah di masa depan. Kedua model tersebut disusun menggunakan dua metode yang berbeda yaitu ARIMA dan JST, dalam hal ini NARNN. Model terbaik ditentukan melalui teknik evaluasi perkiraan.

4.1. ARIMA Model

Sebelum menyusun sebuah model ARIMA, informasi awal mengenai tingkat integrasi dan maksimum lag korelasi data sangat penting untuk diketahui. Tingkat integrasi diperlukan untuk menentukan orde integrasi (d) model ARIMA sedangkan maksimum lag korelasi diperlukan untuk menentukan orde AR (p) dan orde MA (q) model ARIMA. Penelitian ini menggunakan uji akar unit *Augmented Dicky-Fuller* (ADF) untuk memeriksa stasioneritas data. Pengujian akar unit menunjukkan bahwa variable LT stasioner atau terintegrasi pada orde $0/I(0)$.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.673	0.673	557.72	0.000
		2	0.552	0.181	933.54	0.000
		3	0.465	0.072	1199.6	0.000
		4	0.317	-0.113	1323.8	0.000
		5	0.241	-0.005	1395.7	0.000
		6	0.206	0.051	1448.3	0.000
		7	0.161	0.014	1480.3	0.000
		8	0.131	-0.001	1501.6	0.000
		9	0.106	-0.011	1515.6	0.000
		10	0.102	0.034	1528.4	0.000
		11	0.101	0.031	1541.0	0.000
		12	0.081	-0.018	1549.1	0.000
		13	0.078	0.006	1556.7	0.000
		14	0.060	-0.020	1561.1	0.000
		15	0.067	0.042	1566.7	0.000
		16	0.064	0.007	1571.8	0.000
		17	0.055	-0.006	1575.5	0.000
		18	0.051	-0.006	1578.7	0.000
		19	0.048	0.008	1581.6	0.000
		20	0.045	0.012	1584.2	0.000
		21	0.043	0.001	1586.5	0.000
		22	0.042	0.002	1588.6	0.000
		23	0.041	0.004	1590.7	0.000
		24	0.038	0.004	1592.5	0.000

Gambar 4 Correlogram ACF dan PACF

Correlogram ACF dan PACF disajikan pada Gambar 4. Berdasarkan gambar tersebut menunjukkan bahwa maksimum lag korelasi variable LT adalah 4. Ini menunjukkan bahwa orde AR (p) dan orde MA (q) model ARIMA maksimum adalah 4.

Berdasarkan hasil estimasi dan pengujian hasil estimasi dapat diambil kesimpulan bahwa model ARIMA yang terpilih adalah ARIMA(3,0,2) dengan hanya mengikutsertakan lag ke-2 pada MA term sebagai berikut:

$$Y_t = 26.95 + 0.55Y_{t-1} + 0.19Y_{t-2} + 0.35Y_{t-3} + 0.41\varepsilon_{t-2} + \varepsilon_t$$

Semua koefisien signifikan pada level 1%. Keputusan untuk hanya mengikutsertakan lag ke-2 pada MA term pada ARIMA(3,0,2) didasarkan pada nilai AIC dan SBC yang lebih rendah jika dibandingkan dengan mengikutsertakan lag ke-1 dan ke-2. Hasil pengujian unit akar dan estimasi ARIMA model dapat dilihat pada lampiran.

4.2. Jaringan Syaraf Tiruan

NARNN disusun menggunakan MATLAB Toolbox dengan beberapa modifikasi untuk mengakomodasi kebutuhan pengolahan data. Model NARNN yang terpilih adalah model yang dapat mengoptimalkan kinerja prakiraan berdasarkan kriteria MSE. *Time delay* yang digunakan pada penelitian ini adalah 4 – sesuai dengan maksimum lag korelasi variable LT sebagaimana pengujian *Correlogram* ACF dan PACF pada bagian sebelumnya – yang berarti model NARNN menggunakan data hingga empat periode sebelumnya sebagai input. Tiga lapisan tersembunyi, dengan 15 neuron pada tiap

lapisannya, dipilih melalui proses *trial-and-error*, dimana penambahan/pengurangan jumlah neuron lebih/kurang dari 15 neuron gagal meningkatkan kinerja model. Fungsi transfer yang digunakan pada lapisan tersembunyi adalah *Tan-sigmoid* dan pada lapisan output adalah *linear*, yang merupakan pengaturan *default* bagi NARNN. Untuk algoritma pembelajaran dipilih *LM Backpropagation*. Arsitektur NARNN yang digunakan dalam penelitian ini terangkum dalam Tabel 1. Gambaran NARNN secara utuh dapat dilihat pada lampiran.

Tabel 1 Arsitektur Model JST

Neuron pada tiap lapisan (Input-Hidden-Output)	Input Variable	Output
4-15-1	$y_{t-1}, y_{t-2},$ y_{t-3}, y_{t-4}	y_t

4.3. Evaluasi Prakiraan

Evaluasi Kinerja prakiraan masing-masing model pada Tabel 2 menunjukkan bahwa penggunaan metode JST dalam menyusun model prakiraan kas pemerintah dapat meningkatkan kinerja pemodelan jika dibandingkan dengan penggunaan metode ARIMA.

Tabel 2 Perbandingan kinerja masing-masing model prakiraan

Metode	MSE
ARIMA	6.8361
JST	4.6862

5. KESIMPULAN DAN SARAN

Kualitas Pengelolaan Kas Pemerintah yang baik tidak hanya penting bagi suatu pemerintahan, tetapi juga bagi negara secara keseluruhan. Krisis yang dialami Yunani tahun 2010 memberikan gambaran tentang apa yang bisa terjadi jika suatu pemerintahan gagal dalam mengelola kas mereka secara efektif. Tidak sedikit penelitian yang mengemukakan perlunya penguatan prakiraan kas pemerintah untuk mencapai pengelolaan kas yang lebih efektif. Namun demikian, penelitian yang berfokus pada prakiraan kas pemerintah masih sangat jarang. Makalah ini berkontribusi untuk mengisi kesenjangan pada literatur dengan menyelidiki metode pemodelan yang dapat digunakan untuk menghasilkan model prakiraan kas pemerintah dengan tingkat akurasi prakiraan terbaik. Studi ini menggunakan data harian Pengeluaran Tidak Terjadwal pemerintah Indonesia dari tahun 2009 sampai 2015, yang dibagi menjadi data pelatihan (2009-2013) dan data pengujian (2014-2015). Data tersebut selanjutnya digunakan untuk menyusun model

prakiraan kas pemerintah dengan menggunakan metode ARIMA dan JST.

Pada penelitian ini, penulis membuktikan bahwa prakiraan kas pemerintah dapat dilakukan dengan menganalisis data historis pengeluaran pemerintah. Berdasarkan hasil temuan penelitian ini, dapat dibuktikan bahwa metode ARIMA dan JST dapat digunakan untuk menyusun model prakiraan kas pemerintah. Di saat yang sama, penggunaan metode JST pada data historis harian pengeluaran pemerintah terbukti memiliki kinerja yang lebih baik dalam memprediksi kebutuhan dana di masa depan dibandingkan dengan menggunakan metode ARIMA. Hal ini menunjukkan bahwa metode JST dapat menjadi alternatif dalam menyusun model prakiraan kas pemerintah yang lebih akurat.

Hasil penelitian ini sejalan dengan pendapat Widodo, et al., (2014) bahwa dengan menggunakan pendekatan *top-down* untuk mengeksplorasi data historis terbukti dapat meningkatkan akurasi prakiraan kas pemerintah. Oleh karena itu, penulis menyarankan kepada Pengelola Kas Pemerintah lebih mendorong upaya pengembangan model prakiraan kas pemerintah yang berbasis pada eksplorasi pola historis pengeluaran pemerintah yang tersedia pada *database*.

Temuan penelitian ini menunjukkan bahwa kinerja model yang dikembangkan dengan menggunakan teknik *Machine Learning*, dalam hal ini JST, terbukti lebih baik daripada model yang dikembangkan dengan menggunakan metode statistik, ARIMA model. Dukungan teknologi - baik berupa *hardware* dan *software* - perlu diberikan guna pengembangan model prakiraan kas pemerintah berbasis *Machine Learning*, sebagaimana dukungan yang selama ini telah diberikan dalam menyampaikan informasi dari satuan kerja kepada Pengelola Kas Pemerintah dalam rangka menunjang sistem perencanaan kas dengan pendekatan *bottom-up*.

6. IMPLIKASI DAN KETERBATASAN

Penelitian ini memberikan jalan bagi penelitian berikutnya tentang pemodelan prakiraan kas pemerintah. Meski penelitian ini menggunakan pemerintah Indonesia sebagai studi kasus, namun kerangka berfikir yang digunakan dapat pula diimplementasikan pada pemerintahan maupun sektor publik lainnya. Penelitian ini hanya menggunakan total Pengeluaran Tidak Terjadwal dalam menyusun model prakiraan kas pemerintah. Hal tersebut membatasi penelitian ini dalam mengeksplorasi kontribusi masing-masing jenis Pengeluaran Tidak Terjadwal terhadap tingkat akurasi model. Kedepan, penulis berharap penelitian selanjutnya dapat menggunakan data masing-masing jenis Pengeluaran Tidak Terjadwal

dalam menyusun model prakiraan kas pemerintah sehingga dapat diperoleh alternatif penyusunan model prakiraan kas pemerintah yang lebih akurat.

PENGHARGAAN

Penulis mengucapkan terima kasih kepada seluruh pihak yang membantu penyelesaian penelitian ini khususnya kepada *Australia Awards Scholarship* dan Direktorat Sistem Informasi dan Teknologi Perbendaharaan, Direktorat Jenderal Perbendaharaan. Penghargaan juga perlu penulis sampaikan kepada Saudara Rakhmat Jati Waluyo yang membantu penulis dalam menyediakan data yang digunakan pada penelitian ini. Penelitian ini ditulis dengan memperhatikan kaidah-kaidah penulisan karya tulis ilmiah dengan mengutamakan prinsip kehati-hatian guna menghindari kesalahan. Penulis bertanggung jawab sepenuhnya terhadap hasil penelitian termasuk kesalahan yang mungkin terjadi.

DAFTAR PUSTAKA

- Acuna, G., Ramirez, C., & Curilem, M. (2012). Comparing NARX dan NARMAX models using ANN dan SVM for cash demand forecasting for ATM. In *Neural Networks (IJCNN), The 2012 International Joint Conference on* (pp. 1-6).
- Arghyrou, M. G., & Tsoukalas, J. D. (2011). The Greek Debt Crisis: Likely Causes, Mechanics and Outcomes. *World Economy*, 34, 173-191.
- Ariyo, A. A., Adewumi, A. O., & Ayo, C. K. (2014). Stock price prediction using the ARIMA model. In *Computer Modelling and Simulation (UKSim), 2014 UKSim-AMSS 16th International Conference* (pp. 106-112): IEEE.
- Ayala, H. V. H., & Coelho, L. d. S. (2016). Cascaded evolutionary algorithm for nonlinear system identification based on correlation functions and radial basis functions neural networks. *Mechanical Systems and Signal Processing*, 68-69, 378-393.
- Box, G. E., & Jenkins, G. M. (1976). Time series analysis: Forecasting and control. In *Holden-Day series in time series analysis: Holden-Day*.
- Dandekar, P. V., & Ranade, K. M. (2015). ATM Cash Flow Management. *International Journal of Innovation, Management and Technology*, 6, 343.
- Dudek, G. (2016). Multilayer perceptron for GEFCom2014 probabilistic electricity price forecasting. *International Journal of Forecasting*.
- Ebtehaj, I., & Bonakdari, H. (2016). Bed load sediment transport estimation in a clean pipe using multilayer perceptron with different training algorithms. *KSCE Journal of Civil Engineering*, 20, 581-589.
- Gujarati, D. N., & Porter, D. C. (2009). *Basic Econometrics* (5th ed.). Boston: McGraw-Hill/Irwin.
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation* (2 ed.). USA: Prentice Hall International, Inc.
- Iqbal, M., & Naveed, A. (2016). Forecasting inflation: Autoregressive integrated moving average model. *European Scientific Journal*, 12.
- Kamini, V., Ravi, V., Prinzie, A., & Van den Poel, D. (2013). Cash demand forecasting in ATMs by clustering and neural networks. *Eur. J. Oper. Res.*, 232, 383-392.
- Khdanelwal, I., Adhikari, R., & Verma, G. (2015). Time Series Forecasting Using Hybrid ARIMA and ANN Models Based on DWT Decomposition. *Procedia Computer Science*, 48, 173-179.
- Kouretas, G. P., & Vlamis, P. (2010). The Greek crisis: causes and implications. *Panoeconomicus*, 57, 391-404.
- Lienert, I. (2009). Modernizing Cash Management. *IMF Technical Notes and Manuals (Washington: International Monetary Fund)*.
- Menteri Keuangan Republik Indonesia. (2015). Peraturan Menteri Keuangan Nomor 127/PMK.02/2015 tentang Klasifikasi Anggaran. Kementerian Keuangan. Jakarta.
- Mishra, P. S., & Dehuri, S. (2014). Potential Indicators Based Neural Networks for Cash Forecasting of an ATM. *International Journal of Information Systems and Social Change (IJISSC)*, 5, 41-57.
- Mondal, P., Shit, L., & Goswami, S. (2014). Study of effectiveness of time series modeling (ARIMA) in forecasting stock prices. *International Journal of Computer Science, Engineering and Applications*, 4, 13.
- Mu, Y. (2006). Government Cash Management: Good Practice & Capacity-Building Framework. *World Bank Financial Discussion Series*.

- Negnevitsky, M. (2005). *Artificial intelligence: a guide to intelligent systems* (2nd ed.): Pearson Education.
- Ruiz, L. G. B., Cuéllar, M. P., Calvo-Flores, M. D., & Jiménez, M. D. C. P. (2016). An Application of Non-Linear Autoregressive Neural Networks to Predict Energy Consumption in Public Buildings. *Energies*, 9, 684.
- Storkey, I. (2003). Government Cash and Treasury Management Reform. *Asian Development Bank, Governance Brief*.
- Venkatesh, K., Ravi, V., Prinzie, A., & Van den Poel, D. (2014). Cash demand forecasting in ATMs by clustering and neural networks. *European Journal of Operational Research*, 232, 383-392.
- Wang, W.-c., Chau, K.-w., Qiu, L., & Chen, Y.-b. (2015). Improving forecasting accuracy of medium and long-term runoff using artificial neural network based on EEMD decomposition. *Environmental Research*, 139, 46-54.
- Widodo, R., Sihombing, W. P., Budhisusetyo, A., & Harjowiryono, M. (2014). *Cash Management Reform in Indonesia : Making The State Money Work Harder*. Washington, DC: World Bank Group.
- Williams, M. (2009). Government Cash Management: International Practice. In: Oxford Policy Management Working Paper 2009-01.
- Williams, M. (2010). Government Cash Management: Its Interaction with Other Financial Policies. *IMF Technical Notes and Manuals (Washington: International Monetary Fund)*.
- Yildiz, B., & Yezegel, A. (2010). Fundamental Analysis with Artificial Neural Network. *The international journal of business and finance research*, 4, 149.
- Zhang, G. P., Patuwo, B. E., & Hu, M. Y. (2001). A simulation study of artificial neural networks for nonlinear time-series forecasting. *Computers & Operations Research*, 28, 381-396.
- Zhang, P. G. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.

Lampiran

I. Hasil Pengujian Unit Akar (Unit Root Test)

Null Hypothesis: LT has a unit root

Exogenous: Constant

Lag Length: 1 (Automatic - based on SIC, maxlag=22)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-13.42640	0.0000
Test critical values:		
1% level	-3.435471	
5% level	-2.863689	
10% level	-2.567964	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(LT)

Method: Least Squares

Date: 08/09/17 Time: 12:30

Sample (adjusted): 1/07/2009 12/31/2013

Included observations: 1226 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LT(-1)	-0.285332	0.021252	-13.42640	0.0000
D(LT(-1))	-0.221019	0.026770	-8.256313	0.0000
C	7.752799	0.577987	13.41346	0.0000
R-squared	0.234505	Mean dependent var		0.025260
Adjusted R-squared	0.233253	S.D. dependent var		2.381020
S.E. of regression	2.084918	Akaike info criterion		4.309780
Sum squared resid	5316.236	Schwarz criterion		4.322288
Log likelihood	-2638.895	Hannan-Quinn criter.		4.314486
F-statistic	187.3298	Durbin-Watson stat		1.990992
Prob(F-statistic)	0.000000			

II. Hasil Estimasi ARIMA(3,0,2) dengan mengikutsertakan lag ke-1 dan ke-2 pada MA term

Dependent Variable: LT

Method: ARMA Maximum Likelihood (OPG - BHHH)

Date: 08/09/17 Time: 12:33

Sample: 1/05/2009 12/31/2013

Included observations: 1228

Convergence achieved after 334 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	26.96171	0.808919	33.33053	0.0000
AR(1)	0.758322	0.205765	3.685379	0.0002
AR(2)	-0.368576	0.160810	-2.291996	0.0221
AR(3)	0.342210	0.040863	8.374532	0.0000
MA(1)	-0.206714	0.206854	-0.999322	0.3178
MA(2)	0.477944	0.059116	8.084901	0.0000
SIGMASQ	4.612157	0.065777	70.11855	0.0000

R-squared	0.518621	Mean dependent var	27.04481
Adjusted R-squared	0.516256	S.D. dependent var	3.096602
S.E. of regression	2.153741	Akaike info criterion	4.378754
Sum squared resid	5663.729	Schwarz criterion	4.407901
Log likelihood	-2681.555	Hannan-Quinn criter.	4.389721
F-statistic	219.2438	Durbin-Watson stat	2.019885
Prob(F-statistic)	0.000000		

Inverted AR Roots	.82	-.03-.65i	-.03+.65i
Inverted MA Roots	.10+.68i	.10-.68i	

III. Hasil Estimasi ARIMA(3,0,2) dengan hanya mengikutsertakan lag ke-2 pada MA term

Dependent Variable: LT
 Method: ARMA Maximum Likelihood (OPG - BHHH)
 Date: 07/31/17 Time: 21:30
 Sample: 1/05/2009 12/31/2013
 Included observations: 1228
 Convergence achieved after 324 iterations
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	26.95779	0.820745	32.84551	0.0000
AR(1)	0.551774	0.009244	59.68908	0.0000
AR(2)	-0.196891	0.046897	-4.198353	0.0000
AR(3)	0.355132	0.034943	10.16303	0.0000
MA(2)	0.410233	0.045920	8.933560	0.0000
SIGMASQ	4.618623	0.065275	70.75608	0.0000

R-squared	0.517946	Mean dependent var	27.04481
Adjusted R-squared	0.515974	S.D. dependent var	3.096602
S.E. of regression	2.154368	Akaike info criterion	4.378521
Sum squared resid	5671.669	Schwarz criterion	4.403503
Log likelihood	-2682.412	Hannan-Quinn criter.	4.387921
F-statistic	262.5974	Durbin-Watson stat	2.021085
Prob(F-statistic)	0.000000		

Inverted AR Roots	.83	-.14+.64i	-.14-.64i
Inverted MA Roots	-.00+.64i	-.00-.64i	

Arsitektur NARNN

