

PERAMALAN KONSUMSI LISTRIK JANGKA PENDEK DENGAN ARIMA MUSIMAN GANDA DAN ELMAN-RECURRENT NEURAL NETWORK

Suhartono¹ A.J Endharta²

^{1,2}Jurusan Statistika FMIPA, Fakultas Teknologi Informasi, Institut Teknologi Sepuluh Nopember
Email: ¹suhartono@statistika.its.ac.id, ²alfonsus_je@yahoo.com

ABSTRACT

Neural network (NN) is one of many method used to predict the electricity consumption per hour in many countries. NN method which is used in many previous studies is Feed-Forward Neural Network (FFNN) or Autoregressive Neural Network (AR-NN). AR-NN model is not able to capture and explain the effect of moving average (MA) order on a time series of data. This research was conducted with the purpose of reviewing the application of other types of NN, that is Elman-Recurrent Neural Network (Elman-RNN) which could explain MA order effect and compare the result of prediction accuracy with multiple seasonal ARIMA (Autoregressive Integrated Moving Average) models. As a case study, we used data electricity consumption per hour in Mengare Gresik. Result of analysis showed that the best of double seasonal Arima models suited to short-term forecasting in the case study data is ARIMA([1,2,3,4,6,7,9,10,14,21,33],1,8)(0,1,1)²⁴ (1,1,0)¹⁶⁸. This model produces a white noise residuals, but it does not have a normal distribution due to suspected outlier. Outlier detection in iterative produce 14 innovation outliers. There are 4 inputs of Elman-RNN network that were examined and tested for forecasting the data, the input according to lag Arima, input such as lag Arima plus 14 dummy outlier, inputs are the lag-multiples of 24 up to lag 480, and the inputs are lag 1 and lag multiples of 24 ± 1. All of four network uses one hidden layer with tangent sigmoid activation function and one output with a linear function. The result of comparative forecast accuracy through value of MAPE out-sample showed that the fourth networks, namely Elman-RNN (22, 3, 1), is the best model for forecasting electricity consumption per hour in short term in Mengare Gresik.

Keywords: multiple seasonal ARIMA, Recurrent-Neural Network, electricity consumption per hour

ABSTRAK

Neural network (NN) adalah salah satu metode yang banyak digunakan untuk meramalkan konsumsi listrik per jam jangka pendek di berbagai negara. Metode NN yang digunakan dalam banyak penelitian sebelumnya adalah Feed-Forward Neural Network (FFNN) atau Autoregressive Neural Network (AR-NN). Model AR-NN ini tidak dapat menangkap dan menjelaskan efek orde moving average (MA) pada suatu data runtun waktu. Penelitian ini dilakukan dengan tujuan mengkaji penerapan tipe NN yang lain, yaitu Elman-Recurrent Neural Network (Elman-RNN) yang dapat menjelaskan efek orde MA dan membandingkan hasil ketepatan ramalannya dengan model ARIMA (Autoregressive Integrated Moving Average) musiman ganda. Sebagai studi kasus digunakan data konsumsi listrik per jam di Mengare Gresik. Hasil analisis menunjukkan bahwa model ARIMA musiman ganda terbaik yang sesuai untuk peramalan jangka pendek pada data studi kasus adalah ARIMA([1,2,3,4,6,7,9,10,14,21,33],1,8)(0,1,1)²⁴ (1,1,0)¹⁶⁸. Model ini menghasilkan residual yang white noise, namun tidak berdistribusi normal yang diduga karena adanya outlier. Deteksi outlier secara iteratif menghasilkan 14 innovation outlier. Ada 4 input jaringan Elman-RNN yang dikaji dan dicobakan untuk peramalan pada data, yaitu input sesuai lag ARIMA, input seperti lag ARIMA ditambah dengan 14 dummy outlier, input adalah lag-lag kelipatan 24 hingga lag ke 480, serta inputnya adalah lag 1 dan lag kelipatan 24 ± 1. Keempat jaringan ini menggunakan satu lapisan tersembunyi dengan fungsi aktivasi tangent sigmoid dan satu output dengan fungsi linier. Hasil perbandingan akurasi ramalan melalui nilai MAPE out-sample menunjukkan bahwa jaringan keempat, yaitu Elman-RNN (22,3,1), merupakan model terbaik untuk peramalan konsumsi listrik per jam jangka pendek di Mengare Gresik.

Keywords: ARIMA musiman ganda, Recurrent-Neural Network, konsumsi listrik per jam

PT PLN (Perusahaan Listrik Negara) adalah BUMN (Badan Umum Milik Negara) yang bertugas untuk menyediakan kebutuhan listrik di Indonesia. Kebutuhan listrik ini bergantung pada pemakaian peralatan listrik yang digunakan oleh masyarakat, sehingga PLN wajib menyesuaikan kebutuhan listrik masyarakat dari waktu ke waktu. PLN bertugas untuk memperkirakan daya listrik yang dikonsumsi pelanggan tiap jam. Perkiraan ini dibuat berdasarkan atas data penggunaan daya listrik pada waktu sebelumnya.

Perkiraan besarnya penggunaan daya listrik digunakan untuk mengoptimalkan penggunaan daya listrik di masyarakat, sehingga tidak akan terjadi pemborosan ataupun pe-

madaman listrik. Perkiraan daya listrik yang diminta oleh pelanggan dapat dilakukan dengan menggunakan beberapa metode peramalan, antara lain model ARIMA musiman ganda dan metode *Neural Network* (NN). Beberapa penelitian yang berkaitan dengan peramalan daya listrik jangka pendek dengan NN dapat dilihat pada makalah-makalah yang ditulis oleh Kiartzis dkk.(1995)[1], Husen(2001) [2], Taylor dkk(2006) [3], dan Ristiana(2008) [4].

Metode *neural network* yang digunakan dalam penelitian tersebut yaitu *Feed-Forward Neural Network* (FFNN) atau dikenal dengan model AR-NN. Model ini tidak dapat menangkap dan menjelaskan efek orde *moving aver-*

age (MA) pada suatu data runtun waktu. Pada beberapa penelitian sebelumnya, baik kasus di luar negeri atau di Indonesia, menunjukkan bahwa model ARIMA untuk data konsumsi listrik cenderung melibatkan orde MA [3, 4].

Penelitian ini dilakukan dengan tujuan mengkaji penerapan tipe NN lain yaitu *Elman-Recurrent Neural Network* (RNN) yang dapat menjelaskan efek orde AR dan MA secara simultan untuk peramalan data runtun waktu musiman ganda, dan membandingkan ketepatan ramalannya dengan model ARIMA musiman ganda.

METODE PERAMALAN

Ada banyak metode peramalan kuantitatif dengan pendekatan *time series* yang dapat digunakan untuk peramalan data runtun waktu. Pada bagian ini akan dijelaskan secara ringkas beberapa metode peramalan yang digunakan dalam penelitian ini yaitu model ARIMA dan Neural Network.

Model ARIMA

Salah satu model runtun waktu yang populer dan banyak digunakan adalah model ARIMA. Model *autoregressive* (AR) menunjukkan adanya keterkaitan antara suatu nilai pada waktu sekarang (Z_t) dengan nilai pada waktu sebelumnya (Z_{t-k}), ditambah dengan suatu nilai acak, sedangkan model *moving average* (MA) menunjukkan adanya keterkaitan antara nilai pada waktu sekarang (Z_t) dengan nilai residual pada waktu-waktu sebelumnya (a_{t-k} dengan $k = 1, 2, \dots$) [5]. Model ARIMA (p, d, q) merupakan gabungan model AR(p) dan MA(q), dengan pola data yang tidak stasioner dan dilakukan *differencing* orde d . Bentuk umum dari model ARIMA(p, d, q) adalah:

$$\phi_p(B)(1-B)^d Z_t = \theta_q(B)a_t \quad (1)$$

dengan p adalah orde model AR, q adalah orde model MA, d adalah orde *differencing*, dan

$$\begin{aligned} \phi_p(B) &= (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) \\ \theta_q(B) &= (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \end{aligned}$$

Generalisasi dari model ARIMA untuk data yang memiliki pola musiman, yang ditulis dengan ARIMA(p, d, q) (P, D, Q)^s dirumuskan oleh Wei (2006) sebagai berikut:

$$\phi_p(B)\Phi_P(B^s)(1-B)^d(1-B^s)^D Z_t = \theta_q(B)\Theta_Q(B^s)a_t \quad (2)$$

dengan s adalah periode musiman, dan

$$\begin{aligned} \Phi_P(B^s) &= (1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_P B^{Ps}) \\ \Theta_Q(B^s) &= (1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_Q B^{Qs}) \end{aligned}$$

Data konsumsi listrik jangka pendek memiliki pola musiman ganda yaitu musiman harian dan musiman mingguan. Model ARIMA dengan pola musiman ganda multiplikatif sebagai generalisasi dari model ARIMA musiman, ditulis dengan ARIMA(p, d, q)(P_1, D_1, Q_1)^{s1}(P_2, D_2, Q_2)^{s2}, mempunyai bentuk umum sebagai berikut:

$$\phi_p(B)\Phi_{P_1}(B^{s_1})\Phi_{P_2}(B^{s_2})(1-B)^d(1-B^{s_1})^{D_1}(1-B^{s_2})^{D_2} Z_t = \theta_q(B)\Theta_{Q_1}(B^{s_1})\Theta_{Q_2}(B^{s_2})a_t \quad (3)$$

dengan s_1 dan s_2 adalah periode musiman yang berbeda.

Salah satu metode yang dapat digunakan untuk estimasi parameter model ARIMA adalah metode *Maximum Likelihood Estimation* (MLE). Asumsi yang diperlukan pada metode MLE adalah error a_t berdistribusi normal [6]. Oleh karena itu, fungsi kepadatan peluangnya adalah:

$$f(a_t|\sigma_a^2) = (2\pi\sigma_a^2)^{-\frac{1}{2}} \exp\left(-\frac{a_t^2}{2\sigma_a^2}\right) \quad (4)$$

Karena error bersifat independen, maka distribusi bersama dari a_1, a_2, \dots, a_n adalah:

$$f(a_1, a_2, \dots, a_n|\sigma_a^2) = (2\pi\sigma_a^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma_a^2} \sum_{t=1}^n a_t^2\right) \quad (5)$$

Error a_t dapat dinyatakan dalam fungsi Z_t , dan parameter-parameter ϕ, θ, σ_a^2 serta error-error sebelumnya. Secara umum bentuk a_t adalah:

$$a_t = Z_t - \phi_1 Z_{t-1} - \dots - \phi_p Z_{t-p} + \theta_1 a_{t-1} + \dots + \theta_q a_{t-q} \quad (6)$$

Fungsi likelihood untuk parameter model jika diketahui data pengamatan adalah:

$$L(\phi, \theta, \sigma_a^2|Z) = (2\pi\sigma_a^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma_a^2} S(\phi, \theta)\right) \quad (7)$$

dengan:

$$S(\phi, \theta) = \sum_{t=1}^n (Z_t - \phi_1 Z_{t-1} - \dots - \phi_p Z_{t-p} + \phi_p a_{t-1} + \dots + \phi_q a_{t-q})^2 \quad (8)$$

Fungsi log likelihood yang diperoleh adalah:

$$\begin{aligned} l(\phi, \theta, \sigma_a^2|Z) &= -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log(\sigma_a^2) \\ &\quad - \frac{1}{2\sigma_a^2} S(\phi, \theta) \end{aligned} \quad (9)$$

Maksimum fungsi *log likelihood* dihitung dengan mencari turunan pertama persamaan 9 terhadap masing-masing parameter dan disamakan dengan nol.

$$\begin{aligned} \frac{\partial l(\phi, \theta, \sigma_a^2|Z)}{\partial \phi} &= 0; \quad \frac{\partial l(\phi, \theta, \sigma_a^2|Z)}{\partial \theta} = 0; \\ \frac{\partial l(\phi, \theta, \sigma_a^2|Z)}{\partial \sigma_a^2} &= 0 \end{aligned}$$

Untuk mendapatkan standar baku parameter yang diestimasi dengan metode MLE, digunakan matriks informasi [6], dinotasikan dengan $I(\phi, \theta)$. Matriks ini diperoleh dengan menghitung dahulu derivatif kedua terhadap setiap parameternya, yang dinotasikan dengan l_{ij} .

$$l_{ij} = \frac{\partial^2 l(\beta, \sigma_a^2|Z)}{\partial \beta_i \partial \beta_j} \quad (10)$$

dan

$$I(\beta) = -E(l_{ij}) \quad (11)$$

Varians parameter dinotasikan dengan $V(\hat{\beta})$ dan standar baku parameternya adalah $SE(\hat{\beta})$.

$$V(\hat{\beta}) = [I(\hat{\beta})]^{-1} \quad (12)$$

dan

$$SE(\hat{\beta}) = [V(\hat{\beta})]^{1/2} \quad (13)$$

Parameter yang telah diperoleh diuji signifikansinya. Jika misalkan, secara umum parameter model ARIMA dinotasikan dengan β maka signifikansi parameter β diuji dengan hipotesis berikut:

$$\begin{aligned} H_0 : \beta &= 0 \\ H_1 : \beta &\neq 0 \end{aligned}$$

Statistik uji yang digunakan adalah

$$t_{hitung} = \frac{\hat{\beta}}{SE(\hat{\beta})} \quad (14)$$

Untuk tingkat signifikansi pengujian sebesar α dan p menyatakan banyaknya parameter dalam model, hipotesis nol ditolak bila:

$$|t_{hitung}| > t_{\frac{\alpha}{2}, n-p},$$

yang berarti parameter model adalah signifikan atau berbeda dengan nol.

Neural Network

Secara umum *Neural Network* (NN) memiliki beberapa komponen yaitu neuron, lapisan, fungsi aktivasi, dan bobot. Pemodelan NN dilihat pada bentuk jaringan yang terdiri dari jumlah neuron pada lapisan input, jumlah neuron pada lapisan tersembunyi (*hidden layer*) dan jumlah neuron pada lapisan output, serta fungsi aktivasi yang digunakan. *Feed Forward Neural Network* (FFNN) merupakan bentuk model NN yang banyak digunakan untuk peramalan data runtun waktu [7]. Model FFNN dalam pemodelan statistik untuk peramalan runtun waktu dapat dipandang sebagai suatu model *nonlinear autoregressive*. Bentuk ini mempunyai keterbatasan, yaitu hanya dapat menangkap dan menjelaskan efek *autoregressive* (AR) pada data runtun waktu.

Salah satu bentuk NN yang lebih fleksibel daripada FFNN adalah *Recurrent Neural Network* (RNN). Model RNN dikatakan fleksibel karena output jaringan dijadikan sebagai input untuk mendapatkan output berikutnya. Model RNN juga disebut dengan *Autoregressive Moving Average-Neural Network* (ARMA-NN), karena selain himpunan beberapa *lag* variabel respon atau target sebagai input, juga melibatkan lag-lag dari selisih prediksi target dengan nilai aktual target atau yang dikenal dengan lag-lag *error* [8]. Secara umum bentuk arsitektur model RNN sama dengan model ARMA(p, q). Hal yang membedakan adalah fungsi runtun waktu bersifat nonlinier pada model RNN dan linier pada model ARMA(p, d, q). Sehingga model RNN dikatakan sebagai model *autoregressive moving average* yang nonlinier.

Fungsi aktivasi yang digunakan dalam lapisan tersembunyi pada penelitian ini adalah fungsi *tangent sigmoid*, sedangkan fungsi aktivasi pada lapisan output adalah fungsi linier. Pemilihan fungsi aktivasi ini didasarkan bahwa arsitektur NN dengan fungsi aktivasi tersebut dapat digunakan secara baik untuk pendekatan suatu fungsi [9, 10], seperti pada kasus peramalan konsumsi listrik ini. Bentuk fungsi aktivasi *tangent sigmoid* dan linier berturut-turut adalah

$$f(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (15)$$

dan

$$f(x) = x \quad (16)$$

Arsitektur jaringan Elman-RNN dengan ARMA(2,1)-NN dan 4 unit neuron pada lapisan tersembunyi ditunjukkan pada Gambar 1.

Bobot dan bias dalam model yang diperoleh dengan Elman-RNN diestimasi dengan algoritma backpropagation. Model umum jaringan RNN dengan satu lapisan tersembunyi, dengan q unit input dan p unit pada lapisan tersembunyi adalah

$$\hat{Y} = f^o \left[\beta_0 + \sum_{j=1}^p \left(\beta_j f^h \left(\gamma_{j0} + \sum_{i=1}^q \gamma_{ji} X_i \right) \right) \right] \quad (17)$$

dengan β_j adalah besar bobot untuk unit ke- j pada lapisan tersembunyi, γ_{ji} adalah besar bobot dari input ke- i ke unit ke- j pada lapisan tersembunyi, $f^h(x)$ adalah fungsi aktivasi pada lapisan tersembunyi dan $f^o(x)$ adalah fungsi aktivasi pada lapisan output.

Chong dan Zak (1996) menjelaskan bahwa untuk memperoleh bobot dan bias dilakukan estimasi dengan meminimumkan nilai E pada Persamaan berikut

$$E = \frac{1}{2} \sum_{k=1}^n [Y_{(k)} - \hat{Y}_{(k)}]^2 \quad (18)$$


Minimisasi Persamaan 18 dilakukan dengan metode *Gradient Descent* dengan momentum. Metode *Gradient Descent* dengan momentum m , $0 < m < 1$, dirumuskan sebagai

$$w^{(t+1)} = w^{(t)} - \left(m \cdot dw^{(t)} + (1 - m) \eta \frac{\partial E}{\partial w} \right) \quad (19)$$

dengan dw adalah perubahan besar bobot atau bias, η adalah koefisien pembelajaran yang ditentukan, $0 < \eta < 1$.

Untuk memecahkan persamaan tersebut, dilakukan derivatif parsial E terhadap tiap bobot dan bias w dengan aturan berantai. Derivatif parsial E terhadap bobot β_j adalah

$$\begin{aligned} \frac{\partial E}{\partial \beta_j} &= - \sum_{k=1}^n [Y_{(k)} - \hat{Y}_{(k)}] f^{o'} \\ &\quad \left(\beta_0 + \sum_{l=1}^p \beta_l V_{l(k)} \right) V_{j(k)} \end{aligned} \quad (20)$$



Gambar 1: Arsitektur jaringan Elman-RNN(2,4,1) atau ARMA(2,1)-NN

Persamaan 20 disederhanakan menjadi

$$\frac{\partial E}{\partial \beta_j} = - \sum_{k=1}^n \delta_{(k)}^o V_{j(k)} \quad (21)$$

dengan

$$\delta_{(k)}^o = [Y_{(k)} - \hat{Y}_{(k)}] f^{o'} \left(\beta_0 + \sum_{l=1}^p \beta_l V_{l(k)} \right)$$

Dengan cara yang sama dilakukan derivatif parsial E terhadap β_0 , γ_{li} , dan γ_{l0} , sehingga diperoleh

$$\frac{\partial E}{\partial \beta_0} = - \sum_{k=1}^n \delta_{(k)}^o, \quad (22)$$

$$\begin{aligned} \frac{\partial E}{\partial \gamma_{ji}} = & - \sum_{k=1}^n [Y_{(k)} - \hat{Y}_{(k)}] f^{o'} \\ & \left(\beta_0 + \sum_{l=1}^p \beta_l V_{l(k)} \right) \times \beta_j f^{h'} \\ & \left(\gamma_{l0} + \sum_{i=1}^q \gamma_{li} X_{i(k)} \right) X_{i(k)} \end{aligned} \quad (23)$$

atau

$$\frac{\partial E}{\partial \beta_{ji}} = - \sum_{k=1}^n \delta_{(k)}^h X_{i(k)}, \quad (24)$$

dan

$$\frac{\partial E}{\partial \beta_{j0}} = - \sum_{k=1}^n \delta_{(k)}^h, \quad (25)$$

dengan

$$\delta_{(k)}^h = \delta_{(k)}^o \beta_j f^{h'} \left(\gamma_{l0} + \sum_{i=1}^q \gamma_{li} X_{i(k)} \right). \quad (26)$$

Berdasarkan hasil derivatif tersebut dapat diestimasi bobot dan bias model dengan metode *Gradient Descent* dengan momentum. *Updating* bobot dan bias pada lapisan output berturut-turut adalah

$$\beta_j^{(s+1)} = \beta_j^{(s)} - \left(m \cdot dw^{(s)} + (m-1) \eta \sum_{k=1}^n \delta_{(k)}^o V_{j(k)} \right) \quad (27)$$

dan

$$\beta_0^{(s+1)} = \beta_0^{(s)} - \left(m \cdot dw^{(s)} + (m-1) \eta \sum_{k=1}^n \delta_{(k)}^o \right) \quad (28)$$

Sedangkan persamaan *update* untuk bobot dan bias pada lapisan tersembunyi berturut-turut adalah

$$\begin{aligned} \gamma_{ji}^{(s+1)} = & \gamma_{ji}^{(s)} - \\ & \left(m \cdot dw^{(s)} + (m-1) \eta \sum_{k=1}^n \delta_{(k)}^h X_{i(k)} \right) \end{aligned} \quad (29)$$

dan

$$\begin{aligned} \gamma_{j0}^{(s+1)} = & \gamma_{j0}^{(s)} - \\ & \left(m \cdot dw^{(s)} + (m-1) \eta \sum_{k=1}^n \delta_{(k)}^h \right) \end{aligned} \quad (30)$$

dw pada Persamaan 27 hingga 30 merupakan besar perubahan bobot atau bias yang bersangkutan, m adalah besar momentum, dan η adalah koefisien pembelajaran.

Pemilihan Model Peramalan Terbaik

Proses pemilihan model peramalan terbaik dilakukan dengan terlebih dahulu membagi data menjadi dua bagian, yaitu data *in-sample* dan data *out-sample*. Pada data *in-sample* pemilihan model terbaik dilakukan dengan menggunakan kriteria *Akaike's Information Criteria* (AIC) dan *Schwartz's Bayesian Criteria* (SBC). Sedangkan untuk data *out-sample* digunakan *Mean Absolute Percentage Error*

(MAPE) dan *Root of Mean Squared Error*(RMSE). Nilai AIC dirumuskan dengan

$$AIC = n \ln(\hat{\sigma}_a^2) + 2p \quad (31)$$

Nilai SBC dirumuskan dengan

$$SBC = n \ln(\hat{\sigma}_a^2) + p \ln(n) \quad (32)$$

MAPE dapat dihitung berdasarkan rumus

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100\% \quad (33)$$

sedangkan nilai RMSE dihitung dengan

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (34)$$

Dalam hal ini, n adalah banyaknya pengamatan, p adalah banyaknya parameter dalam model, $\hat{\sigma}_a^2$ adalah nilai σ_a^2 yang diestimasi dengan MLE. Perhitungan nilai $\hat{\sigma}_a^2$ adalah

$$\hat{\sigma}_a^2 = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2 \quad (35)$$

KETENAGALISTRIKAN

Berdasarkan UU No. 20 Tahun 2002 tentang Ketenagalistrikan, tenaga listrik adalah suatu bentuk energi sekunder yang dibangkitkan, ditransmisikan, dan didistribusikan untuk segala macam keperluan, tidak termasuk listrik yang digunakan untuk komunikasi, elektronika, atau isyarat. Besar kecilnya konsumsi tenaga listrik ditentukan sepenuhnya oleh para pelanggan, yaitu tergantung bagaimana para pelanggan akan menggunakan alat-alat listriknya kemudian PLN harus mengikuti kebutuhan tenaga listrik para pelanggan ini dalam arti menyesuaikan daya listrik yang dibangkitkannya dari waktu ke waktu [11]. Apabila ada jutaan pelanggan yang harus dilayani, daya listrik yang harus dibangkitkan harus mencapai ribuan megawatt dan untuk ini diperlukan beberapa pembangkit listrik dan beberapa Gardu Induk.

Beban sistem tenaga listrik merupakan daya listrik yang dikonsumsi oleh para pemakai listrik. Besarnya beban sistem tidak dapat dihitung secara pasti karena besarnya tergantung pada kebutuhan pelanggan terhadap tenaga listrik. Oleh karena itu, besarnya beban sistem harus diperkirakan dan disebut perkiraan beban. Ada tiga kelompok perkiraan beban, yaitu perkiraan beban jangka panjang, perkiraan beban jangka menengah, dan perkiraan beban jangka pendek.

METODOLOGI PENELITIAN

Data yang digunakan dalam penelitian ini adalah data konsumsi listrik yang merupakan data sekunder dari PLN Gresik. Data yang diambil sebagai studi kasus adalah data konsumsi listrik per jam di Mengare Gresik, yang tercatat pada 1 Agustus hingga 23 September 2007. Data *in-sample*

dipilih pada tanggal 1 Agustus sampai dengan 15 September 2007, sedangkan data *out-sample* adalah 16-23 September 2007. Pembagian data khususnya data out-sample selama 1 minggu (168 pengamatan) ini diharapkan dapat menunjukkan efek musiman ganda, yaitu harian dan mingguan. Variabel dalam penelitian ini adalah konsumsi listrik tiap jam.

Langkah-langkah analisis data yang dilakukan adalah sebagai berikut: i) Melakukan pemodelan ARIMA musiman ganda; ii) Mendeteksi *outlier* secara iteratif; iii) Melakukan pemodelan Elman-RNN, dengan 4 macam input, yaitu : a) Input berdasarkan model ARIMA musiman ganda; b) Input berdasarkan model ARIMA musiman ganda dengan tambahan *outlier*; c) Input *lag* kelipatan 24 hingga 480; d) Input *lag* 1 dan *lag* kelipatan 24 ± 1 ; iv) Melakukan peramalan data *out-sample*; v) Membandingkan ketepatan ramalan antara model Elman-RNN dan ARIMA musiman ganda; vi) Meramalkan konsumsi listrik pada tanggal 24-30 September 2007 dengan model terbaik.

ANALISIS DATA DAN PEMBAHASAN

Hasil analisis deskriptif konsumsi listrik per jam dan per hari di Mengare, Gresik, dari tanggal 1 Agustus – 23 September 2007 dapat dilihat pada Tabel 1 dan 2. Dari Tabel 1 dapat diketahui bahwa konsumsi listrik paling besar pada jam 19.00 sebesar 3537 kW, sedangkan konsumsi listrik paling sedikit pada jam 07.00 sebesar 1665,2 kW. Hal ini diduga karena pada jam 07.00 pelanggan mematikan lampu, bersiap-siap berangkat kerja, meninggalkan rumah, dan menuju ke tempat kerja. Jam kerja pelanggan umumnya adalah mulai jam 09.00 hingga jam 17.00, sehingga kegiatan konsumsi listrik rumah tangga sedikit atau di bawah rata-rata konsumsi listrik keseluruhan. Sedangkan pada jam 18.00 pelanggan menyalakan lampu malam hari dan jam 19.00 pelanggan sudah kembali dari kegiatan kerja dan melakukan aktivitas di rumah, yang menggunakan banyak listrik seperti penggunaan alat-alat elektronik.

Berdasarkan hasil pada Tabel 2 dapat diketahui bahwa pada hari Selasa konsumsi listrik paling besar sebanyak 2469,5 kW, sedangkan konsumsi listrik paling sedikit pada hari Minggu sebanyak 2204,8 kW. Rata-rata konsumsi listrik hari Sabtu dan hari Minggu berada di bawah rata-rata konsumsi listrik keseluruhan yang disebabkan kedua hari tersebut merupakan akhir pekan, sehingga pelanggan cenderung untuk menghabiskan akhir pekan bersama keluarga di luar rumah. Namun, berdasarkan nilai standar deviasi terbesar pada hari Minggu, yaitu 660,3, dapat diduga juga bahwa ada pelanggan yang tidak meninggalkan rumah dan menghabiskan akhir pekan di rumah dengan mengonsumsi listrik seperti menonton televisi yang menghabiskan banyak daya listrik.

Hasil Model ARIMA Musiman Ganda

Proses pembentukan model ARIMA dilakukan berdasarkan prosedur Box-Jenkins (Box dkk., 1994), diawali dengan identifikasi orde model dari data yang sudah stasioner. Gambar 2 menunjukkan pola data konsumsi listrik per jam yang masih belum stasioner, khususnya pada periode musiman harian dan mingguan. Hal ini didukung oleh deskripsi data pada Tabel 1 dan 2 di atas yang me-

Tabel 1: Statistik Deskriptif Konsumsi Listrik per Jam

Jam	Pengamatan	Rata-Rata	St. Deviasi
0.00	54	2662,2	179,3
1.00	54	2521,5	165,2
2.00	54	2453,3	173,4
3.00	54	2432,6	219,2
4.00	54	2474,8	232,2
5.00	54	2517,0	131,4
6.00	54	2090,4	191,2
7.00	54	1665,2	128,5
8.00	54	1669,6	146,6
9.00	54	1767,4	196,6
10.00	54	1860,0	252,1
11.00	54	1918,5	245,0
12.00	54	1844,4	241,7
13.00	54	1883,7	243,5
14.00	54	1982,2	236,7
15.00	54	1982,2	235,5
16.00	54	1976,3	200,9
17.00	54	2110,4	228,1
18.00	54	3332,6	203,0
19.00	54	3537,0	192,2
20.00	54	3474,8	195,7
21.00	54	3377,8	209,3
22.00	54	3140,7	234,6
23.00	54	2893,3	204,0
Keseluruhan	1296	2399,0	628,0

nunjukkan adanya rata-rata yang berbeda untuk setiap jam dan hari yang diamati. Selain itu pola ACF dari data asli juga menunjukkan adanya *peak* dan turun lambat pada lag 24,48,72,... yang menyatakan periode musiman harian, dan pada lag 168,336,504,... yang mengindikasikan periode musiman mingguan [12].

Stasioneritas data diperoleh melalui proses *differencing* lag 1, 24 dan 168, atau sebanyak 3 (tiga) kali. Gambar 3 dan 4 adalah plot ACF dan PACF dari data yang sudah stasioner.

Berdasarkan plot ACF dan PACF data yang sudah stasioner di atas, model ARIMA musiman ganda dugaan yang diperoleh ada dua, yaitu ARIMA ([1, 2, 3, 4, 6, 7, 9, 10, 14, 21, 33], 1, [8])(0,1,1)²⁴ (1, 1, 0)¹⁶⁸ dan ARIMA([12], 1, [1, 2, 3, 4, 6, 7])(0, 1, 1)²⁴ (1, 1, 0)¹⁶⁸. Uji signifikansi parameter dan cek diagnosa kedua model dengan uji Ljung-Box me-nunjukkan bahwa residual hasil kedua pemodelan adalah *white noise*. Pengujian asumsi kenormalan residual menggunakan statistik uji Kolmogorov-Smirnov me-nunjukkan bahwa residual hasil kedua pemodelan tidak berdistribusi normal. Hal ini diduga karena ada-nya *outlier* pada data.

Proses deteksi *outlier* hanya dilakukan pada model I, karena MSE pada data *in-sample* lebih kecil daripada MSE *in-sample* model II. Deteksi *outlier* dilakukan secara iteratif dan diperoleh 14 *innovational outlier*. Model I memiliki MAPE *out-sample* sebesar 22,8% dan secara matematis model tersebut dapat ditulis sebagai berikut $(1 + 0.164B + 0.139B^2 + 0.155B^3 + 0.088B^4 + 0.112B^6 + 0.152B^7 + 0.077B^9 + 0.067B^{10} + 0.069B^{14} + 0.089B^{21} + 0.072B^{22})(1 + 0.534B^{168})(1 - B)(1 - B^{24})(1 - B^{168})Z_t = (1 - 0.0674B^8)1 - 0.803B^{24}a_t$. Sedangkan model I dengan *outlier* yang tidak diestimasi

Tabel 2: Statistik Deskriptif Konsumsi Listrik per Jam

Hari	Pengamatan	Rata-Rata	St. Deviasi
Senin	168	2439,0	624,1
Selasa	168	2469,5	608,2
Rabu	192	2453,3	584,8
Kamis	192	2447,9	603,9
Jumat	192	2427,3	645,1
Sabtu	192	2362,7	632,4
Minggu	192	2204,8	660,3

ulang adalah sebagai berikut.

$$Z_t = \frac{1}{\hat{\pi}(B)} \left[844I_t^{(830)} - 710.886I_t^{(1062)} + 621.307I_t^{(906)} - 511.067I_t^{810} - 485.238I_t^{(1027)} - 456.19I_t^{(1038)} + 455.09I_t^{(274)} - 438.882I_t^{(247)} + 376.704I_t^{(1075)} - 375.48I_t^{(971)} + 362.052I_t^{(594)} - 355.701I_t^{(907)} - 329.702I_t^{(623)} + 308.13I_t^{(931)} + a_t \right]$$

dengan


$$\hat{\pi}(B) = [(1 + 0.164B + 0.139B^2 + 0.155B^3 + 0.088B^4 + 0.112B^6 + 0.152B^7 + 0.077B^9 + 0.067B^{10} + 0.069B^{14} + 0.089B^{21} + 0.072B^{22})(1 + 0.543B^{168})(1 - B)(1 - B^{24})(1 - B^{168})] / [(1 - 0.0674B^8)(1 - 0.803B^{24})]$$

Hasil Model Elman-Recurrent Neural Network


Penerapan metode Elman-RNN dilakukan untuk mendapatkan jaringan terbaik yang sesuai untuk peramalan konsumsi listrik di Mengare Gresik. Eelemen jaringan yang ditentukan adalah banyaknya input, banyaknya unit pada lapisan tersembunyi, banyaknya output, dan fungsi aktivasi pada lapisan tersembunyi dan lapisan output.

Jaringan Elman-RNN pertama yang dicobakan adalah jaringan dengan input sesuai *lag* pada model ARIMA musiman ganda. Jaringan ini menggunakan input *lag* 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 14, 15, 21, 22, 24, 25, 26, 27, 28, 29, 30, 31, 32, 33, 34, 35, 38, 39, 45, 46, 57, 58, 168, 169, 170, 171, 172, 173, 174, 175, 176, 177, 178, 179, 182, 183, 189, 190, 192, 193, 194, 195, 196, 197, 198, 199, 200, 201, 202, 203, 206, 207, 213, 214, 225, 226, 336, 337, 338, 339, 340, 341, 342, 343, 344, 345, 346, 347, 350, 351, 357, 358, 360, 361, 362, 363, 364, 365, 366, 367, 368, 369, 370, 371, 374, 375, 381, 382, 393, dan 394. Dengan input ini jaringan yang diperoleh adalah Elman-RNN(101,3,1) dengan MAPE sebesar 4,22%.

Pada jaringan kedua, digunakan input ARIMA dengan tambahan 14 *outlier* yang telah dideteksi. Input ini adalah input *lag* ARIMA seperti di atas dengan 14 *outlier*, yaitu pada *t* ke-803, 1062, 906, 810, 1027, 1038, 274,



Gambar 2: Plot runtun waktu konsumsi listrik per jam



Gambar 3: ACF data differencing lag 1, 24, dan 168

247, 1075, 971, 594, 907, 623, dan 931. Pada skenario ini, jaringan yang diperoleh adalah Elman-RNN(115,3,1) dengan MAPE sebesar 4,61%.

Jaringan ketiga yang dicobakan adalah jaringan dengan input lag kelipatan 24. Input lag kelipatan 24 yang digunakan adalah 24, 48, ..., 80. Dengan jaringan ini diperoleh Elman-RNN(20, 6, 1) dengan MAPE sebesar 7,55%.


Yang terakhir, jaringan yang dicobakan adalah input lag 1 dan lag kelipatan 24 ± 1. Input jaringan ini jika dijabarkan adalah lag 1, 23, 24, 25, 47, 48, 49, ..., 167, 168, dan 169. Jaringan terbaik dengan input ini adalah Elman-RNN(22, 3, 1) dengan MAPE 2,78%.

Secara lengkap hasil perbandingan ketepatan ramalan antar model Elman-RNN yang dicobakan dapat dilihat pada Tabel 3. Berdasarkan hasil perbandingan MAPE *out-sample*, dapat disimpulkan bahwa jaringan Elman-RNN (22, 3, 1) merupakan jaringan Elman-RNN terbaik untuk peramalan konsumsi listrik per jam di Mengare Gresik.


Perbandingan Hasil Model ARIMA Musiman Ganda dan Elman-RNN

Model ARIMA yang dibandingkan adalah model ARIMA tanpa *outlier* karena *outlier* yang banyak pada model ARIMA musiman ganda tidak dapat dimodelkan atau dilakukan pada *software* (paket SAS) yang digunakan. Model ARIMA yang terbaik yang diperoleh untuk peramalan data konsumsi listrik per jam di Mengare adalah ARIMA $([1, 2, 3, 4, 6, 7, 9, 10, 14, 21, 33], 1, 8)(0, 1, 1)^{24}(1, 1, 0)^{168}$ dan jaringan yang diperoleh adalah Elman-RNN(22, 3, 1). Perbandingan juga dilakukan dengan jaringan Elman-RNN(101, 3, 1), yaitu jaringan dengan input yang sama dengan model ARIMA musiman ganda yang diperoleh.

Hasil perbandingan kebaikan model berdasarkan ketepatan ramalan dan residual ramalan pada data *out-sample* secara visual dapat dilihat pada Gambar 5 dan 6. Dari gambar tersebut dapat dijelaskan bahwa residual jaringan Elman-RNN berada paling dekat dengan nol, dibandingkan dengan residual model ARIMA. Selain itu, hasil peramalan



Gambar 4: PACF data *differencing* lag 1, 24, dan 168



Gambar 5: Perbandingan ketepatan ramalan *out-sample* model ARIMA, Elman-RNN(101,3,1), dan Elman-RNN(22,3,1)

dengan Elman-RNN menunjukkan nilai yang lebih akurat daripada hasil peramalan model ARIMA.

Proses perbandingan juga dilakukan pada nilai MAPE iteratif pada data *out-sample*. Hasil perbandingan nilai MAPE ini ditunjukkan oleh Gambar 7. Dari gambar ini dapat dilihat bahwa jaringan Elman-RNN(22,3,1) memberikan nilai kesalahan ramalan yang lebih kecil dibanding model ARIMA musiman ganda dan jaringan Elman-RNN yang lain. Secara keseluruhan, hasil perbandingan ketepatan ramalan menunjukkan bahwa Elman-RNN adalah model yang lebih baik daripada model ARIMA musiman ganda, untuk meramalkan konsumsi listrik di Mengare Gresik.

SIMPULAN


Berdasarkan hasil analisis dan pembahasan pada bagian sebelumnya, dapat disimpulkan bahwa ARIMA yang sesuai untuk peramalan jangka pendek konsumsi listrik per jam di

Tabel 3: Kriteria Keباikan Model Elman-RNN


Hari	Pengamatan	Rata-Rata	St. Deviasi
Senin	168	2439,0	624,1
Selasa	168	2469,5	608,2
Rabu	192	2453,3	584,8
Kamis	192	2447,9	603,9
Jumat	192	2427,3	645,1
Sabtu	192	2362,7	632,4
Minggu	192	2204,8	660,3

Mengare Gresik adalah model ARIMA $([1 - 4, 6, 7, 9, 10, 14, 21, 33], 1, 8)(0, 1, 1)^{24}(1, 1, 0)^{168}$ dengan MSE *in-sample* sebesar 11417, 426. Model ini menghasilkan MAPE *out-sample* sebesar 22,8%.

Jaringan metode Elman-RNN terbaik yang sesuai untuk meramalkan konsumsi listrik per jam di Mengare Gresik adalah jaringan Elman-RNN(23,4,1) dengan input ada-



Gambar 6: Perbandingan residual ramalan *out-sample* model ARIMA, Elman-RNN(101,3,1), dan Elman-RNN(22,3,1)



Gambar 7: Perbandingan MAPE *out-sample* model ARIMA, Elman-RNN(101,3,1), dan Elman-RNN(22,3,1)

lah lag 1, 23, 24, 25, 47, 48, 49, 71, 72, 73, 95, 96, 97, 119, 120, 121, 143, 144, 145, 167, 168, dan 169. Fungsi aktivasi yang digunakan pada lapisan tersembunyi adalah fungsi *tangent sigmoid* dan pada lapisan output adalah fungsi lini-er. Jaringan menghasilkan MAPE *out-sample* sebesar 3%.

Hasil perbandingan ketepatan ramalan model menunjukkan bahwa metode Elman-RNN, yaitu jaringan Elman-RNN(23,4,1), adalah model terbaik untuk meramalkan konsumsi listrik per jam di Mengare Gresik. Hasil penelitian juga menunjukkan adanya keterbatasan paket SAS dalam mengestimasi parameter model ARIMA musiman ganda dengan memasukkan efek *outlier* hasil dari proses deteksi *outlier*. Kondisi ini memberikan peluang untuk dilakukan kajian atau penelitian lanjut berkaitan dengan pengembangan paket statistik khusus untuk model ARIMA musiman ganda yang melibatkan lag-lag yang panjang beserta deteksi *outlier*-nya.

DAFTAR PUSTAKA

[1] Kiarziz, S., Bakirtzis, A., Petridis, V.: *Short-term Loading Forecasting using Neural Networks*. Electric

Power Systems Research (33) (1995) 1–6

[2] Husen, W.: *Implementasi JST pada Prakiraan Beban Puncak Listrik Jangka Pendek*. Master's thesis, Jurusan Teknik Fisika Institut Teknologi Sepuluh Nopember Surabaya (2001)

[3] Taylor, J., Menezes, L., McSharry, P.: *A Comparison of Univariate Methods for Forecasting Electricity Demand Up to a Day Ahead*. International Journal of Forecasting (22) (2006) 1–16

[4] Ristiana, Y.: *Model Autoregressive Neural Network (ARNN) untuk Peramalan Konsumsi Listrik Jangka Pendek di PT. PLN Gresik*. Master's thesis, Jurusan Statistika Institut Teknologi Sepuluh Nopember Surabaya (2008)

[5] Wei, W.: *Time Series Analysis, Univariate and Multivariate Methods*. 2nd edn. Pearson Addison Wesley, Boston (2006)

- [6] Box, G., Jenkins, G., Reissel, G.: *Time Series Analysis Forecasting and Control*. 3rd edn. Prentice Hall (1994)
- [7] Suhartono: *Feedforward Neural Networks for Time Series Forecasting*. PhD thesis, Department of Mathematics, Gadjah Mada University, Yogyakarta (2007)
- [8] Trapletti, A.: *On Neural Networks as Statistical Time Series Models*. PhD thesis, Institute for Statistics, Wien University (2000)
- [9] Stinchombe, M., White, H.: *Universal Approximation of an Unknown Mapping and Its Derivatives using Multilayer Feedforward Networks*. *Neural Networks* **3** (1990) 551–560
- [10] White, H.: *Connectionist Nonparametric Regression: Multilayer Feed Forward Networks Can Learn Arbitrary Mapping*. *Neural Networks* **3** (1990) 535–550
- [11] Marsudi, D.: *Operasi Sistem Tenaga Listrik*. Yogyakarta: Graha Ilmu. (2006)
- [12] Endharta, A.: *Peramalan Konsumsi Listrik Jangka Pendek dengan Elman-Recurrent Neural Network*. Master's thesis, Jurusan Statistika Institut Teknologi Sepuluh Nopember Surabaya (2009)