

Pendekatan *Percentile Error Bootstrap* pada Model *Double Seasonal Holt-Winters*, *Double Seasonal ARIMA*, dan *Naïve* untuk Peramalan Beban Listrik Jangka Pendek Area Jawa Timur-Bali

Hidayatul Khusna dan Suhartono

Jurusan Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam,

Institut Teknologi Sepuluh Nopember (ITS)

Jl. Arief Rahman Hakim, Surabaya 60111 Indonesia

e-mail : suhartono@statistika.its.ac.id

Abstrak— Interval prediksi pada model *double seasonal Holt-Winters* (DSHW) tidak dapat dikonstruksi dengan cara analitis. Jika digunakan untuk meramal jauh ke depan, model *double seasonal ARIMA* memiliki varians error yang semakin besar sehingga interval prediksi menjadi semakin lebar. Sementara model *Naïve* untuk data musiman memiliki varians error yang semakin besar setiap kelipatan periode musiman. Penelitian ini bertujuan untuk meramalkan beban listrik area Jawa Timur-Bali menggunakan pendekatan *percentile error bootstrap* (PEB) pada model DSHW, DSARIMA, dan *Naïve*. Data yang digunakan adalah beban listrik per setengah jam dalam satuan Mega Watt (MW) dari periode 1 Januari 2013 hingga 30 September 2014. Hasil penelitian menunjukkan bahwa model DSARIMA merupakan model terbaik berdasarkan kriteria *out-sample* sMAPE, kriteria *in-sample* AIC-SBC, serta kriteria *out-sample* rata-rata lebar interval prediksi. Dengan demikian, dapat disimpulkan bahwa model terbaik untuk peramalan beban listrik jangka pendek area Jawa Timur-Bali adalah model DSARIMA dengan interval prediksi yang dikonstruksi menggunakan pendekatan *percentile error bootstrap*.

Kata Kunci— beban listrik, *double seasonal ARIMA*, *double seasonal Holt-Winters*, *Naïve*, *percentile error bootstrap*.

I. PENDAHULUAN

LISTRIK telah menjadi kebutuhan primer bagi masyarakat. Sebagai pusat pemerintahan dan perekonomian, wilayah distribusi Jawa-Bali mendominasi sekitar 80% dari total kebutuhan listrik nasional pada tahun 2003 [1]. Listrik memiliki karakteristik tidak dapat disimpan. Karena itu, listrik harus dibangkitkan hanya jika diperlukan. PT. PLN perlu melakukan pengoptimalan pendistribusian listrik hingga skala operasional melalui peramalan beban listrik per setengah jam.

Penelitian tentang peramalan beban listrik telah banyak dilakukan, diantaranya oleh Puspitasari [2] menggunakan *Two Level Seasonal Autoregressive* Hibrida ARIMA-ANFIS dan Utomo [3] menggunakan DSARFIMA. Keduanya hanya melakukan peramalan titik. Taylor dan McSharry [4] melakukan penelitian tentang beban listrik jangka pendek di Eropa dan menyatakan bahwa metode *Double Seasonal Holt-Winters* lebih akurat dibandingkan metode PCA dan *Seasonal ARMA*.

Bootstrap merupakan salah satu pendekatan komputatif yang dapat menjadi alternatif untuk mengkonstruksi interval prediksi tanpa mensyaratkan asumsi residual berdistribusi Normal. Hyndman *et al.* [5] menerapkan bootstrap berdasarkan error menggunakan *percentile error bootstrap*. Hyndman dan Fan [6] juga mengembangkan bootstrap pada data yang memiliki pola *double seasonal* menggunakan *double seasonal block bootstrapping*. Kedua metode ini pernah diterapkan oleh Lailiya [7] pada model *double seasonal Holt-Winters*. Hasilnya, masing-masing metode memiliki kelebihan dalam hal lebar serta akurasi interval prediksi. Penelitian ini bertujuan untuk menerapkan pendekatan *percentile error bootstrap* pada model *double seasonal Holt-Winters*, *double seasonal ARIMA*, dan *Naïve* untuk peramalan beban listrik jangka pendek area Jawa Timur-Bali sehingga diperoleh model terbaik dengan interval prediksi yang stabil serta memiliki akurasi yang lebih tinggi.

II. TINJAUAN PUSTAKA

A. *Double Seasonal Holt-Winters*

Model *multiplicative* untuk *double seasonal Holt-Winters* dituliskan sesuai persamaan berikut [6]

$$\text{level} : l_t = \alpha' \left(\frac{Y_t}{D_{t-s_1} W_{t-s_2}} \right) + (1-\alpha')(l_{t-1} + b_{t-1}) \quad (1)$$

$$\text{trend} : b_t = \beta'(l_t - l_{t-1}) + (1-\beta)b_{t-1} \quad (2)$$

$$\text{seasonal 1} : D_t = \delta \left(\frac{Y_t}{l_t W_{t-s_2}} \right) + (1-\delta)D_{t-s_1} \quad (3)$$

$$\text{seasonal 2} : W_t = \omega \left(\frac{Y_t}{l_t D_{t-s_1}} \right) + (1-\omega)W_{t-s_2} \quad (4)$$

$$\text{error} : e_t = Y_t - \left((l_t + b_t h) D_{t-s_1+h} W_{t-s_2+h} \right) \quad (5)$$

$$\text{forecast} : \hat{Y}_t(h) = (l_t + b_t h) D_{t-s_1+h} W_{t-s_2+h} + \phi^h e_t \quad (6)$$

dengan s adalah periode *seasonal*, l_t adalah indeks *level* pada waktu ke- t , b_t adalah indeks *trend* pada waktu ke- t , D_t adalah indeks *seasonal 1* (*daily*) pada waktu ke- t , W_t adalah indeks *seasonal 2* (*weekly*) pada waktu ke- t , e_t adalah error pada waktu ke- t , α' adalah parameter penghalus *level*, β' adalah parameter penghalus *trend*, δ adalah parameter penghalus

seasonal 1, ω adalah parameter penghalus seasonal 2, dan ϕ parameter error terkoreksi.

Langkah-langkah pemodelan *double seasonal Holt-Winters* dapat dijelaskan sebagai berikut.

1. Menentukan nilai awal komponen dimana $m_1=48$ (periode *seasonal 1* atau *daily*) dan $m_2=336$ (periode *seasonal 2* atau *weekly*), dilakukan melalui langkah berikut [8].
 - a. Menentukan nilai awal *trend*, b_0 , yaitu rata-rata dari 1/336 dari selisih antara 336 observasi pertama dengan 336 observasi kedua, dan *differencing* pertama untuk 336 observasi pertama.
 - b. Menentukan nilai awal level, l_0 , yaitu rata-rata dari 672 observasi pertama dikurangi 336,5 kali dari nilai awal *trend*.
 - c. Menentukan nilai awal *seasonal 1 (within-day seasonal)*, D_0 , yaitu rata-rata dari rasio nilai aktual dengan 48 *point centered moving average*, yang diperoleh dari periode setengah jam pada setiap harinya selama tujuh hari.
 - d. Menentukan nilai awal *seasonal 2 (within-week seasonal)*, W_0 , yaitu rata-rata dari rasio nilai aktual dengan 336 *point centered moving average*, yang diperoleh dari periode setengah jam pada setiap dua minggu, kemudian dibagi dengan nilai awal D_0 .
2. Menentukan parameter dengan *nonlinear optimization*, dilakukan melalui langkah berikut [9].
 - a. Membangkitkan 100.000 vektor parameter dari distribusi Uniform 0 hingga 1.
 - b. Memasukkan masing-masing vektor ke dalam model kemudian dihitung nilai *sum of square error* (SSE) setiap model.
 - c. Mendapatkan nilai awal parameter dari sepuluh vektor yang memiliki SSE terkecil.
 - d. Melakukan optimasi parameter menggunakan algoritma *quasi-Newton*.
 - e. Mendapatkan satu vektor parameter akhir yang memiliki SSE terkecil.

B. Double Seasonal ARIMA

Data konsumsi listrik jangka pendek pada umumnya memiliki pola *double seasonal* [8, 10, 11]. Karena itu, model ARIMA yang sesuai untuk peramalan beban listrik jangka pendek adalah *multiplicative double seasonal ARIMA* atau ARIMA $(p, d, q)(P_1, D_1, Q_1)^{s_1}(P_2, D_2, Q_2)^{s_2}$. Secara matematis, model ARIMA ini dapat ditulis sesuai persamaan berikut

$$\phi_p(B)\Phi_{P_1}(B^{s_1})\Phi_{P_2}(B^{s_2})(1-B)^d(1-B^{s_1})^{D_1}(1-B^{s_2})^{D_2}Y_t = \theta_q(B)\Theta_{Q_1}(B^{s_1})\Theta_{Q_2}(B^{s_2})a_t \quad (7)$$

Interval prediksi untuk model *multiplicative double seasonal ARIMA* dapat ditentukan melalui persamaan berikut

$$\{\hat{Y}_t(h) + z_{\alpha/2}\sqrt{\text{var}[e_t(h)]}\} < Y_t(h) < \{\hat{Y}_t(h) + z_{1-\alpha/2}\sqrt{\text{var}[e_t(h)]}\} \quad (8)$$

dengan $\hat{Y}_t(h)$ adalah ramalan h tahap ke depan, dan $\text{var}[e_t(h)]$ adalah varians error untuk ramalan h tahap ke depan.

C. Metode Naïve

Peramalan menggunakan metode Naïve pada data dengan *trend* linear dapat dituliskan sesuai persamaan berikut [12]

$$\hat{Y}_t(h) = Y_{t+h-1} + (Y_{t+h-1} - Y_{t+h-2}) \quad (9)$$

Jika data *time series* memuat pola *double seasonal*, dimana $s_1 < s_2$, maka peramalan menggunakan metode *double seasonal Naïve* dapat dituliskan sebagai berikut

$$\hat{Y}_t(h) = Y_{t+h-s_2} \quad (10)$$

D. Percentile Error Bootstrap

Percentile error bootstrap dapat diterapkan dengan cara mendapatkan N sampel error untuk setiap tahap peramalan melalui resampling error (*ordinary bootstrap*), sebagai berikut [5].

1. Mendapatkan nilai fit dari model.
2. Menghitung error yang didapatkan dari selisih antara data aktual dengan nilai fit.
3. Membangkitkan N sampel error untuk setiap h , dimana $h=1, 2, \dots, H$ tahap ke depan dan N merupakan bilangan yang sangat besar. Error dibangkitkan menggunakan resampling dengan pengembalian (*ordinary bootstrap*) sehingga untuk membangun interval prediksi bagi $Y_t(h)$ dibutuhkan N sampel error.
4. Pada setiap ramalan ke- h , N sampel error hasil bootstrap diurutkan dari yang terkecil hingga terbesar.
5. Mendapatkan persentil error $\alpha/2$ dan $1-\alpha/2$ untuk setiap ramalan ke- h . Sehingga, batas atas dan batas bawah untuk setiap ramalan ke- h adalah sebagai berikut.

$$(\hat{Y}_t(h) + e_{[\alpha/2]}) < Y_t(h) < (\hat{Y}_t(h) + e_{[1-\alpha/2]}) \quad (13)$$

6. Mengulangi langkah 3 hingga 5 untuk mendapatkan interval pada setiap peramalan $h=2, 3, \dots, H$.

III. METODE PENELITIAN

A. Sumber Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari PT. PLN (Persero) P3B Jawa Bali, bagian APB. Variabel penelitian yang digunakan adalah beban listrik per setengah jam yang didistribusikan oleh APB Jawa Timur-Bali periode 1 Januari 2013 hingga 15 September 2014 (*training*) serta 16 hingga 30 September 2014 (*testing*).

B. Metode Analisis Data

Langkah analisis dalam penelitian ini adalah sebagai berikut.


1. Melakukan analisis statistik deskriptif.
2. Melakukan peramalan menggunakan model DSHW.
3. Melakukan peramalan menggunakan model DSARIMA.
4. Melakukan peramalan menggunakan model Naïve.
5. Melakukan peramalan menggunakan pendekatan *percentile error bootstrap* pada model DSHW, DSARIMA, dan Naïve.
6. Membandingkan akurasi hasil peramalan menggunakan model DSHW, DSARIMA, Naïve serta model dengan pendekatan *percentile error bootstrap* untuk masing-masing metode.

IV. HASIL DAN PEMBAHASAN

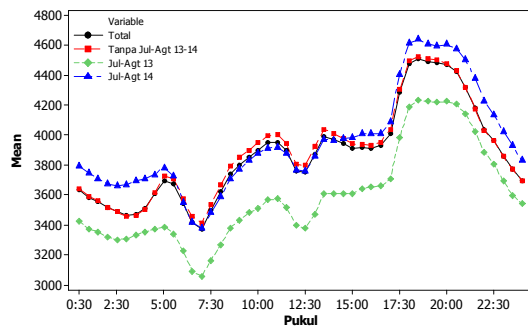
A. Statistika Deskriptif

Data beban konsumsi listrik area Jawa Timur-Bali yang dicatat setiap setengah jam dari periode 1 Januari 2013 hingga 30 September 2014 memiliki dua pola musiman, yaitu musiman harian dan musiman mingguan. Pola musiman harian


dan mingguan pada sampel data di Bulan September 2014 dapat diamati pada gambar 1.



Gambar 1. Time Series Plot Beban Konsumsi Listrik



Gambar 2. Plot Rata-rata Beban Konsumsi Listrik Per Setengah Jam



Gambar 3. Plot Varians Beban Konsumsi Listrik Per Setengah Jam

Tabel 1
Proyeksi Kebutuhan Listrik Jawa Timur-Bali [13]

Sektor	2008	2010	2012	2014	2016	2018	2020
Rumah Tangga	8,40	9,49	10,71	12,03	13,44	15,02	16,78
Usaha	2,75	3,06	3,41	3,78	4,18	4,63	5,12
Umum	1,12	1,23	1,35	1,50	1,69	1,90	2,14
Industri	9,87	11,31	12,95	14,76	16,80	19,15	21,86
Jatim-Bali	22,13	25,09	28,42	32,08	36,12	40,70	45,90

Di Jawa Timur-Bali, industri merupakan konsumen listrik yang lebih dominan. Akan tetapi, selisih kebutuhannya dengan rumah tangga tidak terlalu besar [13]. Karena itu, dapat diamati pada gambar 2 bahwa rata-rata beban konsumsi listrik terendah terjadi pada pukul 07.00 pagi seiring dengan dimulainya aktivitas masyarakat untuk bekerja di luar rumah. Sedangkan rata-rata beban konsumsi listrik mencapai puncak tertingginya pada pukul 18.30 seiring berakhirnya sebagian besar aktivitas masyarakat untuk bekerja di luar rumah. Menjelang malam hari, semua fasilitas umum membutuhkan energi listrik yang tinggi, termasuk sebagai penerangan jalan. Sebagian besar masyarakat yang kembali ke rumah perlu

menyalakan berbagai peralatan elektronik sehingga beban konsumsi listrik melonjak tinggi.

Selain itu, rata-rata beban konsumsi listrik tiap setengah jam khusus periode Juli hingga Agustus 2013 bernilai paling rendah. Sementara rata-rata beban konsumsi listrik tiap setengah jam khusus periode Juli hingga Agustus 2014 bernilai paling tinggi khususnya pada jam-jam di malam hari telah melebihi rata-rata beban konsumsi listrik per setengah jam secara keseluruhan dari periode Januari 2013 hingga September 2014. Hal ini menunjukkan adanya kenaikan *trend* pemakaian listrik dari periode 2013 hingga 2014 dengan proporsi tertinggi terjadi pada malam hari.

Gambar 3 menjelaskan bahwa beban konsumsi listrik memiliki variasi yang tinggi saat siang hari. Sedangkan pada malam hari, pola konsumsi energi listrik didominasi oleh sektor rumah tangga sehingga tidak memiliki fluktuasi konsumsi energi listrik yang tinggi. Hal yang menarik pada gambar 3 adalah varians beban konsumsi listrik tiap setengah jam khusus periode Juli hingga Agustus 2013 serta Juli hingga Agustus 2014 ternyata lebih tinggi daripada varians beban konsumsi listrik tiap setengah jam secara keseluruhan dari periode Januari 2013 hingga September 2014. Hal ini menunjukkan bahwa tingginya varians beban konsumsi listrik tiap setengah jam secara keseluruhan dari periode Januari 2013 hingga September 2014 paling besar disumbang oleh varians beban konsumsi listrik di sekitar Idul Fitri 2013 dan Idul Fitri 2014.

B. Peramalan dengan DSHW

Peramalan pada data *training* menggunakan model DSHW diperoleh persamaan peramalan titik sebagai berikut

$$\hat{Y}_t(h) = (l_t + b_t h) D_{t-48+h} W_{t-336+h} + (0,282)^h e_t$$

dengan

$$l_t = (0,547) \left(\frac{Y_t}{D_{t-48} W_{t-336}} \right) + (1-0,547)(l_{t-1} + b_{t-1})$$

$$b_t = (0,0000466)(l_t - l_{t-1}) + (1-0,0000466)b_{t-1}$$

$$D_t = (0,211) \left(\frac{Y_t}{l_t W_{t-336}} \right) + (1-0,211)D_{t-48}$$

$$W_t = (0,282) \left(\frac{Y_t}{l_t D_{t-48}} \right) + (1-0,282)W_{t-336}$$

$$e_t = Y_t - ((l_t + b_t h) D_{t-48+h} W_{t-336+h})$$


Parameter β' atau parameter penghalus untuk efek *trend* memiliki nilai yang sangat kecil. Hal ini mengindikasikan bahwa data *in-sample* hampir tidak memiliki efek *trend*. Sementara parameter ϕ yang merupakan parameter untuk error terkoreksi memiliki nilai yang cukup besar mengindikasikan bahwa model yang terbentuk memerlukan *adjustment* dengan AR(1) akibat residual model masih memiliki nilai ACF yang signifikan.

C. Peramalan dengan DSARIMA

Pemodelan DSARIMA dengan prosedur Box-Jenkins diawali dengan identifikasi stasioneritas data dalam mean dan varians. Stasioneritas data dalam mean dapat diidentifikasi melalui plot ACF. Plot ACF pada gambar 4 memiliki pola turun sangat lambat mengindikasikan bahwa data tidak stasioner dalam mean sehingga perlu dilakukan *differencing* orde 1 serta orde musiman pada lag 48 dan lag 336.

Berdasarkan plot ACF dan PACF dari data yang telah stasioner, diperoleh dua model dugaan yang telah memiliki parameter signifikan serta residual *white noise* yaitu model ARIMA([11,15,16,17,18,19,20,21,28,29,31,32,33,34,41,44,45,47],1,[1,3,5,7,8,13,22,35,36,40])(0,1,1)⁴⁸(0,1,1)³³⁶ dan model ARIMA([11,15,16,17,18,19,20,21,28,29,30,31,32,33,34],1,[1,3,5,7,8,13,22,35,36])(0,1,1)⁴⁸(0,1,1)³³⁶. Model kedua memiliki *out-sample* sMAPE serta persentase error yang lebih kecil sehingga dipilih sebagai model terbaik. Secara matematis, model DSARIMA terbaik dapat dituliskan sebagai berikut

$$\begin{aligned}
 Y_t = & Y_{t-1} + Y_{t-48} - Y_{t-49} + Y_{t-336} - Y_{t-337} - Y_{t-384} + Y_{t-385} + 0.013Y_{t-11} - 0.013Y_{t-12} \\
 & - 0.026Y_{t-15} - 0.0076Y_{t-16} - 0.0082Y_{t-17} + 0.0005Y_{t-18} - 0.0056Y_{t-19} + 0.0043Y_{t-20} \\
 & + 0.01466Y_{t-21} + 0.026Y_{t-22} - 0.016Y_{t-28} + 0.0002Y_{t-29} + 0.0037Y_{t-30} - 0.0106Y_{t-31} \\
 & + 0.0035Y_{t-32} - 0.0028Y_{t-33} + 0.0066Y_{t-34} + 0.0158Y_{t-35} - 0.013Y_{t-59} + 0.013Y_{t-60} \\
 & + 0.0082Y_{t-65} - 0.0005Y_{t-66} + 0.0056Y_{t-67} - 0.0043Y_{t-68} + 0.026Y_{t-63} + 0.0076Y_{t-64} \\
 & - 0.0166Y_{t-69} - 0.026Y_{t-70} + 0.016Y_{t-76} - 0.0002Y_{t-77} - 0.0037Y_{t-78} + 0.0106Y_{t-79} \\
 & - 0.0035Y_{t-80} + 0.0028Y_{t-81} - 0.0066Y_{t-82} - 0.0158Y_{t-83} - 0.013Y_{t-347} + 0.013Y_{t-348} \\
 & + 0.026Y_{t-351} + 0.0076Y_{t-352} + 0.0082Y_{t-353} - 0.0005Y_{t-354} + 0.0056Y_{t-355} \\
 & - 0.026Y_{t-358} + 0.016Y_{t-364} - 0.0002Y_{t-365} - 0.0037Y_{t-366} + 0.0106Y_{t-367} \\
 & - 0.0043Y_{t-356} - 0.0166Y_{t-357} - 0.0035Y_{t-368} + 0.0028Y_{t-369} - 0.0066Y_{t-370} \\
 & - 0.0158Y_{t-371} + 0.013Y_{t-395} - 0.013Y_{t-396} - 0.026Y_{t-399} - 0.0076Y_{t-400} \\
 & - 0.0082Y_{t-401} + 0.0005Y_{t-402} - 0.0056Y_{t-403} + 0.0043Y_{t-404} + 0.0166Y_{t-405} \\
 & + 0.026Y_{t-406} - 0.016Y_{t-412} + 0.0001Y_{t-413} + 0.0037Y_{t-414} - 0.0106Y_{t-415} \\
 & + 0.0035Y_{t-416} - 0.0028Y_{t-417} + 0.0066Y_{t-418} + 0.016Y_{t-419} \\
 & + a_t - 0.288a_{t-1} - 0.079a_{t-3} - 0.021a_{t-5} - 0.025a_{t-7} - 0.016a_{t-8} - 0.013a_{t-13} \\
 & - 0.026a_{t-22} - 0.014a_{t-35} + 0.024a_{t-36} - 0.783a_{t-48} + 0.225a_{t-49} + 0.062a_{t-51} \\
 & + 0.016a_{t-53} + 0.019a_{t-55} + 0.012a_{t-56} + 0.011a_{t-61} + 0.02a_{t-70} + 0.011a_{t-83} \\
 & - 0.018a_{t-84} - 0.852a_{t-336} + 0.245a_{t-337} + 0.068a_{t-339} + 0.018a_{t-341} + 0.021a_{t-343} \\
 & + 0.013a_{t-344} + 0.011a_{t-349} + 0.022a_{t-358} + 0.012a_{t-371} - 0.02a_{t-372} + 0.667a_{t-384} \\
 & - 0.192a_{t-385} - 0.053a_{t-387} - 0.014a_{t-389} - 0.016a_{t-391} - 0.011a_{t-392} \\
 & - 0.009a_{t-397} - 0.017a_{t-406} - 0.009a_{t-419} + 0.016a_{t-420}
 \end{aligned}$$



Gambar 4. Plot ACF Data Beban Konsumsi Listrik

Tabel 2.

Uji Asumsi Residual Model DSARIMA

	Uji L-Jung Box			Uji Kolmogorov-Smirnov	
	Lag	Q	p-value	D	p-value
Model 1	48	24,250	0,147	0,043	<0,010
Model 2	36	15,970	0,100	0,043	<0,010

P-value uji Kolmogorov-Smirnov pada tabel 2 bernilai kurang dari 0,05 sehingga disimpulkan bahwa residual kedua model tidak berdistribusi Normal. Hal ini dikarenakan data beban konsumsi listrik jangka pendek area Jawa Timur-Bali memiliki banyak *outlier*.


D. Peramalan dengan Naïve

Pada peramalan dengan metode DSHW, diketahui bahwa data beban konsumsi listrik area Jawa Timur-Bali memiliki unsur *trend* meskipun dengan nilai yang sangat kecil. Karena itu, dilakukan peramalan dengan model Naïve *seasonal* dan Naïve *trend-seasonal* masing-masing sebagai berikut

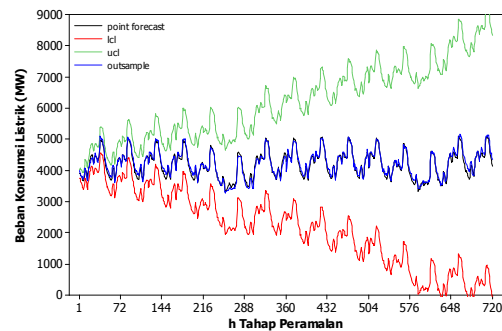
$$Y_t = Y_{t-336} + a_t \text{ dan } Y_t = 2Y_{t-336} - Y_{t-672} + a_t$$

E. Peramalan dengan Pendekatan Percentile Error Bootstrap


Model DSHW yang terbentuk selanjutnya digunakan untuk meramal hingga 720 tahap ke depan untuk dibandingkan dengan data *out-sample* sebagaimana dapat diamati pada gambar 5. Sedangkan interval prediksi diperoleh dengan pendekatan *percentile error bootstrap* berdasarkan residual model DSHW dengan *resampling* sebanyak N 10000. Interval prediksi terlihat stabil dan memiliki jarak yang sempit. Namun, terdapat 202 dari 720 data *out-sample* yang berada di luar interval prediksi. Artinya, terdapat 29,72 persen data *out-sample* yang tidak tercakup dalam interval prediksi.



Gambar 5. Interval Prediksi Hasil Percentile Error Bootstrap pada Model DSHW



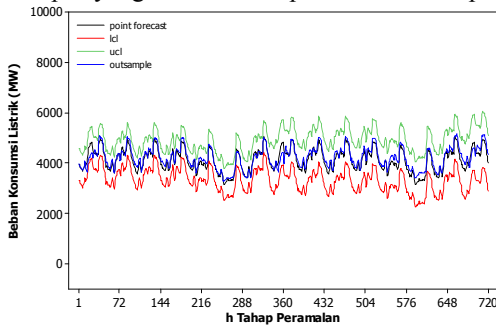
Gambar 6. Interval Prediksi Model DSARIMA




Gambar 7. Interval Prediksi Hasil Percentile Error Bootstrap pada Model DSARIMA

Model DSARIMA terbaik selanjutnya digunakan untuk meramal hingga 720 tahap ke depan untuk dibandingkan dengan data *out-sample* sebagaimana dapat diamati pada gambar 6. Sedangkan interval prediksi pada gambar 7 diperoleh dengan pendekatan *percentile error bootstrap* berdasarkan residual model DSARIMA dengan *resampling* sebanyak N=10000. Menggunakan skala ordinat yang sama, interval prediksi model DSARIMA murni terlihat semakin


melebar akibat membesarnya varians error hasil ramalan. Sedangkan interval prediksi hasil *percentile error bootstrap* pada model DSARIMA terlihat stabil dan memiliki jarak yang sempit. Namun, terdapat 89 dari 720 data *out-sample* yang berada di luar interval prediksi. Artinya, terdapat 12,39 persen data *out-sample* yang tidak tercakup dalam interval prediksi.




Gambar 8. Interval Prediksi Model Naïve Seasonal



Gambar 9. Interval Prediksi Hasil *Percentile Error Bootstrap* pada Model Naïve Seasonal



Gambar 10. Interval Prediksi Model Naïve Trend- Seasonal



Gambar 11. Interval Prediksi Hasil *Percentile Error Bootstrap* pada Model Naïve Trend- Seasonal


Model Naïve *seasonal* selanjutnya digunakan untuk meramal hingga 720 tahap ke depan untuk dibandingkan dengan data *out-sample* sebagaimana dapat diamati pada gambar 8. Sedangkan interval prediksi pada gambar 9 diperoleh dengan pendekatan *percentile error bootstrap*

berdasarkan residual model Naïve *seasonal* dengan *resampling* sebanyak N=10000. Interval prediksi hasil *percentile error bootstrap* pada model Naïve *seasonal* terlihat stabil daripada interval prediksi model Naïve *seasonal* murni, memiliki jarak yang sempit serta telah mencakup data *out-sample* secara sempurna.

Model Naïve *trend-seasonal* selanjutnya digunakan untuk meramal hingga 720 tahap ke depan untuk dibandingkan dengan data *out-sample* sebagaimana dapat diamati pada gambar 10. Sedangkan interval prediksi pada gambar 11 diperoleh dengan pendekatan *percentile error bootstrap* berdasarkan residual model Naïve *trend-seasonal* dengan *resampling* sebanyak N=10000. Interval prediksi model Naïve *seasonal* murni terlihat semakin melebar setiap kelipatan 336 tahap peramalan akibat membesarnya varians error hasil ramalan. Sedangkan interval prediksi hasil *percentile error bootstrap* pada model Naïve *seasonal* terlihat stabil, memiliki jarak yang sempit namun terdapat 22 dari 720 data *out-sample* yang berada di luar interval prediksi.

F. Perbandingan Akurasi Hasil Ramalan

Nilai *iterative out-sample* sMAPE hasil peramalan titik beban konsumsi listrik jangka pendek area Jawa Timur-Bali menggunakan metode DSARIMA, DSHW, dan Naïve dapat diketahui pada gambar 12. Model terbaik berdasarkan kriteria *out-sample* sMAPE adalah model DSARIMA. Selain itu, nilai *out-sample* MAPE model DSARIMA untuk 720 tahap peramalan sebesar 1,69 persen. Nilai ini lebih rendah dari 2 persen yang merupakan batas maksimal error peramalan yang bisa diterima oleh PT. PLN.



Gambar 12. *Iterative out-sample* sMAPE Model DSHW, DSARIMA, dan Naïve

Tabel 3 menunjukkan bahwa model DSARIMA memiliki AIC dan SBC yang lebih kecil daripada model Naïve *seasonal* serta Naïve *trend-seasonal* sehingga dapat disimpulkan bahwa model terbaik berdasarkan kriteria AIC dan SBC adalah model DSARIMA. Penting untuk diketahui bahwa estimasi parameter model DSHW tidak diperoleh melalui metode *Maximum Likelihood* sehingga tidak memiliki kriteria AIC dan SBC.

Tabel 3.

Nilai AIC dan SBC Model DSARIMA serta Naïve

	DSARIMA	Naïve Seasonal	Naïve Trend-Seasonal
AIC	341148,4	435578,2	449932,4
SBC	341364,7	435578,2	449932,4


Dapat diamati pada tabel 4 bahwa interval prediksi yang dikonstruksi menggunakan pendekatan *percentile error bootstrap* memiliki rata-rata lebar interval prediksi yang lebih

stabil jika dibandingkan dengan rata-rata lebar interval prediksi tanpa pendekatan *percentile error bootstrap*. Sementara interval prediksi menggunakan pendekatan *percentile error bootstrap* pada model DSARIMA memiliki rata-rata lebar interval prediksi yang paling kecil untuk tahap peramalan satu minggu hingga empat minggu ke depan sehingga dapat disimpulkan bahwa interval prediksi terbaik berdasarkan kriteria rata-rata lebar interval prediksi adalah interval prediksi menggunakan pendekatan *percentile error bootstrap* pada model DSARIMA.

Tabel 4.

Metode	Tahap Peramalan			
	1 Hari	5 Hari	10 Hari	15 Hari
DSARIMA	711,49	1526,48	2660,84	4022,36
PEB DSARIMA	264,72	264,59	264,51	263,74
PEB DSHW	274,16	274,34	274,43	273,73
Naïve <i>Seasonal</i>	1271,48	1271,48	1429,48	1575,78
PEB Naïve <i>Seasonal</i>	1493,80	1497,25	1494,44	1488,79
Naïve <i>Trend-Seasonal</i>	2086,59	2086,59	2860,34	3665,79
PEB Naïve <i>Trend-Seasonal</i>	2351,85	2349,18	2350,81	2345,02

Dapat diketahui pada gambar 13 bahwa persentase data *out-sample* yang keluar interval prediksi menggunakan pendekatan *percentile error bootstrap* pada model Naïve *seasonal* selalu berada pada titik 0 persen. Artinya, tidak ada satu pun data *out-sample* yang keluar dari interval prediksi. Oleh karena itu, dapat disimpulkan bahwa interval prediksi terbaik berdasarkan kriteria persentase data *out-sample* yang keluar interval prediksi adalah interval prediksi menggunakan pendekatan *percentile error bootstrap* pada model Naïve *seasonal*.



Gambar 13. Persentase Error Interval Prediksi Hasil Pendekatan *Percentile Error Bootstrap* pada Model DSHW, DSARIMA, dan Naïve

Secara keseluruhan dapat diketahui bahwa model terbaik berdasarkan kriteria *out-sample* sMAPE, kriteria *in-sample* AIC-SBC, serta kriteria rata-rata lebar interval prediksi adalah model DSARIMA. Sementara interval prediksi menggunakan pendekatan *percentile error bootstrap* pada model Naïve *seasonal* merupakan interval prediksi terbaik berdasarkan kriteria persentase data *out-sample* yang keluar interval prediksi. Akan tetapi, hasil ramalan titik model Naïve *seasonal* memiliki *out-sample* sMAPE hingga lebih dari tiga persen. Dengan demikian, model terbaik untuk peramalan beban listrik jangka pendek area Jawa Timur-Bali adalah model DSARIMA dengan interval prediksi yang dikonstruksi menggunakan pendekatan *percentile error bootstrap*.

V. KESIMPULAN

Berdasarkan hasil analisis dapat disimpulkan bahwa model terbaik untuk peramalan beban listrik jangka pendek area Jawa Timur-Bali adalah model DSARIMA dengan interval prediksi yang dikonstruksi menggunakan pendekatan *percentile error bootstrap* dengan *out-sample* sMAPE sebesar 1,7 persen; AIC sebesar 341148,4; SBC sebesar 341364,7; rata-rata lebar interval prediksi sebesar 263,74; serta 12,39 persen data *out-sample* yang keluar interval prediksi untuk 720 tahap peramalan. Penelitian berikutnya hendaknya memodelkan beban listrik jangka pendek menggunakan model *additive* DSHW. Hal ini dikarenakan karakteristik data beban listrik jangka pendek di Indonesia berbeda dengan karakteristik data beban listrik jangka pendek di luar negeri yang dikembangkan oleh Taylor [10]. Selain itu, hendaknya melibatkan deteksi *outlier* pada peramalan titik model DSARIMA untuk mendapatkan model yang lebih tepat.

DAFTAR PUSTAKA

- [1] Muchlis, M & Permana, A. D. 2003. Proyeksi Kebutuhan Listrik PLN Tahun 2003 s.d. 2010. Diambil kembali dari *website*: http://www.oocities.org/markal_bppt/publish/slistrk/slmuch.pdf. diakses pada tanggal 20 September 2014 pada pukul 03.41.
- [2] Puspitasari, I. 2011. Model Dua Level Seasonal Autoregressive Hibrida ARIMA-ANFIS Untuk Peramalan Beban Listrik Jangka Pendek Di Jawa Bali. Laporan Tugas Akhir Jurusan Statistika. Surabaya: ITS.
- [3] Utomo, P. D. 2012. Penerapan Model DSARFIMA untuk Peramalan Beban Konsumsi Listrik Jangka Pendek di Jawa Timur dan Bali. Laporan Tugas Akhir Jurusan Statistika. Surabaya: ITS.
- [4] Taylor, J. W. & McSharry, P. E. 2008. Short-Term Load Forecasting Methods: An Evaluation Based on European Data. *IEEE Transactions on Power Systems*, 22, 2213-2219.
- [5] Hyndman, R. J., Koehler, A. B., Snyder, R. D. & Grose, S. 2002. A State Space Framework for Automatic Forecasting Using Exponential Smoothing Methods. *International Journal of Forecasting*, 18, 439-454.
- [6] Hyndman, R. J. & Fan, S. 2010. Density Forecasting for Long-Term Peak Electricity Demand. *IEEE Transaction on Power System*, 25(2), 1142-1153.
- [7] Lailiya, A. R. 2013. Pendekatan Bootstrap untuk Konstruksi Interval Prediksi pada Model Double Seasonal Holt-Winters. Laporan Tesis Jurusan Statistika. Surabaya: ITS.
- [8] Taylor, J. W. 2003. Short-Term Electricity Demand Forecasting Using Double Seasonal Exponential Smoothing. *Journal of Operational Research Society*, 54, 799-805.
- [9] Taylor, J. W. 2010. Triple Seasonal Methods for Short-Term Electricity Demand Forecasting. *European Journal of Operational Research*, 204, 139-152.
- [10] Mohamed, N., Ahmad, M. H., Ismail, Z. & Suhartono. 2010. Double Seasonal ARIMA Model for Forecasting Load Demand. *Matematika*, 26, 217-231.
- [11] Suhartono & Endharta, A. J. 2009. Short Term Electricity Load Demand Forecasting in Indonesia by Using Double Seasonal Recurrent Neural Networks. *International Journal of Mathematical Models and Methods In Applied Sciences*, 3(3), 171-178.
- [12] Hanke, J.E. & Reitsch, A.G. 1995. *Business Forecasting* (5th Ed.). Prentice Hall.
- [13] Boedoyo, M. S. 2006. Perencanaan Kelistrikan dalam Menunjang Pembangunan Nasional yang Berkesinambungan : *Sistem Kelistrikan di Jamali Tahun 2003 s.d. Tahun 2020*. Terbit 31 Juli 2006.