

PERAMALAN BEBAN LISTRIK HARIAN MENGGUNAKAN *ARTIFICIAL NEURAL NETWORK*

Fahmi Alamsyah

S1 Teknik Elektro, Fakultas Teknik, Universitas Negeri Surabaya
fahmialamsyah@mhs.unesa.ac.id

Bambang Suprianto, Widi Aribowo, Aditya Chandra Hermawan

S1 Teknik Elektro, Fakultas Teknik, Universitas Negeri Surabaya
bambangsuprianto@unesa.ac.id. widiaribowo@unesa.ac.id. adityahermawan@unesa.ac.id.

Abstrak

Pada penelitian ini, membahas hasil peramalan beban listrik jangka pendek. Metode peramalan yang digunakan adalah *Feed Forward Backpropagation Neural Network*, *Cascade Forward Backpropagation Neural Network* dan *Generalized Regression Neural Network*. Peramalan akan kebutuhan energi listrik jangka pendek mengacu pada perhitungan beban harian, suhu udara harian. Peramalan ini akan meramalkan beban listrik pada tanggal 7-13 April 2007. Pada penelitian ini, akan membandingkan hasil peramalan beban listrik menggunakan metode *Feed Forward Backpropagation Neural Network*, *Cascade Forward Backpropagation Neural Network* dan *Generalized Regression Neural Network*. Hasil peramalan beban yang hasilnya mendekati beban aktual terdapat pada metode *Cascade Forward Backpropagation Neural Network* pada tanggal 8 April 2007 dengan nilai MAPE sebesar 7,6% sedangkan hasil peramalan beban yang perbedaan hasilnya sangat besar dengan beban aktual terdapat pada metode *Cascade Forward Backpropagation Neural Network* dengan nilai MAPE sebesar 39,7%. Sehingga pada penelitian ini metode peramalan yang paling baik menggunakan metode *Cascade Forward Backpropagation Neural Network*.

Kata Kunci: Peramalan, Jangka Pendek, *Feed Forward Backpropagation*, *Cascade Forward Backpropagation*, *Generalized Regression*, *Neural Network*.

Abstract

In this study, discussing the results of short-term electricity load forecasting. Forecasting methods used are *Feed Forward Backpropagation Neural Network*, *Cascade Forward Backpropagation Neural Network* and *Generalized Regression Neural Network*. Forecasting short-term electrical energy needs refers to the calculation of daily load, daily air temperature. This forecast will predict the electricity load on 7-13 April 2007. In this study, will compare the results of electricity load forecasting using the method of *Feed Forward Backpropagation Neural Network*, *Cascade Forward Backpropagation Neural Network* and *Generalized Regression Neural Network*. Load forecasting results which results close to the actual load contained in the *Cascade Forward Backpropagation Neural Network* method on April 8, 2007 with a MAPE value of 7.6% while the results of load forecasting results that are very large difference with the actual load contained in the *Cascade Forward Backpropagation Neural Network* method with MAPE value of 39.7%. So that in this study the best method of forecasting uses the *Cascade Forward Backpropagation Neural Network* method.

Keywords: Forecasting, Short-term, *Feed Forward Backpropagation*, *Cascade Forward Backpropagation*, *Generalized Regression*, *Neural Network*.

PENDAHULUAN

Peramalan beban listrik jangka pendek pada umumnya untuk mengestimasi aliran daya dan mencegah terjadinya pembebanan yang berlebihan (*overload*). Beban listrik merupakan penjumlahan dari keseluruhan beban yang digunakan oleh konsumen dalam satu waktu tertentu. Tujuan dari peramalan beban listrik adalah untuk memprediksi beban listrik dimasa yang akan datang (Muslimin, 2015).

Peramalan beban listrik berdampak besar dalam operasi sistem tenaga listrik mulai dari perencanaan pembangkitan, analisis aliran daya, unit commitment, dan operasi ekonomis sistem tenaga. Kebutuhan energi listrik semakin hari cenderung berubah-ubah, sehingga Perusahaan Listrik

Negara (PLN) sebagai penyedia energi listrik harus dapat meramalkan kebutuhan beban listrik setiap harinya, ada beberapa metode untuk meramalkan beban listrik, sehingga sangat diperlukan pemilihan metode peramalan beban listrik yang tingkat keakuratan terbaik, sehingga dapat menekan biaya dalam memproduksi energi listrik (Wibowo et al., 2012), banyak metode dapat dipakai untuk melakukan peramalan beban diantaranya, seperti metode *smoothing*, *Box-Jenkins*, ekonometrika, regresi, fungsi transfer dan sebagainya (Safitri et al., 2017).

Artificial Neural Network (ANN) atau Jaringan Syaraf Tiruan (JST) adalah algoritma penyelesaian masalah komputasi di mana prinsip kerjanya mencontoh jaringan syaraf manusia. Salah satu dari jenis metode ini adalah *Feed Forward Backpropagation Neural Network*. Metode

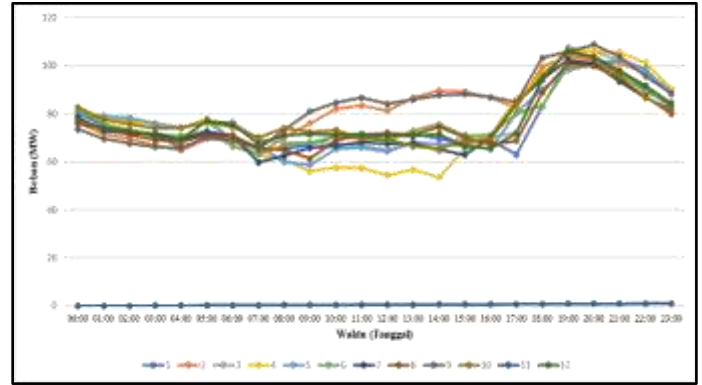
ini digunakan karena, pada saat *output* tidak sama dengan target yang diharapkan maka *output* akan disebarkan mundur (*backward*) pada *hidden layer* dan diteruskan ke unit pada *input layer*, sehingga akan ada *feedback* yang memvalidasi hasil dari keluaran ANN (Panjang & Setiabudi, 2015).

Ada dua langkah dalam memecahkan masalah jaringan saraf tiruan *backpropagation*, yaitu pelatihan, pengujian. Pelatihan adalah suatu proses dimana jaringan belajar untuk mengenali pola-pola sekarang dari set data input. pengujian mengevaluasi kemampuan jaringan untuk kelayakan menyelesaikan solusi, dengan menentukan seberapa dekat output aktual apakah sesuai dengan output yang diinginkan dalam situasi baru (Sinta et al., 2013).

Generalized Regression Neural Network (GRNN) merupakan mode jaringan radial basis yang banyak digunakan untuk melakukan pendekatan suatu fungsi. GRNN secara esensial didasarkan pada regresi nonlinear dimana nilai target *output* ditentukan oleh pola *input* (Caraka, 2015).

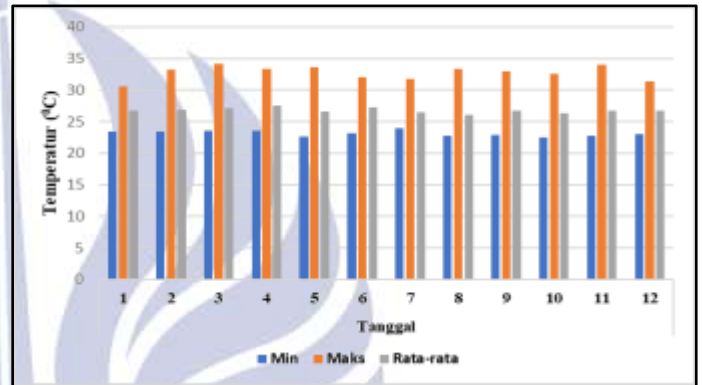
Cascade Forward Backpropagation Neural Network mempunyai ciri di mana terdapat tautan langsung antara lapisan *input* dan *output*, selain tautan tidak langsung melalui lapisan tersembunyi. Pada CFBNN setiap *neuron* di lapisan *input* melekat pada setiap *neuron* lapisan tersembunyi dan dilapisan keluaran. Keuntungan dari metode ini adalah mengakomodasi hubungan nonlinier antara *input* dan *output* dengan tidak menghilangkan hubungan linear antara keduanya (Warsito et al., 2018).

Artikel ilmiah ini, menggunakan metode FFBNN, CFBNN dan GRNN. Data yang digunakan adalah data beban listrik harian yang memperlihatkan perilaku beban listrik di Kota Pontianak, berupa besar beban listrik dalam Mega Watt (MW) dan waktu terjadinya beban tersebut dalam setiap hari (24 jam) data tersebut berdasarkan pada referensi yang diperoleh dari PT. PLN (Persero) Wilayah Kalimantan Barat (Unit Sektor Kapuas) untuk data beban listrik, sedangkan data temperatur atau suhu udara Kota Pontianak berdasarkan referensi diperoleh dari Badan Meteorologi dan Geofisika (BMG) Supadio, Pontianak, kedua jenis data tersebut adalah data harian dengan rentang waktu Januari 2007 hingga Mei 2007 dengan menggunakan data pada bulan April 2007. Berikut data yang digunakan ditunjukkan pada Gambar 1.



(Sumber: Hasim, 2008)

Gambar 1. Data Beban Listrik Tanggal 1-12 April 2007



(Sumber: Hasim, 2008)

Gambar 2. Temperatur Tanggal 1-12 April 2007

KAJIAN PUSTAKA

Peramalan Beban

Peramalan merupakan prediksi atau dugaan dari suatu kejadian tertentu pada masa yang akan datang. Beban yang diramalkan disesuaikan dengan kebutuhan dengan jangka waktu tertentu. Menurut jangka waktunya, peramalan dibagi menjadi 3 periode sesuai dengan materi yang diramalkannya yaitu: (Sani, 2018)

1. Peramalan Jangka Panjang (*Long-Term Forecasting*)
2. Peramalan Jangka Menengah (*Mid-Term Forecasting*)
3. Peramalan Jangka Pendek (*Short-Term Forecasting*)

Feed Forward Backpropagation Neural Network (FFBNN)

Jaringan *backpropagation* merupakan salah satu algoritma yang sering dipakai dalam menyelesaikan permasalahan yang kompleks. Hal ini didukung karena jaringan dengan algoritma ini dilatih (*learned*) dengan menggunakan metode belajar terbimbing. Algoritma pelatihan *backpropagation neural network* terdiri dari 2 langkah, yaitu propagasi maju dan propagasi mundur.

Perambatan maju dimulai dengan memberikan pola *input* ke *input layer*. Pola ini merupakan nilai aktivasi unit-unit *input*. Dengan melakukan perambatan maju dihitung nilai aktivasi pada unit-unit pada *layer* selanjutnya. Pada setiap *layer*, tiap unit pengolah melakukan penjumlahan berbobot dan menerapkan fungsi sigmoid untuk menghitung keluarannya.

Langkah-langkah algoritma Pelatihan Propagasi Balik adalah sebagai berikut:

- 1) Inisialisasi bobot-bobot.
- 2) Bila syarat berhenti adalah salah, kerjakan langkah 2 sampai 9.
- 3) Untuk setiap pasangan pelatihan, kerjakan langkah 3 sampai 8.
- 4) Tiap unit input ($x_i, i = 1, \dots, n$) menerima isyarat *input* x_i dan diteruskan ke unit-unit tersembunyi.

- 5) Tiap unit tersembunyi ($z_j, j = 1, \dots, p$) menjumlahkan isyarat masukan berbobot;

$$z_in_j = v_{oj} + \sum_{i=1}^n x_i v_{ij} \quad (1)$$

dengan menerapkan fungsi aktivasi hitung:

$$z_j = f(z_in_j) \quad (2)$$

dan mengirim isyarat ke unit *output*.

- 6) Tiap unit keluaran ($y_k, k = 1, \dots, m$) menjumlahkan isyarat *input* berbobot,

$$y_in_k = w_{ok} + \sum_{j=1}^p z_j w_{jk} \quad (3)$$

dengan menerapkan fungsi aktivasi hitung,

$$y_k = f(y_in_k) \quad (4)$$

- 7) Tiap unit *output* ($y_k, k = 1, \dots, m$) menerima pola sasaran berkaitan dengan pola pelatihan *input*.

Hitung *error*:

$$\delta_k = (t_k - y_k) f'(y_in_k) \quad (5)$$

$$\Delta w_{jk} = \alpha \delta_k z_j \quad (6)$$

$$\Delta w_{ok} = \alpha \delta_k \quad (7)$$

- 8) Tiap unit tersembunyi ($z_j, j = 1, \dots, p$) menjumlahkan delta masukannya (dari unit-unit di lapisan atasnya).

$$\delta_in_j = \sum_{k=1}^m \delta_k w_{jk} \quad (8)$$

Hitung *error*:

$$\delta_j = \delta_in_j f'(z_in_j) \quad (9)$$

$$\Delta v_{ij} = \alpha \delta_j x_i \quad (10)$$

- 9) Tiap unit keluaran ($y_k, k=1, \dots, m$) memperbaharui bobot-bobot dan bias ($j=0, 1, \dots, p$)

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad (11)$$

Tiap unit tersembunyi ($z_j, j=1, \dots, p$) memperbaharui bobot dan prasikapnya ($i=0, 1, \dots, n$)

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad (12)$$

- 10) Uji syarat berhenti.

Keterangan:

x_i = sinyal masukan pembelajaran.

w_{jk} = bobot koneksi antara sel j ke sel k .

z_j = sinyal luaran unit tersembunyi.

f_k = fungsi aktivasi sel k

y_k = sinyal luaran pembelajaran.

t_k = sinyal referensi.

δ_k = sinyal *error*.

α = konstanta laju pembelajaran

q = literasi ke- q .

Cascade Forward Backpropagation Neural Network (CFBNN)

Cascade Forward Backpropagation Neural Network bisa dikatakan hampir mirip dengan FFBNN. Tetapi pada CFBNN menyertakan tautan berat dari *input layer* ke setiap *layer*. CFBNN menambahkan tautan tambahan dari setiap lapisan ke lapisan berikutnya (Furat & İbrikçi, 2019).

Ketika jaringan dua umpan maju dibandingkan dengan jaringan *multi-layer*, hubungan kompleks dipelajari lebih lanjut segera oleh jaringan *multi-layer*. Bisa dianalogikan seperti jaringan tiga lapis memiliki tautan dari layer 1 ke layer 2, dari layer 1 ke layer 3 dan dari layer 2 ke lapisan 3. Jaringan tiga lapis memiliki tautan dari input apa pun untuk setiap tiga lapisan. Mempelajari hubungan dalam jaringan dapat dipercepat melalui tautan tambahan antar lapisan. Jaringan Neural CFB mirip dengan Jaringan Neural TBS di menggunakan algoritma backpropagation untuk memperbarui bobot.

Generalized Regression Neural Network (GRNN)

Generalized Regression Neural Network dapat mengontrol kesalahan *backpropagation*. Metode ini memiliki keuntungan dari fungsi absolut antara input dan *output* langsung dari data pelatihan. GRNN memiliki empat *layer* yang terdiri dari *input*, lapisan pola, lapisan tambahan dan *output*. Lapisan pertama terhubung ke lapisan kedua, yaitu lapisan pola. Jumlah variabel *input* tergantung pada jumlah data yang diamati pada lapisan *input*. Lapisan *input* mengumpulkan informasi dan meneruskannya ke lapisan pola. Lapisan pola memiliki fungsi untuk mengklasifikasikan proses pelatihan (Aribowo et al., 2020).

Persamaan dalam metode ini berbeda dari algoritma *backpropagation*. Metode GRNN menggunakan fungsi peramalan secara langsung dari data pelatihan. GRNN adalah metode untuk memperkirakan fungsi probabilitas probabilitas gabungan dari x dan y , diberikan hanya satu set pelatihan (Aribowo et al., 2020).

$$y_i(x) = \frac{\sum_{i=1}^n y_i f(x,y)}{\sum_{i=1}^n f(x,y)} \quad (13)$$

$f(x,y)$ biasanya diperkirakan dari sampel pengamatan variabel (x, y) sebagai berikut:

$$f(x,y) = \frac{1}{2\pi^{(p+1)/2} \sigma^{(p+1)}} \frac{1}{n} \quad (14)$$

$$\sum_{i=1}^n \exp \left[-\frac{(x-x^i)^T(x-x^i)}{2\sigma^2} \right] \exp \left[-\frac{(y-y_i)^2}{2\sigma^2} \right] \quad (15)$$

$$\delta_i^2 = (x - x^i)^T(x - x^i) \quad (16)$$

$$\hat{y}(x) = \frac{\sum_{i=1}^n y_i \exp\left(-\frac{d_i^2}{2\sigma^2}\right)}{\sum_{i=1}^n \exp\left(-\frac{d_i^2}{2\sigma^2}\right)} \quad (17)$$

Ket:

- $f^*(x,y)$ = estimasi probabilitas
- n = jumlah observasi
- σ = parameter *smoothing*
- p = dimensi vektor variabel x

Parameter GRNN yang dapat diatur dan dioptimalkan secara eksperimental adalah parameter *smoothing*. Ketika parameter *smoothing* diatur, estimasi kerapatan akan menjadi lunak. Sebaliknya, bila nilai parameter *smoothing* terlalu kecil yang memungkinkan estimasi kepadatan menjadi bentuk non-Gaussian (Aribowo et al., 2020).

Mean Square Error (MSE)

FFBNN dilatih dengan metode belajar terbimbing. Metode ini pada jaringan terdiri dari pola *input* dan pola target. Pelatihan dilakukan berulang-ulang sehingga dihasilkan jaringan yang memberi tanggapan yang benar ke seluruh *input*.

Menghitung MSE yaitu dengan cara membandingkan nilai *output* ($y_i(x)$) dan nilai target ($T_i(x)$). Hasilnya adalah perbedaan antara hasil dibagi dengan jumlah variabel (n). Ini akan memberikan hasil *error* peramalan. Selisih yang dihasilkan antara keduanya dapat ditentukan dengan cara menggunakan persamaan berikut: (Aribowo et al., 2020)

$$MSE = \frac{1}{n} \sum_{i=1}^n (T_i(x) - y_i(x))^2 \quad (18)$$

Keterangan:

- T_i = nilai *output* yang diinginkan atau target
- Y_i = nilai *output* jaringan syaraf
- n = jumlah observasi.

Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) adalah algoritma yang menghitung kesalahan atau perbedaan antara data nyata (beban *real*) dan peramalan. Kemudian dihitung sebagai persentase dari data nyata (beban *real*). Hasilnya diperoleh dengan nilai rata-rata. Percobaan yang memiliki pencapaian yang baik atau dapat diterima apabila nilai MAPE di bawah 10% (Aribowo et al., 2020).

Ketika data diuji, hasil pelatihan akan diuji dengan menggunakan metode *Mean Absolute Deviation* (MAD) dan *Mean Absolute Percentage Error* (MAPE). Untuk mencari nilai MAD dan MAPE dapat dilakukan dengan menggunakan persamaan berikut: (Aribowo et al., 2020)

$$MAD = \frac{1}{N} \sum_{i=1}^N |R_i - F_i| \quad (19)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|R_i - F_i|}{R_i} \times 100 \quad (20)$$

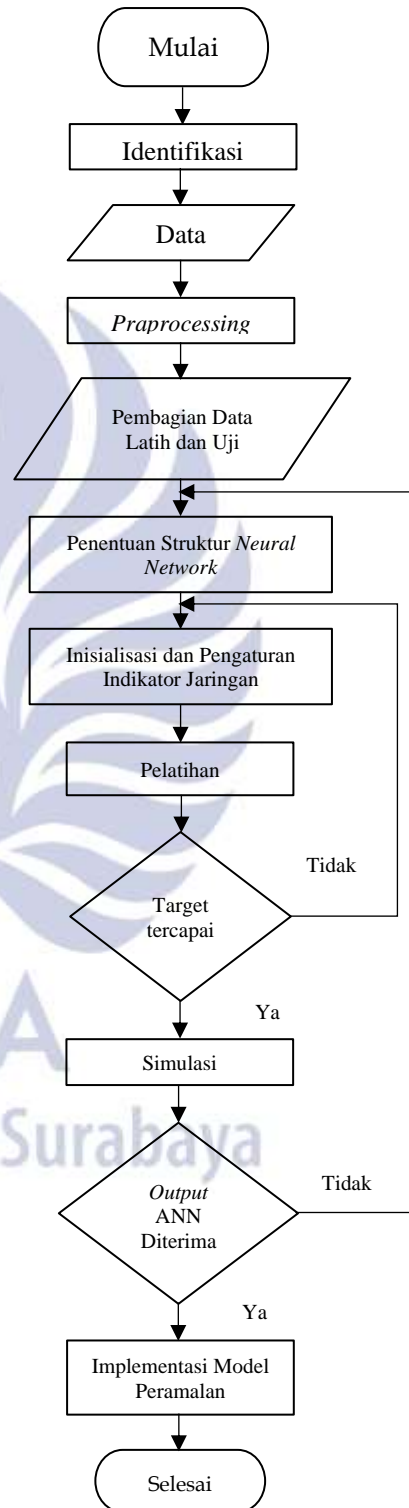
Keterangan:

- N = Banyaknya observasi

- F = Peramalan
- R_i = Data aktual

HASIL DAN PEMBAHASAN

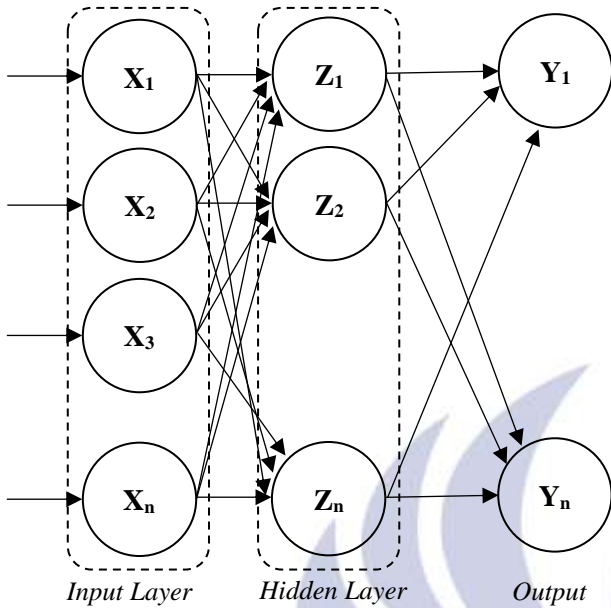
Flowchart untuk peramalan beban listrik jangka pendek ditunjukkan pada Gambar 1.



Gambar 3. *Flowchart* Peramalan Beban Listrik Jangka Pendek

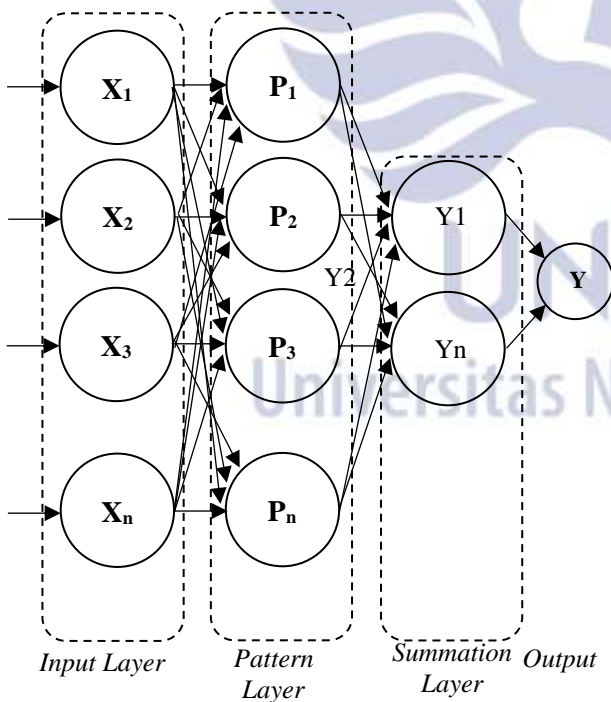
Arsitektur *Artificial Neural Network*

Arsitektur model yang dikembangkan dari metode FFBN ditunjukkan pada Gambar 4.




Gambar 4. Arsitektur *Feed Forward Backpropagation Neural Network*

Arsitektur model yang dikembangkan dari metode *Generalized Regression Neural Network* ditunjukkan pada Gambar 5.




Gambar 5. Arsitektur *Generalized Regression Neural Network*


Hasil peramalan metode *Feed Forward Backpropagation Neural Network*, metode *Cascade Forward Backpropagation Neural Network* dan metode *Generalized Regression Neural Network* ditunjukkan pada Gambar 6 sampai Gambar




Gambar 6. Grafik Perbandingan Peramalan Beban Listrik Tanggal 7 April 2007 (Sumber: Data Primer)




Gambar 7. Grafik Perbandingan Peramalan Beban Listrik Tanggal 8 April 2007 (Sumber: Data Primer)




Gambar 8. Grafik Perbandingan Peramalan Beban Listrik Tanggal 9 April 2007 (Sumber: Data Primer)




Gambar 9. Grafik Perbandingan Peramalan Beban Listrik Tanggal 10 April 2007 (Sumber: Data Primer)



Gambar 10. Grafik Perbandingan Peramalan Beban Listrik Tanggal 11 April 2007 (Sumber: Data Primer)



Gambar 11. Grafik Perbandingan Peramalan Beban Listrik Tanggal 12 April 2007 (Sumber: Data Primer)



Gambar 12. Grafik Perbandingan Peramalan Beban Listrik Tanggal 13 April 2007 (Sumber: Data Primer)

Untuk nilai MAPE dari masing-masing metode ditunjukkan pada Tabel 1.

Tabel 1. Mean Absolute Deviation (MAD)

TGL	MAD (%)		
	FFBNN	CFBNN	GRNN
7	9.3	27.7	10.1
8	7.7	3.7	8.1
9	15.8	13.2	12.3
10	12.4	6.3	7.9
11	21.2	9.9	9.7
12	23.9	5.5	11.9
13	22.3	8.3	10.9

Tabel 2. Mean Absolute Percentage Error (MAPE)

TGL	MAPE (%)		
	FFBNN	CFBNN	GRNN
7	11.1	39.7	13.4
8	9.0	5.1	10.4
9	17.3	15.1	14.0
10	16.4	8.4	9.3
11	29.3	13.5	12.1
12	34.9	7.6	15.2
13	30.3	10.4	13.0

PENUTUP

Kesimpulan

Hasil peramalan beban yang hasilnya mendekati beban aktual terdapat pada metode *Cascade Forward Backpropagation Neural Network* pada tanggal 12 April 2007 dengan nilai MAPE sebesar 7,6% sedangkan hasil peramalan beban yang hasilnya menjauhi beban aktual terdapat pada metode *Cascade Forward Backpropagation Neural Network* dengan nilai MAPE sebesar 39,7%. Sehingga pada penelitian ini metode peramalan yang paling baik menggunakan metode *Cascade Forward Backpropagation Neural Network*.

Saran

Penelitian ini menggunakan data berdasarkan pada referensi yang diperoleh dari PT. PLN (Persero) Wilayah Kalimantan Barat (Unit Sektor Kapuas) untuk data beban listrik, sedangkan data temperatur atau suhu udara Kota Pontianak berdasarkan referensi diperoleh dari Badan Meteorologi dan Geofisika (BMG) Supadio Pontianak, kedua jenis data tersebut adalah data harian dengan rentang waktu Januari 2007 hingga Mei 2007, sehingga perlu dilakukan peramalan dengan sumber data yang terbaru (*up to date*), juga disarankan untuk menggunakan metode peramalan untuk mendapatkan hasil peramalan dengan nilai *error* yang mendekati dengan daya *real* di setiap jam per jam pada satu hari (24 jam).

DAFTAR PUSTAKA

- Aribowo, W., Muslim, S., & Basuki, I. (2020). Generalized Regression Neural Network for Long-Term Electricity Load Forecasting. *Proceeding - ICoSTA 2020: 2020 International Conference on Smart Technology and Applications: Empowering Industrial IoT by Implementing Green Technology for Sustainable Development, February*. <https://doi.org/10.1109/ICoSTA48221.2020.1570611361>
- BMKG, 2016, "Data Iklim Harian Temperatur Suhu" BMKG Batu, http://dataonline.bmkg.go.id/data_iklim,1Juli2020pukul09.58.
- Caraka, R. E., Yasin, H., & Prahutama, A. (2014). Pemodelan General Regression Neural Network (Grnn) Dengan Pemodelan General Regression Neural Network (Grnn) Dengan Peubah Input Data Return Untuk. *Trusted Digital Identity and Intelligent System, June 2015*, 283–288. https://www.researchgate.net/publication/277712485_Pemodelan_General_Regression_Neural_Network_GRNN_Dengan_Peubah_Input_Data_Return_untuk_Peramalan_Indeks_Hangseng?ev=prf_pub
- Elektro, T., Teknik, F., Surabaya, U. N., & Aribowo, W. (2015). *Peramalan Beban Listrik Jangka Pendek Menggunakan Metode Feed Forward Backpropagation Neural Network Muhammad Permana Setya Gunawan Abstrak*.
- Furat, F. G., & İbrikiçi, T. (2019). *Application of Feed Forward Backpropagation and Cascade Forward Backpropagation Neural Network Algorithms to Detect Pulsar Stars Application of Feed Forward Backpropagation and Cascade Forward Backpropagation Neural Network Algorithms to Detect Pulsar Stars. March*.
- Hasim, Agus. 2008. "Prakiraan Beban Listrik Kota Pontianak Dengan Jaringan Syaraf Tiruan (*Artificial Neural Network*). Sekolah Pasca Sarjana. Bogor: Institut Pertanian Bogor.
- Ikhtari, H. (2010). *Dengan Menggunakan Metode Adaptive Neuro Fuzzy Inference System (ANFIS) Oleh : Ikhtari Haimi*.
- Indonesia, U., Dwianto, B., Teknik, F., Studi, P., & Elektro, T. (2012). *Berdasarkan Data Historis Menggunakan Metode Generalized Autoregressive Conditional Heteroskedasticity (Garch) Metode Generalized Autoregressive Conditional*.
- M. Djiteng. (1990). *Operasi Sistem Tenaga Listrik*, Balai Penerbit dan Humas ISTN, Jakarta, hal 13.
- Muslimin. (2015). Peramalan Beban Listrik Jangka Menengah Pada Sistem Kelistrikan Kota Samarinda. *Jiti, 14(09)*, 113–121.
- Panjang, J., & Setiabudi, D. (2015). *Sistem Informasi Peramalan Beban Listrik. 1(1)*, 1–5.
- Safitri, T., Dwidayati, N., Safitri, T., Dwidayati, N., & Peramalan, S. P. (2017). Menggunakan Exponential Smoothing Holt-Winters dan Arima. *Unnes Journal of Mathematics, PISSN 2252-6943, EISSN 2460-5859, 6(1)*, 48–58.
- Sani, S. A. (2018). Perbandingan Metode Peramalan Beban Listrik Jangka Pendek menggunakan Metode Moving Average , Single Exponential Smoothing dan Autoregressive Moving Average di Yogyakarta. *Perbandingan Metode Peramalan Beban Listrik Jangka Pendek Menggunakan Metode Moving Average , Single Exponential Smoothing Dan Autoregressive Moving Average Di Yogyakarta*, 68.
- Sinta, R., Gernowo, R., & Suryono, S. (2013). Rancang Bangun Sistem Peramalan Konsumsi Daya Listrik dengan Artificial Neural Network Backpropagation. *Jurnal Sistem Informasi Bisnis, 3(1)*, 48–58. <https://doi.org/10.21456/vol3iss1pp48-58>.
- Teknik, J., Fakultas, S., & Maret, U. S. (2004). *Lembar persetujuan. 1–12*.
- Teknologi, J., & No, E. (2005). Aplikasi Jaringan Syaraf Tiruan Untuk Peramalan Beban Tenaga Listrik Jangka Panjang Pada Sistem Kelistrikan Di Indonesia. *Tahun XIX, 3*, 211–217. http://seminar1.te.ugm.ac.id/pdf/05920_Paper3.pdf
- Triwulan, Y., Hariyanto, N., & Anwari, S. (2013). Peramalan Beban Puncak Listrik Jangka Pendek Menggunakan Metode Jaringan Syaraf Tiruan. *Jurnal Reka Elkomika ©TeknikElektro | Itenas Jurnal Online Institut Teknologi Nasional Jurnal Reka Elkomika, 1(4)*, 2337–2439.
- Warsito, B., Santoso, R., Suparti, & Yasin, H. (2018). Cascade Forward Neural Network for Time Series Prediction. *Journal of Physics: Conference Series, 1025(1)*. <https://doi.org/10.1088/1742-6596/1025/1/012097>
- Wibowo, H., Mulyadi, Y., & Abdullah, A. G. (2012). Peramalan Beban Listrik Jangka Pendek Terklasifikasi Berbasis Metode Autoregressive Integrated Moving Average. *Electrans, 11(2)*, 44–50.