PERAMALAN BEBAN LISTRIK JANGKA PENDEK MENGGUNAKAN METODE *FEED FORWARD BACKPROPAGATION NEURAL NETWORK*

Muhammad Permana Setya Gunawan
Teknik Elektro, Fakultas Teknik, Universitas Negeri Surabaya
e-mail: muhammadgunawan@mhs.unesa.ac.id

Widi Aribowo, S.T., M.T.
Teknik Elektro, Fakultas Teknik, Universitas Negeri Surabaya
e-mail: widiaribowo@unesa.ac.id

Abstrak

Penelitian ini, membahas perbandingan metode peramalan. Metode peramalan yang digunakan adalah *Feed Forward Backpropagation Neural Network* dan *Generalized Regression Neural Network.* Peramalan beban listrik jangka pendek mengacu pada perhitungan beban harian, temparatur udara harian. Peramalan ini akan meramalkan beban listrik pada tanggal 3 Mei 2007. Peramalan ini akan membandingkan metode *Feed Forward Backpropagation Neural Network* dengan berbagai fungsi pelatihannya dan metode *Generalized Regression Neural Network*, pada metode *Feed Forward Backpropagation Neural Network* hasil peramalan yang nilainya mendekati beban aktual adalah pada pukul 05.00 dengan hasil peramalan dari fungsi pelatihan traincgf sebesar 0,08% sedangkan pada metode *Generalized Regression Neural Network* pada pukul 17.00 dengan hasil peramalan sebesar 29,06% dan beban peramalan yang selisihnya paling besar dengan beban aktual pada metode *Feed Forward Backpropagation Neural Network* adalah pada pukul 21.00 dengan hasil dari peramalan fungsi pelatihan traincgp sebesar 55,14% sedangkan pada metode *Generalized Regression Neural Network* pada pukul 12.00 sebesar 4,34%. Peramalan terbaik terdapat pada metode *Feed Forward Backpropagation Neural Network* dengan fungsi pelatihan traincgf di mana nilai MAPE-nya mendekati nilai beban *real* yaitu sebesar 2,52%.
Kata Kunci: Peramalan Beban Listrik, Peramalan Jangka Pendek, *Feed Forward Backpropagation Neural Network, Generalized Regression Neural Network, Mean Absolute Percentage Error.*

Abstract

This study discusses the comparison of forecasting methods. Forecasting methods used are Feed Forward Backpropagation Neural Network and Generalized Regression Neural Network. Short-term electricity load forecasting refers to the calculation of daily load, daily air temperature. This forecast will forecast the electricity load on May 3, 2007. This forecast will compare the Feed Forward Backpropagation Neural Network method with its various training functions and the Generalized Regression Neural Network method, the method of Feed Forward Backpropagation Neural Network forecasting results whose value is close to the actual load is at 05.00 with the traincgf training function of 75.6 MW or 0.08% while the Generalized Regression Neural Network method at 17.00 with forecasting results 29.06% and forecasting load which is the biggest difference with the actual load on the Feed Forward Backpropagation Neural Network method is at 21.00 with a traincgp training function of 55.14% while the Generalized Regression Neural method Network at 12.00 is 54.34%. The best forecast is found in the Feed Forward Backpropagation Neural Network method with the traincgf training function where the MAPE value approaches the real load value of 2.52%.
Keywords: *Load Forecasting, Short-term Forecasting, Feed Forward Backpropagation Neural Network, Generalized Regression Neural Network, Mean Absolute Percentage Error.*

PENDAHULUAN

Kehidupan masyarakat sangat bergantung kepada sumber daya energi, salah satunya adalah energi listrik dengan ditandai dengan fenomena peningkatan kebutuhan listrik di masyarakat. Hal tersebut mengharuskan PT. PLN (Persero) yang ditunjuk selaku penyalur utama listrik ke masyarakat berdasarkan amanat undang-undang (Khasanah, 2019:1), melakukan perencanaan operasi dan perencanaan sistem pengembangan tenaga listrik untuk mengetahui seberapa besar daya listrik yang harus disalurkan ke konsumen agar daya listrik yang ditransmisikan tepat sasaran dan tepat ukuran (Kristiana, 2015:1).

Untuk memasok energi listrik ke pelanggan dengan cara yang aman dan ekonomis, perusahaan listrik menghadapi banyak tantangan diantaranya ekonomi dan teknis dalam pengoperasian. Di antara penelitian yang sudah ada peramalan beban merupakan salah satu bidang penelitian yang paling sering muncul dalam beberapa tahun terakhir (Baliyan, 2015:2).

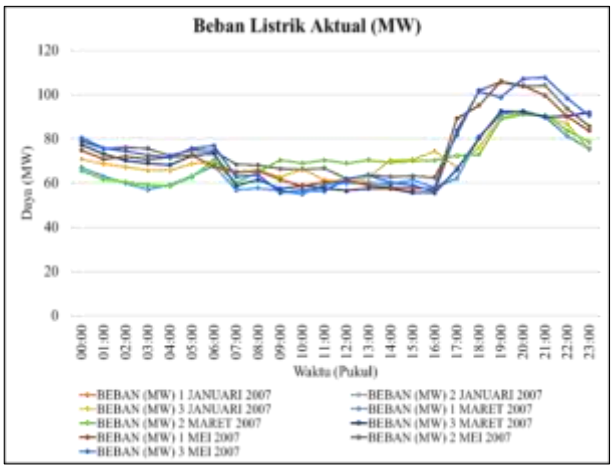

Gambar 1. Data Beban Listrik Aktual (MW)

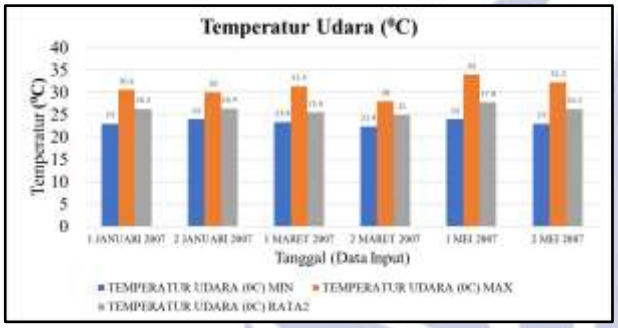

Gambar 2. Data Temperatur Udara (^{0}C)

Peramalan yang ada pada tenaga listrik umumnya berupa peramalan atau prediksi beban (*load forecasting*) yang meliputi peramalan atau prediksi beban puncak (MW) dan peramalan atau prediksi kebutuhan atau permintaan energi listrik (*demand forecasting*) (MWh) (Hamidie, 2009). Banyak metode yang dapat dipakai untuk melakukan peramalan beban diantaranya, seperti metode *smoothing*, Box-Jenkins, ekonometrika, regresi, fungsi transfer dan sebagainya (Safitri, 2017:2).

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 (Setiabudi, 2015:1).

Generalized Regression Neural Network (GRNN) merupakan mode jaringan radial basis yang banyak digunakan untuk melakukan pendekatan suatu fungsi. Dasar dari operasi *Generalized Regression Neural Network* (GRNN) secara esensial didasarkan pada regresi nonlinear dimana nilai target *output* ditentukan oleh pola *input* (Caraka, 2015:4).

Artikel ilmiah ini, menggunakan metode *Feed Forward Backpropagation Neural Network* dengan membandingkan hasil dari berbagai fungsi pelatihan yaitu fungsi traingd, traingda, traingdx, traingdm, traincgf, traincgp serta traincgb dan metode *Generalized Regression Neural Network.* 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 refrensi 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 refrensi diperoleh dari Badan Meteorologi dan Geofisika (BMG) Supadio, Pontianak, kedua jenis data tersebut adalah data harian dengan rentang waktu Januari 2007 hingga Mei 2007 di mana dalam artikel ini menggunakan data pada tanggal 1-2 Januari 2007 dan 1-2 Maret 2007 sebagai *input* latih dan tanggal 3 Januari 2007 dan 3 Maret 2007 sebagai target latih dengan tanggal 1-2 Mei 2007 sebagai *input* uji dan tanggal 3 Mei 2007 sebagai target uji, data beban listrik harian (aktual) dan temperatur udara harian ditunjukan pada Gambar 1 dan Gambar 2.

METODE

Peramalan Beban

Peramalan beban listrik merupakan penerapan dari ilmu peramalan yang digunakan untuk memperkirakan perubahan dari beban listrik yang diperlukan oleh pelanggan atau konsumen. Hasil dari peramalan tersebut akan dimanfaatkan untuk membuat rencana pemenuham kebutuhan konsumen ataupun untuk pengembangan *supply* energi listrik setiap saat secara cukup dan menjamin kehandalannya (Pratama, 2016:2).

Salah satu fitur penting dari *Artificial Neural Network (ANN)* dapat digunakan untuk mempelajari data yang kompleks. Berdasarkan percobaan yang ada, *neural network* yang terlatih dengan baik dapat meramalkan dan mencapai data target yang diinginkan. Salah satu kelebihan dari ANN yaitu, memiliki respon yang cepat terhadap penyimpangan diantara beban aktual dan yang diramalkan (Sruthi dan Catherine, 2015:4).

Backpropagation melatih jaringan untuk memperoleh keseimbangan pada kemampuan jaringan mengenal pola yang dipakai ketika proses pelatihan serta kemampuan jaringan untuk memberikan *feedback* yang benar terhadap *input* yang samaa dengan pola yang dipakai ketika proses pelatihan (Suhendra dan Wardoyo, 2015:2). *Generalized Regression Neural Network* menghasilkan *output* berupa vektor yang memiliki multivariasi, di mana pada bagian ini disederhanakan pada *output* (Caraka, 2015:4).

Flowchart untuk peramalan beban listrik ditunjukan pada Gambar 3.

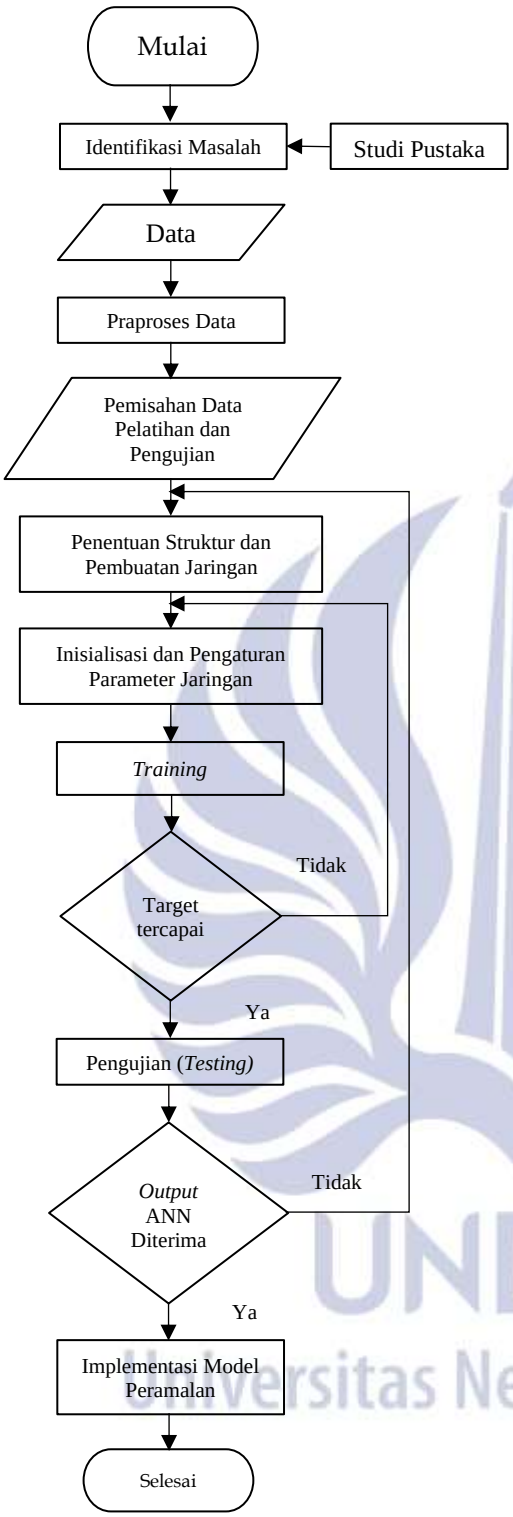

Gambar 3. *Flowchart* Peramalan Beban Listrik Menggunakan ANN

Tahapan pertama pada penelitian ini yaitu melakukan praproses pada data yang akan digunakan untuk melakukan peramalan kemudian data dibagi menjadi data *input* dan *output*, setelah itu menentukan struktur dan pembuatan jaringan untuk melakukan proses pelatihan jaringan bilamana *output* target telah tercapai maka dapat dilakukan simulasi atau pengujian sehingga akan menghasilkan *output* peramalan dari ANN.

Feed Forward Backpropagation Neural Network

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.

Algoritma pelatihan *backpropagation neural network* adalah sebagai berikut: (Hasim, 2008:14)

Langkah 0: Inisialisasi bobot-bobot.

Langkah 1: Bila syarat berhenti adalah salah, kerjakan langkah 2 sampai 9.

Langkah 2: Untuk setiap pasangan pelatihan, kerjakan langkah 3 sampai 8.

Feed Forward:

Langkah 3: Tiap unit *input* (x_i, i = 1, ..., n) menerima isyarat *input* x_i dan diteruskan ke unit-unit tersembunyi.

Langkah 4: Tiap unit tersembunyi (z_j, j = 1, ..., p) menjumlahkan isyarat masukan berbobot;

$$z_in_j = v_{oj} + \sum_{i=1}^{n} x_1 v_{ij} \quad (1)$$

dengan menerapkan fungsi aktivasi hitung:

$$z_j = f(z\text{-}in_j) \quad (2)$$

dan mengirim isyarat ke unit *output*.

Langkah 5: Tiap unit keluaran (y_k, k = 1,....,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,

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

Backpropagation Error:

Langkah 6: Tiap unit *output* (y_k, k = 1,...,m) menerima pola sasaran berkaitan dengan pola pelatihan *input*.

Hitung *error*:

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

Hitung koreksi bobot:

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

$$\Delta w_{0k} = \alpha\, \delta_k \quad (7)$$

Langkah 7: Tiap unit tersembunyi (z_j, j = 1,....,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:*

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

Hitung koreksi bobot:

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

Update bobot dan bias:

Langkah 8: Tiap unit keluaran (y_k, k = 1, ..., m) memperbaharui bobot-bobot dan bias (j = 0, 1, ..., p)

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

UNESA Universitas Negeri Surabaya

Tiap unit tersembunyi (z*j*, j = 1, ..., p) memperbaharui bobot dan prasikapnya (I = 0, 1, …, n)

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

Langkah 9: Uji syarat berhenti.

Ket:

$x_1 \ldots x_n$ = *input*
$y_1 \ldots y_n$ = *output*
$z_1 \ldots z_n$ = nilai *hidden layer*
v_{ij} = bobot antara *input layer* dan *hidden layer*
w_{jk} = bobot antara *hidden layer* dan *output layer*
δ = galat informasi
α = kecepatan atau laju belajar

Fungsi Pelatihan (*Train)*

Fungsi pelatihan yang digunakan pada metode *Fast Forward Backpropagation Neural Network* pada artikel ilmiah ini untuk mendapatkan perbandingan diantaranya:

1. Traingd *(Gradient Descent)* adalah fungsi pelatihan jaringan yang memperbarui nilai bobot dan bias berdasarkan turunan gradien.
2. Traingda *(Gradient Descent with Adaptive Learning Rate Backpropagation)* adalah fungsi pelatihan jaringan yang memperbarui nilai bobot dan bias menurut turunan gradien dengan tingkat pembelajaran adaptif.
3. Traingdx *(Gradient Descent with Momentum And Adaptive Learning Rate Backpropagation)* adalah fungsi pelatihan jaringan yang memperbarui nilai bobot dan bias berdasarkan momentum turunan gradien dan tingkat pembelajaran adaptif.
4. Traingdm *(Gradient Descent with Momentum Backpropagation)* adalah pelatihan jaringan yang memperbarui bobot dan nilai bias menurut turunan gradien dengan momentum.
5. Traincgf *(Conjugate Gradient Backpropagation with Fletcher-Reeves Updates)* adalah fungsi pelatihan jaringan yang memperbarui bobot dan nilai bias menurut konjugasi gradien *backpropagation* dengan pembaruan Fletcher-Reeves.
6. Traincgp *(Conjugate Gradient Backpropagation with Polak-Ribiére Updates)* adalah fungsi pelatihan jaringan yang memperbarui nilai bobot dan bias berdasarkan konjugasi gradien *backpropagation* dengan pembaruan Polak-Ribiére.
7. Traincgb *(Conjugate Gradient Backpropagation with Powell-Beale Restarts)* adalah fungsi pelatihan jaringan yang memperbarui nilai bobot dan bias berdasarkan pada propagasi balik konjugasi gradien dengan pengulangan Powell-Beale.

Generalized Regression Neural Network

Generalized Regression Neural Network dapat mengontrol kesalahan *backpropagation*. Metode ini memiliki keuntungan dari fungsi absolut antara input dan *output* langsung dari data pelatihan. Kelebihannya adalah *learning* yang cepat dan kontrol yang mudah. Landasan teori dari *Generalized Regression Neural Network* adalah analisis regresi nonlinear (Wihardono, 2016:2).

Generalized Regression Neural Network memiliki empat *layer* yang terdiri dari *input*, lapisan pola, lapisan tambahan dan *output*. Lapian 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, 2020:2).

Persamaan dalam metode ini berbeda dari algoritma *backpropagation*. Metode *Generalized Regression Neural Network* menggunakan fungsi peramalan secara langsung dari data pelatihan. Persamaan dari metode *Generalized Regression Neural Network* sebagai beikut: (Aribowo, 2020:2).

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

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

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

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

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

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

Ket:

$\hat{f}(x,y)$ = estimasi probabilitas
n = jumlah observasi
σ = parameter *smoothing*
p = dimensi vektor variabel x

Parameter *Generalized Regression Neural Network* 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, 2020:2).

Penentuan Pola *Input* dan Pola *Output*

Terlebih dahulu membagi data menjadi 2 bagian yaitu menjadi data *input* dan target *output*. Berikut diagram blok model ANN pada penelitian ini ditunjukan pada Gambar 4.

UNESA Universitas Negeri Surabaya

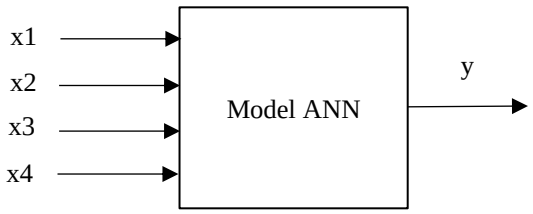

Gambar 4. Diagram Blok Model ANN

Ket:
x1 = Beban tanggal 1 Januari, 1 Maret, 1 Mei 2007
x2 = Beban tanggal 2 Januari, 2 Maret, 2 Mei 2007
x3 = Suhu tanggal 1 Januari, 1 Maret, 1 Mei 2007
x4 = Suhu tanggal 2 Januari, 2 Maret, 2 Mei 2007
y = Beban hasil prediksi tanggal 3 Mei 2007

Pola *Input*

Pola *input* terdiri dari:

1. Data beban listrik per hari dan temperatur udara pada tanggal 1-2 Januari, 1-2 Maret sebagai data *input* latih dan 1-2 Mei 2007 sebagai data *input* uji.
2. Data beban listrik per hari dan temperatur udara pada tanggal 3 Januari, 3 Maret sebagai data target latih. Dapat dilihat diagram blok pola *input* dan *output* pada Gambar 4.

Pola *Output*

Pola *Output* adalah keluaran yang diharapkan atau target uji dari model peramalan, yaitu berupa hasil peramalan beban listrik dari jam ke jam selama 24 jam pada tanggal 3 Mei 2007. Dengan demikian jumlah neuron keluaran jaringan adalah 24 neuron.

Data yang digunakan sebagai *input* adalah data beban listrik setiap jam dalam satu hari (24 jam) dan temperatur udara dalam satu hari temperatur minimum, maksimum dan rata-rata, dapat dilihat pada Gambar 4.

***Mean Square Error* (MSE)**

Feed Forward Backpropagation Neural Network 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, 2020:4)

Mean Square Error (MSE):

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

Ket:
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, 2020:4).

Ketika data diuji, hasil pelatihan akan diuji dengan menggunakan metode *Mean Absolute Deviation* (MAD) dan *Mean Absolute Perscentage Error* (MAPE). Untuk mencari nilai MAD dan MAPE dapat dilakukan dengan menggunakan persamaan berikut: (Aribowo, 2020:4)

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

$$MAPE = \frac{1}{N}\sum_{i=1}^{N}\frac{|R_i - F_i|}{R_i}x100 \quad (20)$$

Ket:
N = Banyaknya observasi
F_i = Peramalan
R_i = Data aktual

Arsitektur *Artificial Neural Network*

Pada metode *Feed Forward Backpropagation Neural Network* ini menggunakan 8 *layer* dan 8 neuron. *Feed Forward Backpropagation* diawali dengan memberikan pola *input* ke *input layer*. Pola *input* ini adalah nilai aktivasi unit-unit *input*. Dengan melakukan perambatan maju dihitung nilai aktivasi pada unit-unit di lapisan berikutnya. Pada setiap lapisan, tiap unit pengolah melakukan penjumlahan berbobot dan menerapkan fungsi sigmoid untuk menghitung keluarannya. Arsitektur metode FFBNN ditunjukan pada Gambar 5.

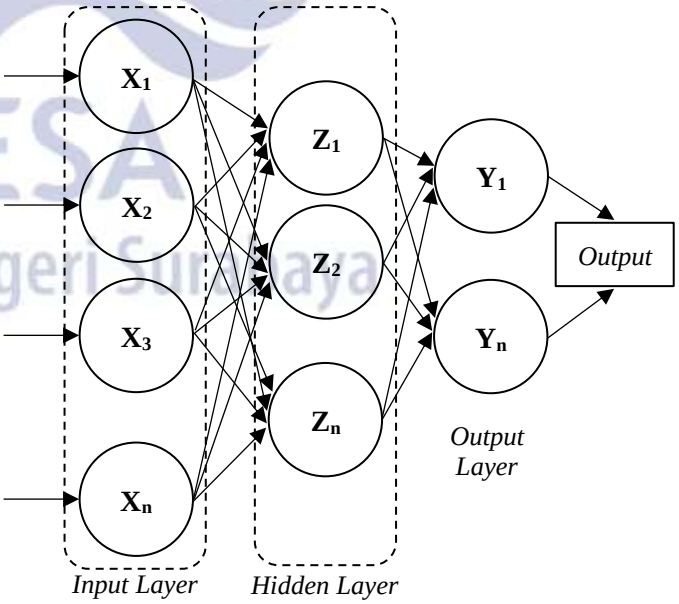

Gambar 5. Arsitektur *Feed Forward Backporpagation Neural Network*

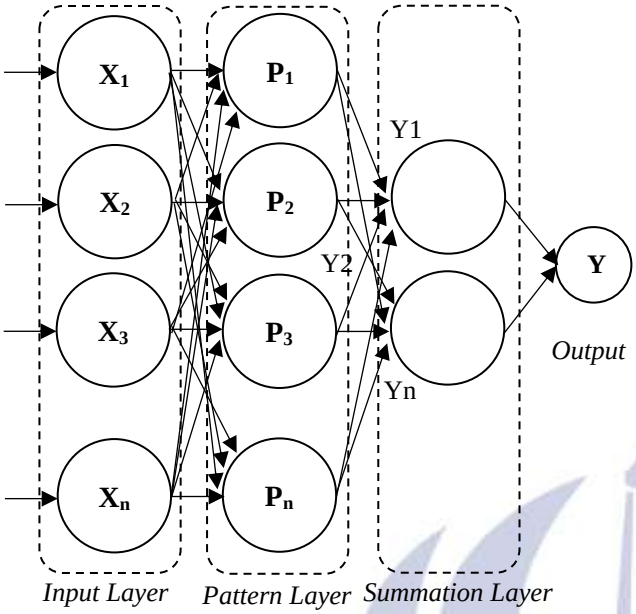

Gambar 6. Arsitektur *Generalized Regression Neural Network*

Gambar 6 adalah arsitektur model yang dikembangkan dari metode *Generalized Regression Neural Network*, di mana metode *Generalized Regression Neural Network* ini juga menggunakan 8 *layer* dan 8 *neuron*. Metode ini menggunakan fungsi perkiraan langsung dari data pelatihan, metode ini untuk memperkirakan fungsi kepadatan probabilitas gabungan fungsi yang hanya diberikan satu set pelatihan. Karena fungsi pelatihan diperoleh dari kumpulan data tanpa bias.

Praprocessing Data

Fungsi aktivasi yang diterapkan pada jaringan adalah fungsi sigmoid biner yang memiliki nilai dengan rentang antara 0-1, sehingga data *input* perlu dilakukan normalisasi dengan persamaan sebagai berikut:

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}}(BA - BB) + BB \quad (21)$$

Ket:

X' = Nilai *input* hasil normalisasi
X = Nilai *input*
X_{min} = Nilai *input* paling rendah
X_{max} = Nilai *input* paling tinggi
BA = Batas atas (1)
BB = Batas bawah (0)

HASIL DAN PEMBAHASAN

Kinerja dari ANN dinyatakan oleh *mean square error* (MSE) yang merupakan ukuran ketepatan ANN dalam mencapai nilai target yang diinginkan. Hasil peramalan dari metode *Feed Forward Backpropagation Neural Network* dengan beberapa fungsi pelatihan dan metode *Generalized Regression Neural Network* ditunjukan pada Tabel 1.

Pada Tabel 1, dapat disimpulkan bahwa hasil kinerja metode peramalan dengan nilai MSE yang paling baik atau mendekati angka 0 adalah kinerja dari metode *Feed Forward Backpropagation Neural Network* dengan fungsi peltihan traincgf dengan nilai MSE sebesar 0.00699, sedangkan hasil dengan nilai yang kurang baik terdapat pada metode *Feed Forward Backpropagation Neural Network* dengan fungsi peltihan traincgp dengan nilai MSE sebesar 0.18481.

Hasil peramalan metode *Feed Forward Backpropagation Neural Network* menggunakan beberapa fungsi pelatihan dan metode *Generalized Regression Neural Network* ditunjukan pada Tabel 2 dan Tabel 3.

Tabel 1. Kinerja Metode FFBNN Dengan Beberapa Fungsi Pelatihan dan Metode GRNN

Metode		**Epoch**	**MSE**
FFBNN	TRAINGD	1000	0.04833
	TRAINGDA	1004	0.07587
	TRAINGDX	1065	0.08117
	TRAINGDM	1001	0.02080
	TRAINCGF	1074	0.00699
	TRAINCGP	519	0.18481
	TRAINCGB	229	0.11110
GRNN			0.09108

Tabel 2. Hasil Peramalan Beban Listrik Tanggal 3 Mei 2007

Waktu	**Beban *Real* (MW)**	**Metode FFBNN**			
		Fungsi Pelatihan			
		GD	**GDA**	**GDX**	**GDM**
00:00	80.4	79.4	73.9	66.4	65.4
01:00	75.7	75.2	74.2	66.7	68.4
02:00	74.5	76.7	74.2	66.6	67.7
03:00	72.5	75.0	74.2	66.7	68.4
04:00	71.5	78.1	74.4	66.9	71.5
05:00	75.7	78.1	74.3	66.6	68.3
06:00	76.9	71.7	74.2	67.0	70.1
07:00	62.9	71.9	74.1	67.3	76.3
08:00	63.7	72.7	74.2	67.3	77.1
09:00	55.6	69.9	73.9	67.5	76.8
10:00	56.7	68.2	73.6	67.5	75.0
11:00	56.3	69.2	73.8	67.5	75.9
12:00	61.8	71.6	73.7	67.6	81.8
13:00	63.6	69.3	73.6	67.6	78.0
14:00	60.2	69.1	73.5	67.6	78.1
15:00	58.9	68.7	73.4	67.6	77.2
16:00	56.2	68.9	73.4	67.6	78.0
17:00	83.8	91.2	72.2	70.1	66.4
18:00	101.4	91.4	62.8	83.0	90.9
19:00	98.7	91.6	62.1	91.5	92.1
20:00	107.1	91.6	62.2	90.1	91.7
21:00	107.7	91.5	62.4	87.9	91.8
22:00	98.3	90.9	65.9	74.9	81.6
23:00	90.5	89.0	71.4	69.6	68.3

Tabel 3. Hasil Peramalan Beban Listrik Tanggal 3 Mei 2007

Waktu	Beban *Real* (MW)	Metode FFBNN			Metode GRNN
		Fungsi Pelatihan			
		CGF	CGP	CGB	
00:00	80.4	82.0	103.2	81.4	54.9
01:00	75.7	76.9	102.5	82.8	50.7
02:00	74.5	77.4	102.7	82.7	49.8
03:00	72.5	76.9	102.4	82.8	48.2
04:00	71.5	71.7	101.7	83.9	46.6
05:00	75.7	75.6	102.5	83.1	50.5
06:00	76.9	75.1	101.1	82.6	51.7
07:00	62.9	63.5	95.1	84.2	38.0
08:00	63.7	62.7	95.7	85.0	38.2
09:00	55.6	56.8	86.0	83.9	29.1
10:00	56.7	57.3	75.9	81.8	32.6
11:00	56.3	56.8	82.6	82.9	31.0
12:00	61.8	59.5	84.2	94.3	28.2
13:00	63.6	59.1	80.0	85.5	37.7
14:00	60.2	59.4	78.7	85.5	33.7
15:00	58.9	59.4	76.7	83.8	33.5
16:00	56.2	59.6	77.7	85.1	28.8
17:00	83.8	84.3	103.2	77.6	59.4
18:00	101.4	103.1	51.6	73.0	70.2
19:00	98.7	103.4	46.6	72.9	69.2
20:00	107.1	103.2	49.8	72.9	72.2
21:00	107.7	103.3	48.3	72.9	72.4
22:00	98.3	100.5	91.0	73.2	68.9
23:00	90.5	92.0	102.4	75.7	64.1

Tabel 4. *Mean Absolute Percentage Error* (MAPE)

Metode		MAD	MAPE
FFBNN	TRAINGD	7.88	11.18
	TRAINGDA	16.11	20.40
	TRAINGDX	10.83	14.09
	TRAINGDM	13.77	11.18
	TRAINCGF	1.93	2.52
	TRAINCGP	28.45	37.68
	TRAINCGB	19.89	27.93
GRNN		27.12	37.17

Pada Tabel 3, dapat dilihat bahwasannya metode FFBNN dengan fungsi traincgf yang nilai hasil peramalannya paling mendekati dengan data beban aktual.

Pada Tabel 4, nilai MAPE terkecil terdapat pada metode *Feed Forward Backpropagation Neural Network* dengan fungsi traincgf sebesar 2,52% di mana hasil peramalan dengan nilai MAPE terkecil adalah hasil yang terbaik.

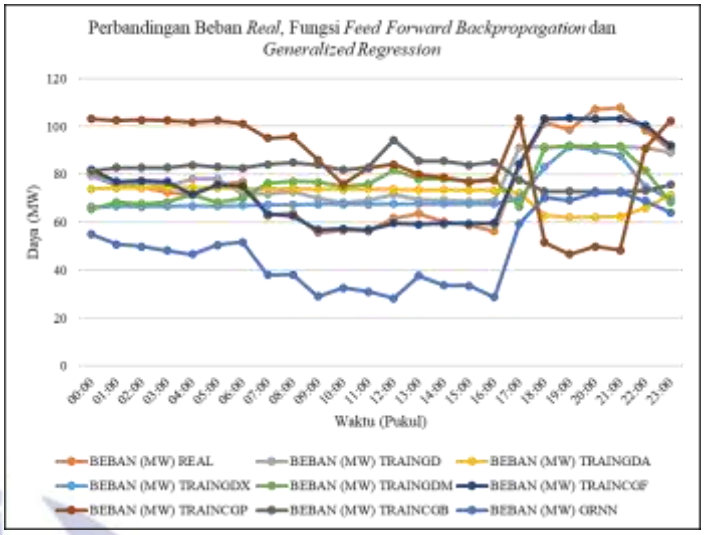

Gambar 7. Grafik Perbandingan Beban *Real*, metode *Feed Forward Backpropagation Neural Network* dengan beberapa fungsi dan metode *Generalized Regression Neural Network*

Perbandingan antara beban real, metode Feed Forward Backpropagation Neural Network menggunakan beberapa fungsi dan metode Generalized Regression Neural Network dapat dilihat pada Gambar 7.

Dari Gambar 7, dapat diketahui bahwa hasil peramalan dengan metode peramalan *Feed Forward Backpropagation Neural Network* dengan fungsi traincgf grafik hasil peramalannya hampir mendekati nilai beban aktual di setiap jamnya.

PENUTUP

Kesimpulan

Pembahasan pada artikel ini adalah peramalan beban listrik jangka pendek (*Short-term Forecasting)* satuan PLN di Kota Pontianak, Kalimantan Barat menggunakan metode *Feed Forward Backpropagation Neural Network* dan metode *Generalized Regression Neural Network* (GRNN), di mana beban peramalan dengan data target uji pada tanggal 3 Mei 2007 dengan hasil peramalan yang mendekati nilai beban *real* terdapat pada metode *Feed Forward Backpropagation Neural Network* adalah pada pukul 05.00 dengan fungsi pelatihan traincgf dengan selisih 0,1 MW atau sebesar 0,08%, sedangkan hasil peramalan beban dengan selisih yang sangat besar terdapat pada metode *Feed Forward Backpropagation Neural Network* adalah pada pukul 21.00 dengan fungsi pelatihan traincgp di mana pada beban *real* sebesar 107,7 MW dan peramalan dengan fungsi pelatihan traincgp sebesar 59,4 MW atau sebesar 55,14%. Nilai MAPE dengan hasil peramalan terbaik terdapat pada metode *Feed Forward Backpropagation Neural Network* dengan fungsi pelatihan traincgf di mana nilai MAPE-nya mendekati nilai beban *real* yaitu sebesar 2,52%.

Saran

Artikel ilmiah ini menggunakan data beban listrik harian beban listrik di Kota Pontianak, data tersebut berdasarkan pada refrensi yang diperoleh dari PT. PLN (Persero) Wilayah Kalimantan Barat (Unit Sektor Kapuas) untuk data beban listrik, sedangkan data temperatur udara Kota Pontianak berdasarkan refrensi 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 lain atau bisa menggunakan fungsi lain pada *Feed Forward Backpropagation Neural Network* yang berbeda 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, Widi. 2020. "*Generalized Regression Neural Network For Long-Term Electricity Load Forecasting*". *Journal of International Conference on Smart Technology and Applications* (ICoSTA). Surabaya: Universitas Negeri Surabaya.

Baliyan, Arjun. 2015. "*A Review of Short Term Load Forecasting using Artificial Neural Network Models*". *Journal of International Conference on Intelligent Computing, Communication & Convergence* (ICCC-2015). India: Interscience Institue of Management and Technology Bhubasewar.

Caraka, Rezzy Eko. 2015. "Permodelan *General Regression Neural Network* (GRNN) Pada Data Return Indeks Harga Saham Euro 50". Semarang: Universitas Diponegoro.

Hamidie, Kafahri Arya. 2009. "Metode Koefisien Energi Untuk Peramalan Beban Jangka Pendek Pada Jaringan Jawa Madura Bali". Depok: Universitas Indonesia.

Hasim, Agus. 2008. "Prakiraan Beban Listrik Kota Pontianak Dengan Jaringan Syaraf Tiruan (*Artificial Neural Network*). Sekolah Pasca Sarjana. Bogor: Institut Pertanian Bogor.

Khasanah, Uswatun. 2019. "Analisis Peramalan Beban Listrik Jangka Pendek Menggunakan Metode *Adaptive Neuro Fuzzy Inference System* (Studi Kasus : PT. PLN (Persero) Area Pengaturan Distribusi Jawa Timur)". Surabaya: UIN Sunan Ampel Surabaya.

Kristiana, Ana. 2015. "Peramalan Beban Puncak Pemakaian Listrik Di Area Semarang Dengan Metode *Hybrid* ARIMA (*Autoregressive Integrated Moving Average*)-ANFIS (*Adaptive Neuro Fuzzy Inference System*) (Studi Kasus di PT. PLN (Persero) Distribusi Jawa Tengah dan DIY)". Semarang: Universitas Diponegoro.

Pratama, Ricky Ardian. 2016. "Permalan Beban Listrik Jangka Panjang Provinsi D.I. Yogyakarta menggunakan *Neural Network Backpropagation*". Sruabaya: Universitas Negeri Surabaya.

Safitri, Tias. 2017. "Perbandingan Peramalan Menggunakan Metode *Exponential Smoothing Holt-Winters* Dan ARIMA. Semarang: Universitas Negeri Semarang.

Setiabudi, Dodi. 2015. "Sistem Informasi Peramalan Beban Listrik Jangka Panjang di Kabupaten Jember Menggunakan JST *Backpropagation*". Jurnal SMARTICS. Vol. 1 (1). Malang: Universitas Kanjuruhan.

Sruthi, Ja dan Catherine, R.L. Helen. 2015. "*A Review on Electrical Load Forecasting in Energy Management*". *International Journal of Innovative Science, Engineering & Technology* (IJISET). Vol. 2. Issues 3. India: Sri Krishna College of Engineering & Technology Coimbatore.

Suhendra, Christian Dwi dan Wardoyo, Retantyo. 2015. "Penentuan Arsitektur Jaringan Syaraf Tiruan *Backpropagation* (Bobot Awal dan Bias Awal) Menggunakan Algoritma Genetika. Yogyakarta: Universitas Gajah Mada

Wihardono, Juniar Doan dkk. 2016. "Peramalan Beban Jangka Pendek Pada Hari Libur Di Bali Menggunakan Metode *Generalized Regression Neural Network* (GRNN)". Bali: Universitas Udayana.