

PREDIKSI PEMBEBANAN PENYULANG TRANSFORMATOR DISTRIBUSI GARDU INDUK PETROKIMIA DENGAN METODE *NONLINEAR AUTOREGRESSIVE NEURAL NETWORK* (NARNN)

Rosmita Dwijayanti

S1 Teknik Elektro, Fakultas Teknik, Universitas Negeri Surabaya
e-mail : rosmiadwiyanti@mhs.unesa.ac.id

Subuh Isnur Haryudo

Teknik Elektro, Fakultas Teknik, Universitas Negeri Surabaya
e-mail : subuhisnur@unesa.ac.id

Abstrak

Pada jaringan sistem distribusi, transformator merupakan komponen yang paling penting dalam penyaluran tenaga listrik dari gardu distribusi ke konsumen. Transformator pada gardu induk 150 kV/20 kV sering mengalami perubahan beban yang diakibatkan oleh perkembangan pemukiman, perkantoran, maupun industri. Agar penyaluran tenaga listrik memiliki keandalan yang tinggi perlu dilakukan prediksi terhadap beban yang akan datang. Penelitian ini bertujuan untuk memprediksi beban rata-rata pada transformator distribusi. Prediksi adalah salah satu solusi untuk dapat memperkirakan pergerakan beban rata-rata. Salah satu metode dalam prediksi adalah dengan menggunakan *Nonlinear Autoregressive (NAR) Neural Network*. Hasil performa optimum akan didapatkan dengan mengganti jumlah *delay* dan *hidden neuron* dan menghitung *Mean Squared Error* (MSE) dan *Regression* (R) pada masing-masing eksperimen. Hasil penelitian menunjukkan beban prediksi pembebanan harian siang dan malam Januari 2018 untuk setiap penyulang pada Gardu Induk Petrokimia. Besar perbedaan *Mean Square Error* (MSE) terbesar perbandingan antara hasil peramalan dengan data aktual terletak pada penyulang Panca Putra pada malam hari sebesar 0.3653 dan terkecil pada penyulang PON 1 malam hari sebesar 0.0350.

Kata Kunci: Transformator Distribusi, Prediksi, Nonlinear Autoregressive, Neural Network, Time Series.

Abstract

In a network of distribution systems, transformers are the most important component in the distribution of electricity from distribution substations to consumers. Transformers at 150 kV/20 kV substations often experience changes in load due to the development of settlements, offices, and industries. In order for distribution of electricity to have high reliability, it is necessary to predict future loads. This research aims to predict the average load on the distribution transformer. Prediction is one solution to be able to predict the average load movement. One method in prediction is to use the Nonlinear Autoregressive (NAR) Neural Network. Optimum performance results will be obtained by changing the number of delay and hidden neurons and calculating the Mean Squared Error (MSE) and Regression (R) in each experiment. This research produces the model under study to predict the right average load to produce a precise prediction. The biggest difference result Mean Square Error (MSE) of prediction in Panca Putra at night is 0.3653 and the smallest in PON 1 at night is 0.0350.

Keywords: Distribution Transformer, Prediction, Nonlinear Autoregressive, Neural Network, Time Series.

PENDAHULUAN

Pada jaringan sistem distribusi, Komponen yang paling diperlukan dari gardu distribusi ke konsumen untuk pembagian tenaga listrik adalah transformator. Transformator pada umumnya banyak dimanfaatkan untuk sistem tenaga listrik maupun rangkaian elektronik. Namun, pemutusan listrik atau kebakaran dapat terjadi bila terjadi gangguan dalam transformator distribusi sehingga mengakibatkan kontinuitas pelayanan konsumen tidak maksimal. Presentasi pembebanan transformator distribusi diusahakan tidak mencapai lebih dari 70% - 80%. Kapasitas beban transformator di Indonesia pada umumnya diklasifikasikan menjadi 25

kVA, 50 kVA, 100 kVA, 160 kVA, 200 kVA, dan 250 kVA (Suhadi, et.al, 2008).

Peramalan beban adalah fungsi dan aktivitas yang penting dalam operasi sistem tenaga dan perencanaan untuk transmisi dan distribusi. Utilitas memerlukan model peramalan beban yang akurat untuk berbagai proses bisnis termasuk perencanaan pembangkit, transmisi, dan distribusi, pengadaan energi, operasi dan pengiriman *real-time* (Kampezidou, 2016).

Metode peramalan dapat diklasifikasikan menjadi dua jenis yaitu: 1) metode statistika, seperti analisis regresi dan analisis *time series* 2) metode kecerdasan buatan seperti *Artificial Neural Network* (ANN), *Fuzzy*

Logic dan lain-lain. Sebuah peramalan dapat dilakukan menggunakan metode analisis regresi, Seperti pada penelitian sebelumnya metode analisis regresi digunakan untuk meramalkan penjualan suatu produk. Pada metode regresi pada umumnya variable yang diramalkan dipengaruhi besarnya variabel bebas. Dalam pengaplikasiannya dibagi menjadi dua yaitu analisa deret waktu dan *causal* model yang memiliki keuntungan dalam keadaan tertentu. Keuntungan dari model deret waktu sering dapat dipergunakan secara mudah dalam peramalan. Sedangkan, *causal* model dapat dipergunakan dalam peramalan dengan ketepatan yang lebih besar dan sering digunakan untuk pengambilan keputusan. Namun, analisis regresi memiliki kelemahan yaitu ketidakakuratan dalam meramal yang diakibatkan jika menggunakan data yang berfluktuasi tinggi. (Zunaidhi, et.al, 2012)

Metode selanjutnya yang dapat digunakan untuk peramalan adalah metode analisis *time series* atau deret waktu. Pada penelitian sebelumnya metode deret waktu digunakan untuk meramalkan beban listrik jangka pendek. Analisis deret waktu diaplikasikan untuk mempelajari perilaku sebelumnya dan menaksir kinerja sebelumnya. Serta menghasilkan peramalan untuk sebuah variabel dari suatu kelompok tertentu Namun metode ini masih memiliki kelemahan yaitu terbatasnya keakuratan dalam menghasilkan peramalan. (Nguyen dan Hansen, 2017).

Artificial Neural Network adalah jaringan syaraf tiruan diinputkan informasi yang sebelumnya telah diketahui hasil keluarannya. Penginputan informasi ini dilakukan lewat *node – node* atau unit – unit input. Ada dua hal yang ingin dicapai dalam melatih jaringan syaraf tiruan. Yang pertama adalah kemampuan memorisasi dimana dapat menggunakan dengan memanggil secara lengkap pola yang telah dipelajari. Lalu, yang kedua adalah kemampuan generalisasi dimana jaringan syaraf tiruan dapat memproduksi respon yang dapat diterima serupa terhadap pola-pola yang telah dipelajari sebelumnya dengan pola-pola input serupa. Sehingga memberi kegunaan untuk jaringan syaraf tiruan jika dimasukkan input informasi yang belum sepenuhnya dipelajari maka jaringan syaraf tiruan ini masih akan tetap dapat memberikan tanggapan yang baik dan memberikan keluaran yang paling mendekati. (Muslimin, 2015).

Tujuan dari penelitian ini adalah merancang dan mengimplementasikan metode *Backpropagation Nonlinear Aggressive* (NAR) *Neural Network* yang akan digunakan untuk mengestimasi pembebanan pada trafo jangka menengah pada Gardu Induk Petrokimia. Estimasi dilakukan untuk menghitung total beban per hari setiap tahun di Gardu Induk Petrokimia.

KAJIAN PUSTAKA

Transformator Distribusi

Transformator distribusi adalah transformator yang menyediakan tegangan terakhir pada sistem tenaga listrik. Transformator digunakan untuk *stepping down* tegangan pada jaringan distribusi ke tingkatan tegangan pada pelanggan. Transformator distribusi biasanya ditempatkan pada *service drop* dimana kabel pada tiang listrik atau jaringan bawah tanah ke tempat pelanggan. Pada beban penyulang merupakan total beban primer pada transformator distribusi. Pada bagian primer, struktur lilitan terbagi menjadi dua tipe koneksi yaitu wye dan delta. Pada rangkaian distribusi wye, transformator dari fase ke netral digunakan. Transformator satu fase wye biasanya hanya mempunyai satu *bushing* di atasnya yang berhubungan dengan salah satu dari tiga fase primer. Di sisi lainnya dari lilitan primer berhubungan dengan kotak transformator dimana berhubungan dengan kabel netral yang juga ditanahkan. Pada rangkaian distribusi delta, transformator dari fase ke fase digunakan. Transformator satu fase mempunyai dua *bushing* di atasnya dimana berhubungan dengan dua dari tiga kabel primer sehingga tegangan yang melewati lilitan primer adalah tegangan fase-ke-fase. (Amry, 2016)

Deret Waktu (*Time Series*)

Deret waktu (*time series*) dalam statistik adalah serangkaian nilai data yang didapatkan dalam kurun waktu tertentu. Sebagian besar deret waktu adalah urutan data yang diambil berturut-turut sama dengan jarak data pada waktu itu. Secara matematis, deret waktu didefinisikan oleh nilai-nilai Y_1, Y_2 , dari suatu variabel Y untuk titik-titik waktu t_1, t_2 . Dengan demikian, Y merupakan sebuah fungsi dari t dan disimbolkan dengan $Y = F(t)$. (Murray, 2007)

Suatu urutan titik-titik data yang berturut-turut diukur yang mempunyai jarak antar dua titik data yang sama untuk suatu interval waktu yang kontinu dan pada interval waktu yang hanya mempunyai satu titik data dalam setiap satuan waktu. Analisa deret waktu terdiri dari metode-metode yang digunakan untuk menganalisis data deret waktu untuk memperoleh nilai statistik dan nilai karakteristik lain yang bermakna. Sementara analisis regresi sering digunakan dengan cara seperti untuk menguji teori bahwa nilai-nilai saat ini dari satu atau lebih deret waktu independen mempengaruhi nilai saat ini dari seri waktu lain, jenis analisis *time series* ini tidak disebut "analisis deret waktu", yang berfokus pada membandingkan nilai-nilai dari serangkaian waktu satu atau beberapa tergantung seri waktu di berbagai titik dalam waktu Peramalan data deret waktu adalah penggunaan model untuk memprediksi nilai masa depan

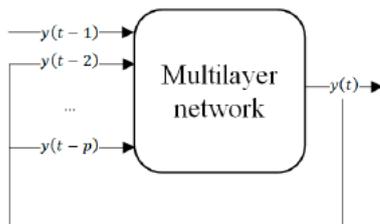
berdasarkan nilai-nilai yang diamati sebelumnya. (Rofiq, 2017)

Non-Linear Autoregressive Neural Network (NARNN)

Dalam sebagian besar kasus, aplikasi deret waktu dicirikan oleh variasi yang tinggi dan periode sementara yang singkat. Fakta ini menyulitkan untuk memodelkan deret waktu menggunakan model linier, oleh karena itu pendekatan nonlinear harus disarankan. Sebuah jaringan saraf autoregresif nonlinear diterapkan pada peramalan seri waktu, menggambarkan model autoregresif diskret, non-linear, yang dapat ditulis sebagai persamaan berikut.

$$y(t) = h(y(t-1), y(t-2), \dots, y(t-p)) + \epsilon(t) \quad (1)$$

Rumus ini menjelaskan bagaimana jaringan NAR digunakan untuk memprediksi nilai dari seri data y pada saat waktu t , $y(t)$ menggunakan nilai-nilai p dari deret data sebelumnya. Fungsi $h(\cdot)$ tidak diketahui sebelumnya dan pelatihan dari jaringan syaraf bertujuan untuk mendekati fungsi dengan cara bobot dan bias neuron. Maka istilah $\epsilon(t)$ merupakan pendekatan kesalahan dari seri y pada waktu t . Topologi jaringan NAR ditunjukkan pada gambar 1 berikut (Ruiz, 2016).



Gambar 1. Topologi Jaringan NAR

Fitur p pada $y(t-1)$, $y(t-2)$, ..., $y(t-p)$ disebut *feedback delay*. Jumlah lapisan dan neuron tersembunyi per lapisan benar-benar fleksibel dan dioptimalkan melalui prosedur *trial-and-error* untuk mendapatkan topologi jaringan itu dapat memberikan kinerja terbaik. Namun demikian, penting untuk diingat bahwa meningkatkan jumlah neuron membuat sistem lebih kompleks, sementara jumlah neuron yang rendah dapat digeneralisasi dan kekuatan komputasi jaringan. Aturan pembelajaran yang paling umum untuk jaringan NAR adalah *Levenberg-Marquardt* prosedur *Backpropagation* (LMBP). Fungsi pelatihan ini sering kali paling cepat algoritma tipe *Backpropagation*. Algoritma LMBP dirancang untuk mendekati orde kedua derivatif tanpa perlu menghitung matriks Hessian, oleh karena itu dapat meningkatkan kecepatan *training*. Ketika fungsi kinerja memiliki bentuk jumlah kuadrat pada bagian jaringan feedforward pelatihan, maka matriks Hessian dapat didekati seperti yang ditunjukkan dalam Persamaan (2) dan gradient dapat dihitung seperti yang dijelaskan dalam Persamaan (3)

$$H = J^T J \quad (2)$$

$$g = J^T e \quad (3)$$

Dalam Persamaan (2) dan (3), J adalah matriks Jacobian yang berisi turunan pertama dari jaringan kesalahan sehubungan dengan bobot dan bias, dan e adalah vektor kesalahan jaringan di semua pelatihan sampel. Untuk memperkirakan matriks Jacobian, pada penelitian (Ruiz, 2016) menggunakan algoritma *backpropagation* standar untuk mendekati matriks Hessian. Pendekatan ini lebih sederhana daripada menghitung matriks Hessian (H). Algoritma LMBP menggunakan pendekatan ini dalam pembaruan seperti

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (4)$$

Metode ini menggunakan matriks Jacobian untuk perhitungan, dengan asumsi bahwa kinerja rata-rata dari jumlah kesalahan kuadrat. Oleh karena itu, jaringan harus menggunakan keduanya mean square error (MSE) atau jumlah kesalahan kuadrat (SSE), dinyatakan dalam Persamaan (5) dan (6), di mana y_i singkatan dari sampel data ke- i , \hat{y}_i adalah data yang diperkirakan diperoleh oleh jaringan untuk nilai y_i , dan n jumlah sampel data untuk pelatihan jaringan.

$$SSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5)$$

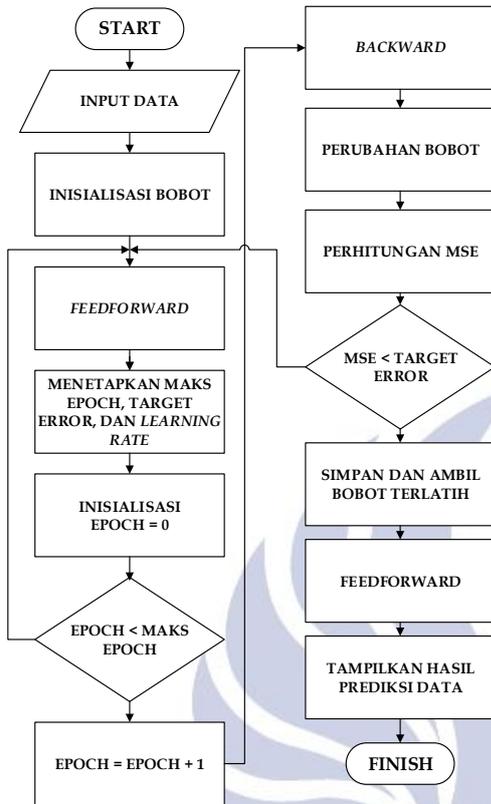
$$MSE = \frac{SSE}{n} \quad (6)$$

METODE PENELITIAN

Rancangan Penelitian

Diagram alur rancangan penelitian ini terdapat pada Gambar 2. Penelitian akan dilakukan dengan studi literatur, dengan menggunakan teori-teori yang telah didapatkan penelitian akan dilanjutkan ke pengambilan data dimana pengambilan data diambil dari data pembebanan dari Area Pengatur Distribusi (APD) PT. PLN Persero Jawa Timur. Setelah itu dilanjutkan dengan analisis data awal yaitu data yang diambil adalah data beban rata-rata yang dibagi menjadi 2 yaitu beban rata-rata pada siang hari pada pukul 10.00 dan malam hari pada pukul 19.00. Jika terdapat nilai kosong atau (NaN) maka dilakukan perhitungan *average* terhadap data sebelum dan sesudahnya. Data harian rata-rata menggunakan satuan ampere yang kemudian dirubah menjadi satuan MW. Beban yang digunakan adalah beban pada penyulang dimana beban tersebut merupakan total beban primer dari transformator distribusi pada penyulang tersebut. Sistem listrik di Jawa Timur menetapkan nilai RST pada penyulang rata sehingga nilai satu fasa dapat merepresentasikan nilai dari tiga fasa, Dilanjutkan memodelkan *Neural Network* menggunakan jenis *Nonlinear Autoregressive* (NAR). Kemudian

melakukan *training* dan melakukan prediksi Januari 2018 untuk setiap penyulang di Gardu Induk Petrokimia.



Gambar 2. Diagram rancangan penelitian.

Konfigurasi Model Neural Network

Tabel 1. arsitektur ANN yang digunakan dalam penelitian peramalan beban harian transformator distribusi 20 kV:

Tabel 1. Arsitektur ANN

Input Nodes	31 node
Hidden Layers	1 layer
Hidden Nodes	31 node
Output Nodes	1 node
Fungsi Aktivasi	Fungsi Tan Sigmoid $f(x) = \frac{2}{(1 + e^{-x})} - 1$
Learning Algorithm	Lavenberg-Marquardt Backpropagation (trainlm)

Algoritma *Backpropagation* merupakan algoritma pembelajaran yang terawasi dan memiliki tiga layer, yaitu input layer, hidden layer dengan fungsi aktivasi sigmoid bipolar (tansig). Fungsi sigmoid bipolar hampir sama dengan fungsi sigmoid biner, hanya saja output dari fungsi ini memiliki range antara 1 sampai -1

Fungsi aktivasi sigmoid bipolar dirumuskan menurut Sri Kusumadewi, 2004 adalah sebagai berikut:

$$y = f(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \tag{7}$$

atau

$$f(x) = \frac{2}{(1 + e^{-x})} - 1 \tag{8}$$

dengan: $f'(x) = \frac{\sigma}{2} [1 + f(x)][1 - f(x)]$ (9)

Sebelum dilakukan *training* data input dan output, perlu dilakukan normalisasi/*preprocessing* data input ataupun target untuk dilakukan penskalaan sedemikian hingga data-data dan target tersebut masuk dalam suatu range tertentu. Metode normalisasi yang digunakan adalah *min-max normalization*. *Min-max normalization* yaitu metode yang *re-scale* data dari suatu *range* ke *range* baru lain. Data diskalakan dalam *range* 0 dan 1. *X* adalah nilai data asli, *X_{min}* adalah nilai terkecil pada data asli dan *X_{max}* adalah nilai terbesar pada data asli. Maka nilai normalisasinya menurut (Sthitapragyan Mohanty, 2015):

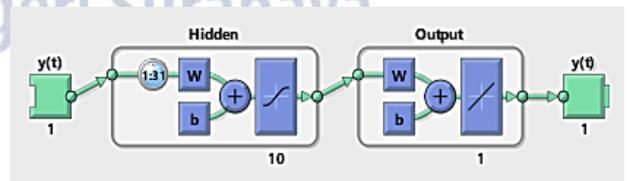
$$X_{normalisasi} = (X - X_{min}) / (X_{max} - X_{min}) \tag{10}$$

Untuk mengetahui errornya dapat menggunakan rumus *Mean Squared Error* (MSE) menurut (Ardian, Ricky. 2016) dimana cara untuk mengukur kesalahan peramalan keseluruhan, MSE merupakan rata-rata selisih kuadrat antara nilai yang diramalkan dan diamati seperti yang ditunjukkan pada fungsi berikut.

$$MSE = \sum \frac{[Kesalahan Peramalan]^2}{n} \tag{11}$$

Semakin kecil error yang didapatkan, maka akan semakin bagus, yang artinya data hasil prediksi mendekati data aktualnya. Dengan membagi antara nilai kesalahan peramalan dan jumlah sampel nilai data (n).

Dalam perancangan model, perlu dipersiapkan data untuk *training* dan *testing* model. Jumlah data keseluruhan sebanyak 2557 data. Data yang digunakan untuk *training* sebesar 70% dari keseluruhan data atau sebanyak 1789 *entri* data, data yang digunakan untuk *testing* sebesar 15% dari keseluruhan data atau sebanyak 384 data, dan data yang digunakan untuk *validation* sebesar 15% dari keseluruhan data atau sebanyak 384 data. Berikut ini adalah gambar 3 yang merupakan arsitektur *Nonlinear Autoregressive* (NAR) Neural Network.



Gambar 3. Arsitektur NAR Neural Network

Dalam penulisan ini, penulis menggunakan NAR *Neural Network* mengestimasi deret waktu penggunaan konsumen beban rata – rata dari gardu induk transformator distribusi 20 kV Gardu Induk Petrokimia dengan *network structure* yang berdasarkan satu input (respon untuk pemakaian beban rata-rata pada waktu *t – 1*, *y(t-1)*), dan satu output (hasil dari deret waktu, *y(t)*) akan terprediksi. Pada penelitian ini menggunakan *delay*

31 akan memprediksi hari ke-32 dari input data hari ke-1 hingga hari-31 dan seterusnya dengan *training* beban harian Januari 2011 sampai dengan Desember 2017 pada siang hari dan malam hari. Kemudian dilakukan *testing* beban harian Januari 2018 pada siang dan malam setiap penyulang di Gardu Induk Petrokimia.

HASIL DAN PEMBAHASAN

Untuk meramalkan beban listrik pada satu hari tertentu maka diperlukan data historis beban listrik 31 hari sebelumnya. Selain itu dilakukan interpolasi untuk menyesuaikan frekuensi beberapa data dengan frekuensi per hari sehingga dapat sesuai dengan model peramalan *time-series* yang akan dikembangkan.

Peramalan dilakukan terhadap arsitektur *Nonlinier Autoregressive* (NAR) *Neural Network* terbaik pada hasil eksperimen. Tujuan penelitian ini adalah mengestimasi beban rata-rata harian setiap penyulang transformator pada Gardu Induk Petrokimia siang dan malam Januari 2018. Nilai MSE didapatkan dari hasil perbandingan antara hasil peramalan dengan data aktual. Semakin kecil nilai MSE maka semakin baik kinerja prediksi.

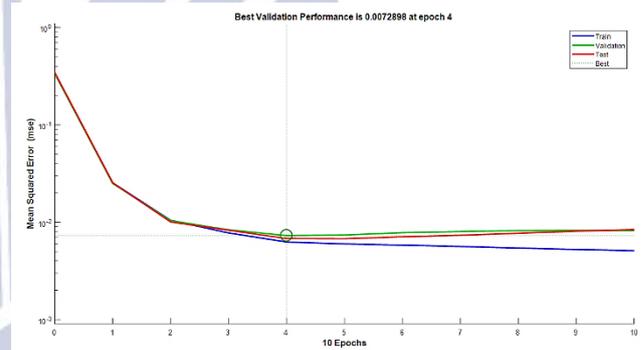
Tabel 2 merupakan perbandingan peramalan pembebanan transformator distribusi untuk setiap penyulang pada Gardu Induk Petrokimia Januari 2018 siang dan malam hari

Tabel 2. Perbandingan Peramalan Beban Harian Setiap Penyulang pada Gardu Induk Petrokimia

Periode	Penyulang	Waktu	Mean Squared Error (MSE)
Januari 2018	Gubernur Suryo	Siang (10.00)	0.0851
		Malam (19.00)	0.0524
Januari 2018	Panca Putra	Siang (10.00)	0.1284
		Malam (19.00)	0.3653
Januari 2018	Industri	Siang (10.00)	0.0485
		Malam (19.00)	0.0809
Januari 2018	PON 1	Siang (10.00)	0.0460
		Malam (19.00)	0.0350
Januari 2018	Esterindo	Siang (10.00)	0.0679
		Malam (19.00)	0.0661

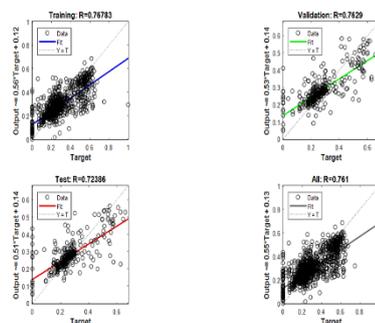
Periode	Penyulang	Waktu	Mean Squared Error (MSE)
Januari 2018	Kebomas	Siang (10.00)	0.0607
		Malam (19.00)	0.0849
Januari 2018	KIG	Siang (10.00)	0.0975
		Malam (19.00)	0.1231

Berdasarkan tabel 2 besar perbedaan MSE terbesar perbandingan antara hasil peramalan dengan data aktual terletak pada penyulang Panca Putra pada malam hari sebesar 0.3653 dan terkecil pada penyulang PON 1 malam hari sebesar 0.0350. Kinerja dan keakurasian dari ANN dapat diketahui berdasarkan MSE. Berikut ini adalah gambar 4. Dimana MSE digunakan sebagai acuan performa training apakah baik (sesuai target) atau tidak (tidak mencapai target).



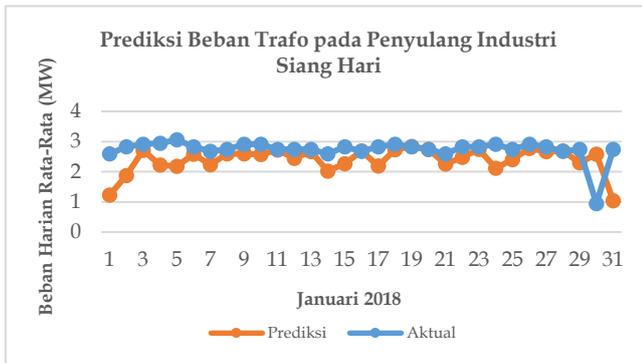
Gambar 4. Plot Performa Trafo Industri Siang

Gambar 4. merupakan hasil kinerja pada proses *training* dan menghasilkan MSE sebesar 0.0072898 dan didapatkan pada *epoch* ke-4 menunjukkan tampilan grafik performa proses *training* pada program NN peramalan beban harian rata-rata siang pada penyulang industri. Gambar 5. menunjukkan nilai regresi pada keluaran ANN pada *training*, *validation*, dan *testing* sebesar 0.76783, 0.7629, dan 0.72386.



Gambar 5. Plot Regresi Training Trafo Industri Siang

Setelah dilakukannya *training* dengan *delay* 31 dan *hidden neuron* 10 terhadap data beban harian siang penyulang Industri Januari 2011- Desember 2017 siang maka dilakukan *testing* menggunakan *weight* dan *bias* yang telah disimpan untuk memprediksi beban harian siang Januari 2018 dengan mengambil 31 hari Desember 2017. Berikut gambar 6. yang merupakan plot perbandingan data aktual dan prediksi Januari 2018.



Gambar 6. Prediksi Beban Trafo Industri Januari 2018 Siang Hari

Berdasarkan gambar 6 dapat diketahui bahwa perbandingan antara hasil prediksi dan data aktual masih memiliki perbedaan. Namun dengan prediksi menggunakan NN didapatkan akurasi peramalan dengan *Mean Squared Error* (MSE) sebesar 0.0485.

PENUTUP

Simpulan

Berdasarkan tabel 2, metode *Nonlinear Autoregressive Neural Network* (NARNN) menghasilkan prediksi beban rata-rata harian siang dan malam hari dengan nilai *Mean Squared Error* (MSE) dari perbandingan hasil peramalan dan nilai aktual untuk prediksi beban harian siang dan malam hari Januari 2018 pada penyulang transformator Gubernur Suryo sebesar 0.0851 dan 0.0524, pada penyulang transformator Panca Putra sebesar 0.1284 dan 0.3653, pada penyulang transformator Industri sebesar 0.0485 dan 0.0809, pada penyulang transformator PON sebesar 0.0460 dan 0.0350, pada penyulang transformator Esterindo sebesar 0.0679 dan 0.0661, pada penyulang transformator Kebomas 0.0607 dan 0.0849, serta pada penyulang transformator KIG sebesar 0.0975 dan 0.1231.

Saran

Peneliti selanjutnya dapat melakukan prediksi untuk bulan – bulan selanjutnya pada setiap penyulang gardu induk Petrokimia siang dan malam dengan menambahkan variabel input seperti jumlah penduduk, data iklim, ekonomi penduduk, dan *derating*

transformator untuk menambah akurasi hasil prediksi dengan meminimalkan nilai *Mean Squared Error* (MSE).

DAFTAR PUSTAKA

- Amry, M Rizqi Choirul. 2016. “Prediksi Suhu Minyak Transformator Distribusi (20 kV/220 V) dengan Metode Radial Basis Function Neural Network (RBFNN)”. *Jurnal Teknik Pomits* Vol.1 (1) : hal. 1-5
- Kampepidou, I Styliani. 2016. “Distribution Transformers Short-Term Load Forecasting Models”. *Power and Energy Society General Meeting (PESGM)*.
- Kusumadewi, Sri. 2004. Jaringan Syaraf Tiruan Menggunakan MATLAB dan Excel Link. Yogyakarta : Graha Ilmu
- Mohanty, Sthitapragyan dan Patra, Prashanta Kumar. 2015. “Prediction of Global Solar Radiation using Nonlinear Auto Regressive with Exogenous Inputs (NARX)”. *National Systems Conference (NSC)*.
- Muslimin. 2015. “Peramalan Beban Listrik Jangka Menengah Pada Sistem Kelistrikan Kota Samarinda”, *Jurnal Ilmiah Teknik Industri*. Vol. 14 (2) : hal. 113-121.
- Nguyen, Hung dan Hansen, K. Christian. 2017. “Short-term Electricity Load Forecasting with Time Series Analysis”, *International Conference on Prognostics and Health Management (ICPHM)*
- Rofiq, Muh Aunu. 2017. “Peramalan Komoditas Strategis Pertanian Cabai Menggunakan Metode Backpropagation Neural Network”. Tugas Akhir Institut Teknologi Sepuluh Januari : tidak diterbitkan
- Ruiz, Luis Gonzaga Baca et, al.2016.”An Application of Nonlinear Autoregressive Neural Network to Predict Energy Consumption in Public Buildings”. *Energies*.
- Spiegle.R Murray dan Stephens J. Larry. 2007. *Schaum Outlines Statistik*. Terjemahan oleh Wiwit Kastawan dan Irzam Harmein. Jakarta: Erlangga.
- Winarso. 2014. ”Estimasi Umur Pakai dan Rugi Daya Transformator”, *Techno*, ISSN 1410-8607. Vol. 15 (2) : hal. 50-55.
- Suhadi dan Wrahatnolo, Tri. 2008. *Teknik Distribusi Tenaga Listrik Jilid 1*. Jakarta: Direktorat Pembinaan Sekolah Menengah Kejuruan.
- Zunaidhi, Rival, Saputra, Wahyu S. J, dan Sari, Ni Ketut. 2012. “Aplikasi Peramalan Penjualan Menggunakan Metode Regresi Linier”, *SCAN*, ISSN 1978-0087. Vol. 7 (3)