

PEMODELAN JARINGAN SARAF TIRUAN UNTUK PREDIKSI KONSUMSI LISTRIK MESIN UJI PADA LABORATORIUM OTOMOTIF

MODELING ARTIFICIAL NEURAL NETWORK FOR ELECTRICAL CONSUMPTION PREDICTION TEST MACHINE IN AUTOMOTIVE LABORATORY

Teguh Iryanto*, Mas'ud Adhi Saputra
Balai Besar Bahan dan Barang Teknik
Jl. Sangkuriang No. 14, Bandung

Diterima: 8 Juli 2019

Direvisi: 30 Juli 2019

Disetujui: 7 Agustus 2019

ABSTRAK

Energi listrik menjadi kebutuhan utama manusia saat ini. Konsumsi terbesar adalah penggunaan energi listrik pada bangunan baik pabrik, gedung, maupun hunian tinggal. Manajemen energi diperlukan untuk efisiensi penggunaan energi listrik. Prediksi penggunaan energi listrik bertujuan untuk mengetahui berapa beban di masa yang akan datang sehingga membantu penyedia energi listrik untuk mempersiapkan sumber energi listrik yang memadai. Jaringan saraf tiruan (JST) digunakan dengan algoritma pelatihan *backpropagation* untuk membuat pemodelan sistem cerdas yang mampu memprediksi penggunaan listrik pada saat pengujian dalam jangka waktu satu jam. Pengambilan data penelitian dibatasi pada penggunaan listrik laboratorium otomotif Balai Besar Bahan dan Barang Teknik, Kota Bandung, Propinsi Jawa Barat. Arsitektur JST menggunakan 6 neuron pada *layer* input, 3 *layer* tersembunyi dengan neuron 12 dan 1 *layer* output. Fungsi aktivasi *logsig* dan *purelin* digunakan untuk membangun pemodelan JST. Hasil pemodelan menunjukkan bahwa prediksi menggunakan JST menghasilkan nilai *mean square error* (MSE) 0,00043.

Kata Kunci: *backpropagation*, energi, jaringan saraf tiruan, prediksi

ABSTRACT

Electric energy is becoming a major human need today. The biggest consumption is the use of electric energy in factories, buildings, and residential dwellings. Energy management is needed for efficient use of electric energy. Electric energy prediction aims to find out how much load in the future so as to help providers of electric energy to prepare adequate sources. Artificial neural network (ANN) was used with a backpropagation learning algorithm to make intelligent system modeling to predict electricity usage during testing hourly. Retrieval of research data was limited to the use of automotive laboratories in Center for Material and Technical Product, Bandung City, West Java Province. ANN architecture used 6 neuron at input layer, 3 hidden layer with 12 neuron and 1 output layer. The logsig and purelin activation function was used to construct ANN modeling. The results of modeling showed that predictions using ANN got a mean square error (MSE) of 0,00043.

Keywords: *backpropagation, energy, artificial neural network, prediction*

PENDAHULUAN

Energi merupakan kebutuhan utama manusia pada era digital saat ini. Bangunan tempat manusia beraktivitas memerlukan konsumsi energi yang besar. Apalagi jika di bangunan tersebut terdapat mesin-mesin yang membutuhkan daya listrik besar. Penggunaan energi listrik harus diatur dengan baik. Penggunaan energi listrik dimasa yang akan datang dapat diprediksi menggunakan metode

ilmiah. Prediksi tersebut dilakukan berdasarkan data dan fakta yang diperoleh pada masa sebelumnya. Prediksi penggunaan energi listrik dapat membantu manajemen energi sehingga akan mengurangi emisi yang dihasilkan oleh pembangkit listrik maupun emisi CO₂ dari gedung yang beroperasi secara berlebihan. Manajemen Energi yang baik juga dapat meningkatkan penghematan energi. Gedung dimasa depan akan mempunyai sebuah sistem manajemen energi cerdas. Sistem ini mampu

*Corresponding author:

Email: teguh-iryanto@kemenperin.go.id

DOI: <http://dx.doi.org/10.37209/jtbbt.v9i2.105>

memberikan data konsumsi energi gedung pada masa sekarang, masa lampau dan prediksi pada masa yang akan datang. Sistem manajemen energi cerdas juga mampu memberikan rekomendasi penghematan energi.

Prediksi penggunaan energi listrik juga dapat digunakan sebagai persiapan bagian keuangan untuk melakukan pembayaran tagihan listrik. Dengan mengetahui perkiraan daya terpakai, maka biaya dapat pula diprediksi.

Data pemakaian energi listrik diambil pada laboratorium otomotif Balai Besar Bahan dan Barang Teknik. Data pemakaian selama ini belum terekam secara digital. Padahal pada laboratorium ini terdapat satu mesin uji *drum test* mobil yang konsumsi energinya terbesar dengan *rating breaker* 160A. Penggunaan harus terpantau agar lebih efisien sesuai dengan pekerjaan yang ditugaskan.

Metode jaringan saraf tiruan (JST) digunakan sebagai metode prediksi berdasarkan pada data-data yang diperoleh dari sistem monitoring energi. Metode kecerdasan buatan merupakan pengolahan lanjut setelah sistem monitoring energi. Data monitoring energi ini akan terekam secara kontinyu. Penggunaan JST karena mempunyai arsitektur yang lebih detail dalam perhitungan jika dibandingkan dengan perhitungan data secara konvensional [1]. Perangkat lunak Matlab digunakan untuk melakukan prediksi konsumsi energi listrik menggunakan JST metode *backpropagation*.

Penelitian ini ditujukan untuk mengetahui arsitektur JST yang paling efektif dalam memprediksi konsumsi listrik dalam jangka waktu per-jam.

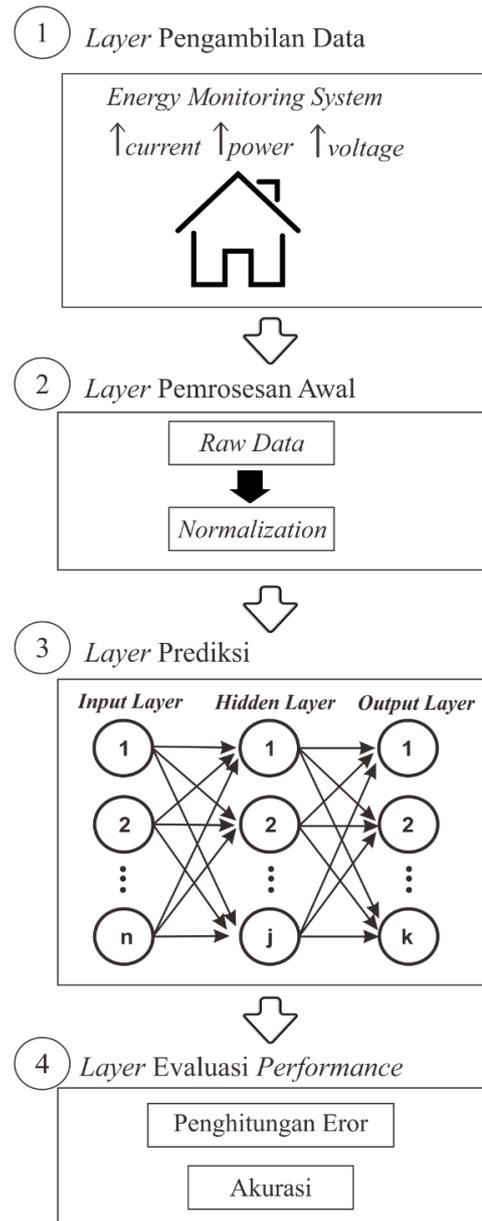
BAHAN DAN METODE

Pada penelitian sistem monitoring energi ini dilakukan langkah-langkah pengambilan data sampai dengan pemodelan sistem seperti yang ditunjukkan pada Gambar 1. Langkah-langkah penelitian sebagai berikut.

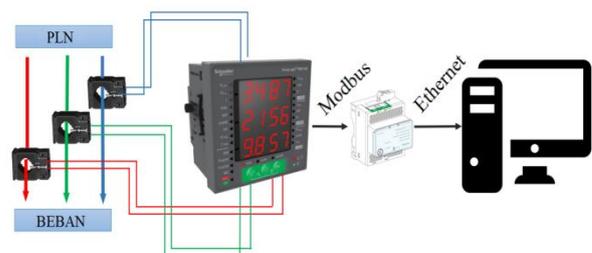
1. Layer Pengambilan Data

Pada *layer* ini dilakukan pemasangan sensor arus dan tegangan pada *breaker incoming* PLN yang merupakan penyuplai energi listrik ke laboratorium otomotif. Tegangan menggunakan 3-phase 380VAC dengan *rating breaker* 250A. Aliran listrik yang melalui *breaker* ini merupakan penyedia energi listrik bagi kebutuhan laboratorium otomotif Balai Besar Bahan dan

Barang Teknik, Bandung. Bagan pengambilan data dapat dilihat pada Gambar 2.



Gambar 1. Metode Penelitian



Gambar 2. Bagan Konfigurasi Peralatan Pengambilan Data

Pengambilan data tegangan dan arus menggunakan sensor *current transformer* dengan rating 300A. Data tegangan dan arus dibaca oleh power meter. Selanjutnya power meter akan terhubung dengan *ethernet gateway* untuk mengkonversi sistem komunikasi ke jaringan *ethernet* sehingga bisa dibaca oleh komputer. Komputer server akan membaca data tegangan dan arus melalui *ethernet gateway*. Pengambilan data dimulai pada bulan April 2019.

2. Layer Pemrosesan Awal

Data tegangan dan arus ditampilkan dalam bentuk web *dashboard*. Data ini kemudian digunakan untuk mengetahui beban listrik setiap 5 menit. Data yang terekam akan dibagi menjadi dua bagian yaitu data input (x) dan data target (y) JST. Cuplikan data tiga puluh menit pertama digunakan sebagai *data input*, sedangkan cuplikan data kelipatan enam puluh menit digunakan sebagai data target. Data-data ini juga dapat disimpan dalam bentuk *Excel* sehingga dapat diolah dan dievaluasi lebih lanjut. Data akan diamati kesesuaiannya. Jika *missing value* ditemukan maka digunakan metode yang diperbolehkan untuk menggantikannya. Data akan diabaikan jika *missing value* dalam jumlah besar, sedangkan jika ada *missing value* pada salah satu cuplikan data maka akan digunakan nilai rata-rata pada nilai yang berdekatan.

Data *input* JST akan dinormalisasi agar penghitungan bobot dan error menjadi mudah. Normalisasi data akan dikonversi pada nilai antara 0 dan 1 dengan rumus sebagai berikut [2],

$$Z_i = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (1)$$

Keterangan :

- i : banyaknya dataset ($i=1,2,3, \dots, n$)
- Z_i : merupakan data hasil normalisasi,
- X_i : data aktual,
- X_{min} : nilai terkecil pada dataset,
- X_{max} : nilai terbesar pada dataset.

Data hasil normalisasi dibagi menjadi dua yaitu data latih dan data uji. Data bulan Mei digunakan sebagai data latih sedangkan bulan selanjutnya digunakan sebagai data uji.

3. Layer Prediksi

Algoritma *backpropagation* yang digunakan merupakan algoritma yang mengubah bobot-bobot yang terhubung dengan neuron pada lapisan tersembunyi. *Error* output digunakan untuk mengubah nilai bobot dalam arah mundur (*backward*). Untuk mendapatkan error ini, tahap perambatan maju (*forward propagation*) akan dikerjakan terlebih dahulu dengan mengaktifkan fungsi aktivasi pada *neuron layer* tersembunyi [3].

Pada tahap ini jaringan akan dilatih menggunakan metode pelatihan algoritma *backpropagation*. Algoritma ini terdiri dari 3 *layer/lapisan* utama : *layer* input, berfungsi untuk masuknya data; *layer* tersembunyi berfungsi sebagai tempat memproses data; dan *layer* output yang merupakan hasil akhir dari pengolahan data [4].

Pelatihan menggunakan algoritma Powell Beale *conjugate gradient backpropagation* (*traincgb*) dan *gradient descent momentum and adaptive learning rate backpropagation* (*traingdx*). Kedua metode ini paling sering dan cocok digunakan dalam hal memprediksi menggunakan metode JST [1]. Pelatihan JST menggunakan metode supervisi. Pada pelatihan ini dataset akan memandu dan mengajari JST agar menghasilkan keluaran yang sesuai dengan data target [5]. Variasi jumlah *layer* tersembunyi dan jumlah neuron akan diuji coba untuk menghasilkan hasil prediksi terbaik. Hasil dari pelatihan kedua algoritma ini akan dibandingkan untuk mencari akurasi prediksi paling tinggi.

Pengolahan dan pemodelan JST menggunakan Matlab R2016a yang dijalankan pada spesifikasi komputer Intel Core i5-7300HQ 2.5 GHz, memori RAM 8192 MB, dan hardisk 1 TB dengan kecepatan 5400 rpm.

4. Layer Evaluasi Performance

Pengujian akurasi JST dilakukan dengan penentuan *mean square error* (MSE). Penghitungan rumus MSE yaitu:

$$MSE = \frac{\sum E^2}{n} \quad (2)$$

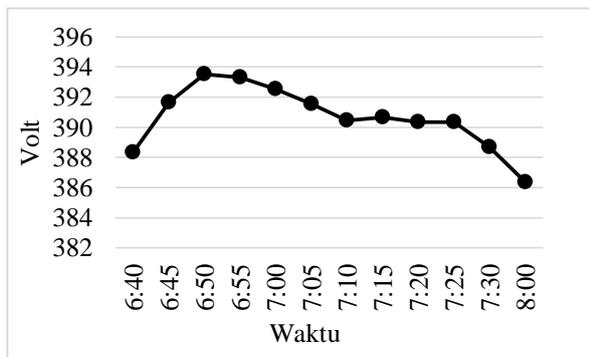
Keterangan :

- $\sum E^2$: selisih antara nilai target dengan nilai keluaran prediksi (dikuadratkan)
- n : banyaknya data.

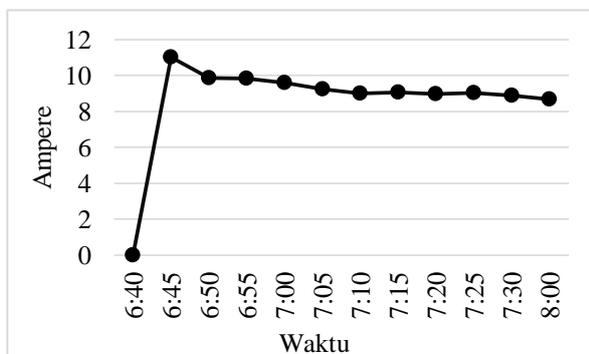
Nilai target akan dibandingkan dengan nilai prediksi untuk menentukan ketepatan prediksi. Penghitungan MSE dan akurasi dihitung untuk menentukan kinerja JST dan penentuan variabel pelatihan agar JST mampu mencapai target dengan baik [6]. Pengujian JST akan menggunakan data bulan Juni 2019. Hasil output prediksi dalam rentang 0 dan 1 akan dikonversi kembali menjadi nilai daya dalam satuan *watt*. Hasil output prediksi akan dibandingkan dengan nilai sebenarnya/target.

HASIL DAN PEMBAHASAN

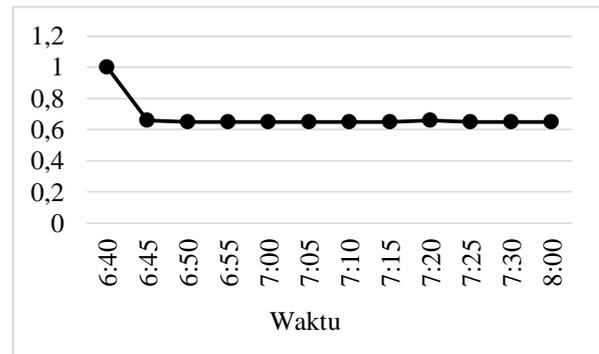
Pada tahap pengambilan data diperoleh data seperti pada Gambar 3, 4, 5 dan 6. Cuplikan setiap 5 menit sekali untuk setiap aktivitas pengujian mesin uji sehingga ketika tidak ada aktivitas pengujian daya listrik akan dianggap sebagai 0. Pengambilan data dilakukan sesuai dengan jam kerja pegawai dari jam 7:30 sampai dengan jam 16:00 pada hari Senin sampai Jumat. Dataset target ditentukan per-jam yaitu untuk jam 8, 9, 10, 11 dan seterusnya.



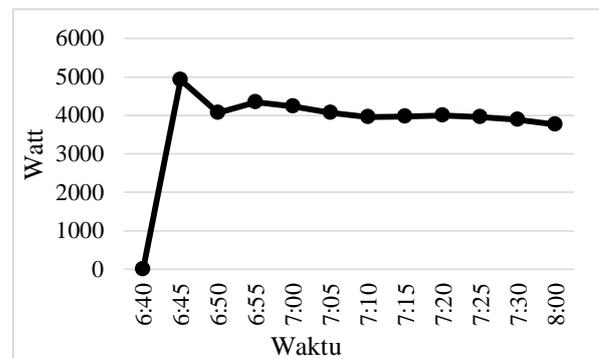
Gambar 3. Data Perekaman Tegangan



Gambar 4. Data Perekaman Arus



Gambar 5. Data Perekaman Power Faktor

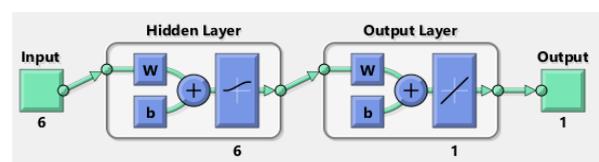


Gambar 6. Data Perekaman Daya

Dataset JST diperoleh dari bulan April, Mei, Juni dan seterusnya. Data ini tergantung dari *order* pekerjaan pada mesin di laboratorium. Data sampling 30 menit pertama digunakan sebagai data *input* ($x_1, x_2, x_3, x_4, x_5, x_6$) sedangkan data pada menit ke 60 digunakan sebagai data target (y) seperti pada Gambar 10. Pada bulan April 2019 diperoleh 858 cuplikan data. Setelah diolah menggunakan *Excel* menghasilkan 70 pola input dan target. Pada bulan Mei 2019 menghasilkan 134 pola input dan target. Pada bulan Juni 2019 menghasilkan 27 pola input dan target.

Data cuplikan bulan Mei 2019 ditampilkan pada Gambar 3, 4, 5 dan 6. Gambar 10 menunjukkan data *input* dan target setelah proses normalisasi.

Salah satu arsitektur jaringan yang digunakan dalam pemodelan JST ditunjukkan pada Gambar 7.



Gambar 7. Arsitektur JST 6-6-1

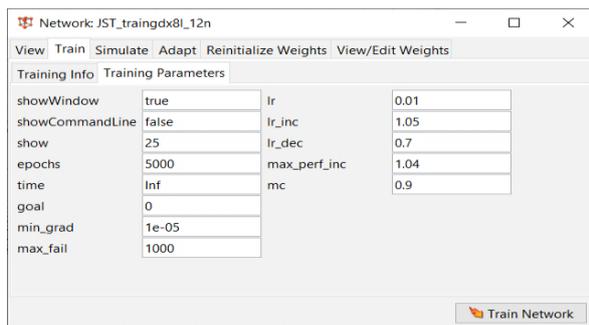
Percobaan pelatihan JST menggunakan algoritma *gradient descent momentum and adaptive learning rate backpropagation* (traingdx) menggunakan parameter pelatihan seperti pada Gambar 8. Sedangkan parameter pelatihan dengan algoritma Powel Beale *conjugate gradient* (traincgb) ditunjukkan pada Gambar 9. Kedua algoritma *backpropagation* tersebut menggunakan fungsi aktivasi *logsig* pada *hidden layer* dan fungsi aktivasi *purelin* pada *layer output*. Arsitektur menggunakan 6 neuron input, variasi neuron pada *hidden layer* dan satu neuron pada *layer output*. Variasi dilakukan pada jumlah *layer* tersebut diharapkan akan lebih banyak dilakukan penghitungan sehingga data semakin akurat.

Percobaan pemodelan dilakukan sebanyak 16 model dengan variasi pada algoritma, jumlah *hidden layer* dan jumlah neuron pada *hidden layer*. Tabel 1 menunjukkan hasil percobaan dengan membandingkan MSE pada masing-masing arsitektur. Pemodelan dengan algoritma *traincgb*, arsitektur 6-12-12-1, fungsi aktivasi *logsig-purelin* menghasilkan MSE paling kecil. Arsitektur ini diuji menggunakan dataset bulan Juni 2019. Data uji ini diluar data yang digunakan pada saat pelatihan.

Hasil prediksi arsitektur terbaik ini dibandingkan dengan data sebenarnya seperti ditunjukkan pada Tabel 2. Hasil prediksi mampu untuk mengikuti data sebenarnya seperti ditunjukkan pada Gambar 11.

Tabel 1. Hasil Percobaan Pemodelan JST

No	Algoritma	Input	Hidden Layer		Output	Fungsi Aktivasi	Training Best Validation Performance		Tes
			Neuron	Jumlah			MSE	Epoch	
1	traingdx	6	1	6	1	logsig-purelin	0,0010792	4997	0,002185
2	traingdx	6	1	12	1	logsig-purelin	0,00092468	4932	0,001989
3	traingdx	6	1	18	1	logsig-purelin	0,010098	172	0,001353
4	traingdx	6	4	6	1	logsig-purelin	0,006631	3027	0,003133
5	traingdx	6	4	12	1	logsig-purelin	0,00029117	4826	0,001017
6	traingdx	6	8	6	1	logsig-purelin	0,00061921	4014	0,002334
7	traingdx	6	8	12	1	logsig-purelin	0,0018118	176	0,002759
8	traincgb	6	2	6	1	logsig-purelin	0,0015336	46	0,001497
9	traincgb	6	2	12	1	logsig-purelin	0,00038818	30	0,001597
10	traincgb	6	2	20	1	logsig-purelin	0,0013348	12	0,001008
11	traincgb	6	4	6	1	logsig-purelin	0,0013286	20	0,001117
12	traincgb	6	4	12	1	logsig-purelin	0,00046402	35	0,000430
13	traincgb	6	4	20	1	logsig-purelin	0,0045439	84	0,005225
14	traincgb	6	8	6	1	logsig-purelin	0,00059759	178	0,001399
15	traincgb	6	8	12	1	logsig-purelin	0,00032821	101	0,001276
16	traincgb	6	16	6	1	logsig-purelin	0,0023783	23	0,004378

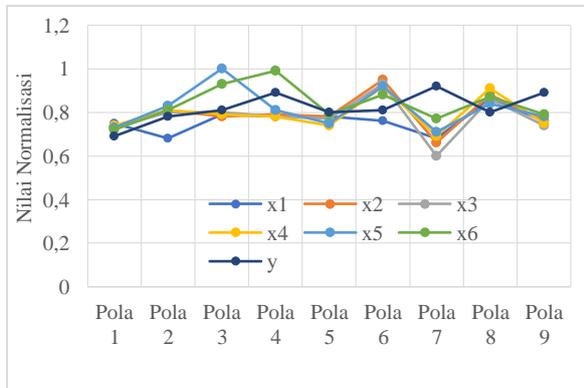


Gambar 8. Parameter Pelatihan Traingdx

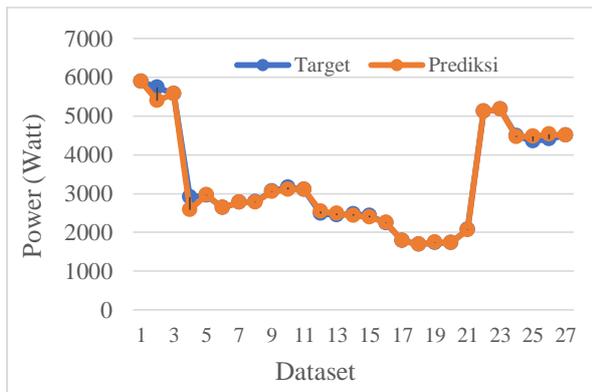
Pada penelitian-penelitian sebelumnya, Hasim melakukan percobaan prediksi daya harian menggunakan metode *backpropagation* dengan hasil *traincgb* menunjukkan paling optimal. Rata-rata error 5,81% pada pengujian data selama satu minggu [7].



Gambar 9. Parameter Pelatihan Traincgb



Gambar 10. Pola Input JST



Gambar 11. Perbandingan Hasil Prediksi dan Data Real

Arifah dkk melakukan penelitian untuk memperkirakan konsumsi beban listrik jangka panjang di Kabupaten Ponorogo menggunakan jaringan saraf tiruan dengan metode *backpropagation* algoritma *gradient descent* dengan momentum dan *adaptive learning rate* (traindgx). Penelitian ini memprediksi konsumsi listrik tiap bulan. Hasil dari implementasi JST menghasilkan MSE sebesar 0.7% [8].

Rodrigues, dkk. juga menggunakan JST algoritma Levenberg-Marquardt untuk prediksi konsumsi energi listrik pada 93 rumah dalam periode jam dan harian [9]. Zagrebina, dkk. melakukan penelitian untuk memprediksi

konsumsi energi listrik tujuh distrik di Rusia menggunakan metode recurrent neural network (RNN). Hasil prediksi menggunakan RNN menunjukkan rata-rata *relative error* lebih baik 2,10% jika dibandingkan memprediksi menggunakan metode regresi [10].

Tabel 2. Keluaran Hasil Prediksi menggunakan JST

No.	Data Real (W)	Data Hasil Prediksi (W)	galat (error)
1	5888,31	5888,98	0,01%
2	5738,38	5403,88	5,83%
3	5580,38	5579,88	0,01%
4	2918,29	2580,08	11,59%
5	2953,66	2960,12	0,22%
6	2639,43	2641,32	0,07%
7	2780,72	2773,64	0,25%
8	2787,86	2779,03	0,32%
9	3056,80	3053,24	0,12%
10	3162,82	3100,75	1,96%
11	3106,47	3106,09	0,01%
12	2486,28	2545,82	2,39%
13	2447,02	2483,56	1,49%
14	2476,71	2424,75	2,10%
15	2427,84	2384,72	1,78%
16	2234,75	2247,49	0,57%
17	1786,37	1787,27	0,05%
18	1694,33	1695,10	0,05%
19	1737,30	1744,36	0,41%
20	1733,77	1734,32	0,03%
21	2068,50	2062,08	0,31%
22	5124,69	5124,38	0,01%
23	5177,57	5176,35	0,02%
24	4489,70	4460,66	0,65%
25	4348,19	4477,59	2,98%
26	4411,74	4538,10	2,86%
27	4500,44	4499,96	0,01%
	Rata-rata		1,34%

KESIMPULAN DAN SARAN

Kesimpulan

Dari hasil pemodelan JST dapat disimpulkan bahwa algoritma *backpropagation* dapat digunakan sebagai metode prediksi berdasarkan pada data sebelum kejadian. Pada kasus penelitian ini didapatkan algoritma traincgb arsitektur 6-12-12-1 dengan fungsi aktivasi

logsig dan pureline mampu memberikan hasil prediksi yang paling optimal.

Penggunaan dataset latihan dalam jumlah banyak akan makin baik dalam proses pelatihan JST. Makin banyak pola yang digunakan dalam pelatihan akan membuat JST makin mudah dalam mengingat pola input dan target. Data bulan Mei 2019 yang memiliki paling banyak pola digunakan sebagai data latihan JST sehingga dapat melakukan pengenalan dengan menghasilkan MSE 0,00043.

Saran

Penelitian dapat dilanjutkan untuk prediksi secara *real time*. Data dari sistem akuisisi data dapat langsung diolah secara *web based*. Penghitungan dapat juga dilanjutkan pada penghitungan dampak ekonominya. Sedangkan pada bagian metode prediksi dapat juga dibandingkan dengan metode kecerdasan buatan yang lain. Perbandingan ini untuk mencari metode prediksi yang paling optimal.

UCAPAN TERIMA KASIH

Terima kasih kami sampaikan kepada Ka. Balai Besar Bahan dan Barang Teknik atas dukungannya dalam penelitian ini dan rekan-rekan laboratorium otomotif atas kerjasamanya dalam kegiatan pemasangan peralatan *monitoring* energi.

DAFTAR PUSTAKA

- [1] C. Fan, Y. Sun, Y. Zhao, M. Song, and J. Wang, "Deep learning-based feature engineering methods for improved building energy prediction," vol. 240, no. January, pp. 35–45, 2019.
- [2] I. Prediction, "The General Regression Neural Network Based on the Fruit Fly Optimization Algorithm and the Data Inconsistency Rate for Transmission Line Icing Prediction," 2017.
- [3] S. Kusumadewi, *Membangun Jaringan Saraf Tiruan Menggunakan MATLAB & EXCEL LINK*, Pertama. Yogyakarta: Graha Ilmu, 2004.
- [4] Y. A. Lesnussa, S. Latuconsina, and E. R. Persulesy, "Aplikasi Jaringan Saraf Tiruan Backpropagation untuk Memprediksi Prestasi Siswa SMA (Studi kasus: Prediksi Prestasi Siswa SMAN 4 Ambon)," vol. 11, no. 2, pp. 149–160,

- 2015.
- [5] C. Hopmann, C. Augusto Santos Silva Eng Christian Luft, J. de Saldanha Gonçalves Matos Supervisor, and C. Augusto Santos Silva, "Machine Learning to improve indoor climate and building energy performance Energy Engineering and Management Examination Committee," no. October, 2017.
- [6] N. M. Sukarno, P. W. Wirawan, and S. Adhy, "Perancangan dan implementasi jaringan saraf tiruan," vol. 5, pp. 9–18.
- [7] A. Hasim, "Prakiraan Beban Listrik Kota Pontianak Dengan Jaringan Saraf Tiruan (Artificial Neural Network)," *Cent. Libr. Bogor Agric. Univ.*, p. 1, 2008.
- [8] Arifah, N., T., A. Murnomo, and A. Suryanto, "Implementasi Neural Network pada Matlab untuk Prakiraan Konsumsi Beban Listrik Kabupaten Ponorogo Jawa Timur," vol. 9, no. 1, 2017.
- [9] F. Rodrigues, C. Cardeira, and J. M. F. Calado, "The Daily and Hourly Energy Consumption and Load Forecasting Using Artificial Neural Network Method: A Case Study Using a Set of 93 Households in Portugal," *Energy Procedia*, vol. 62, pp. 220–229, 2014.
- [10] S. A. Zagrebina, V. G. Mokhov, and V. I. Tsimbol, "ScienceDirect ScienceDirect ScienceDirect Electrical Energy Consumption Prediction is based Electrical Energy Consumption Prediction is based on the Recurrent Neural Network on the Recurrent Neural Network," vol. 00, 2019.

