

## Prediksi Daya Listrik Jangka Sangat Pendek Pembangkit *Photovoltaic* Berbasis *Internet of Things* Menggunakan *Feed Forward Neural Network*

**Kukuh Eko Purwantoro**

S1 Teknik Elektro, Fakultas Teknik, Universitas Negeri Surabaya  
e-mail : kukuh.18004@mhs.unesa.ac.id

**Unit Three Kartini, Bambang Suprianto, Achmad Imam Agung**

S1 Teknik Elektro, Fakultas Teknik, Universitas Negeri Surabaya  
e-mail : unitthree@unesa.ac.id, bambangsuprianto@unesa.ac.id, achmadimam@unesa.ac.id

### Abstrak

Penggunaan daya listrik di kalangan masyarakat semakin meningkat seiring perkembangan teknologi pada zaman sekarang. Maka dapat dilakukan pemantauan dan prediksi daya listrik untuk mengatur ketersediaan baterai pada pembangkit *photovoltaic*. Penelitian prediksi daya listrik dilakukan dengan mengambil data dengan melakukan pengujian pemodelan *monitoring* daya listrik pembangkit *photovoltaic* berbasis IoT. Rumusan masalah berdasarkan latar belakang tersebut yaitu penggunaan daya listrik dapat dipantau dengan IoT dan diprediksi untuk jangka waktu satu jam sampai hari berikutnya serta, analisa akurasi *error* pada prediksi daya listrik yang dibandingkan dengan data pengujian untuk mendapatkan tingkat ketepatan terbaik. Bertujuan untuk pemantauan pemodelan yang dapat diakses melalui telepon pintar dan mendapatkan akurasi kesalahan terbaik pada prediksi daya listrik yang dibandingkan dengan data pengujian. Metode yang digunakan adalah metode eksperimen dengan pendekatan kuantitatif, dimulai dengan studi literatur, selanjutnya pengambilan data, dilanjutkan dengan analisis data, lalu membuat desain sistem peramalan, serta konfigurasi *neural network*, selanjutnya melakukan pembelajaran (*training*) dan pengujian (*testing*) pada *software* MATLAB. Kesalahan tertinggi prediksi sebesar 4,26% dan terendah pada sebesar 0,34 %. MSE pada *traingdx* sebesar 0.007844, *Traincgb* sebesar 0.043241 dan rata-rata MAPE pada *traingdx* sebesar 2.65% dan Pada *traincgb* sebesar 2.6%. Tingkat ketepatan prediksi daya terbaik didapat pada *traingdx* sebesar 97,45% dan terkecil sebesar 97,15% pada *traincgb* pula. Semakin banyak pola dan jenis pembelajaran (*train*) yang dilakukan semakin baik pula hasil *error* yang dihasilkan.

**Kata Kunci:** daya listrik, FF-NN, *internet of things*, *photovoltaic*

### Abstract

Utilization of electric power in the community is increasing along with the development of technology today. So it can be done by monitoring and predicting electrical power to regulate the availability of batteries in photovoltaic plants. Electrical power prediction research is carried out by taking data by testing the IoT-based photovoltaic power monitoring modeling model. The formulation of the problem based on this background is that the use of electrical power can be monitored with IoT and predicted for a period of one hour to the next day as well as, analysis of error accuracy in the prediction of electrical power which is compared with test data to get the best level of accuracy. Aims for modeling monitoring that can be accessed via a smartphone and getting the best error accuracy on the electric power prediction compared to the test data. The method used is an experimental method with a quantitative approach, starting with a literature study, and data collection, followed by data analysis, then making a forecasting system design, and neural network configuration, then doing training and testing on the MATLAB software. The highest prediction error is 4.26% and the lowest is 0.34%. MSE on *traingdx* is 0.007844, *Traincgb* is 0.043241 and the average MAPE on *traingdx* is 2.65% and on *traincgb* is 2.6%. The best level of power prediction accuracy is obtained on *traingdx* of 97.45% and the smallest of 97.15% on *traincgb* as well. The more patterns and types of learning (*train*) that are carried out, the better the error results produced.

**Keyword:** electric power, FF-NN, internet of things, photovoltaic

### PENDAHULUAN

Penggunaan alat elektronik di kalangan masyarakat semakin meningkat seiring perkembangan teknologi pada zaman sekarang. Salah satu kegiatan yang dapat dilakukan untuk mengurangi jumlah

penggunaan daya listrik ini yaitu menerapkan penghematan energi, penghematan sendiri dapat dideskripsi dengan pemantauan dan kontrol daya listrik. Pada penelitian ini diterapkan pemantauan dan kontrol daya listrik pada pembangkit

*photovoltaic*, serta ditambahkan prediksi daya listrik untuk mengetahui berapa daya listrik untuk beberapa waktu kedepan. Pemantauan yang digunakan berbasis *Internet of Things (IoT)* dimana dapat dimonitoring dan dikontrol penggunaan daya listrik pada pembangkit *photovoltaic* tersebut menggunakan telepon pintar yang terhubung jaringan internet.

Dengan penggunaan daya listrik yang semakin meningkat dan untuk mengatur ketersediaan baterai pada pembangkit *photovoltaic*. Maka digunakan monitoring atau pemantauan dan prediksi daya listrik tersebut. Prediksi daya listrik merupakan suatu penelitian yang bertujuan sama seperti peramalan / *forecasting* daya listrik. Penelitian prediksi daya listrik dilakukan dengan mengambil data dengan melakukan pengujian pemodelan *monitoring* pembangkit *photovoltaic* yang berbasis *IoT*. Dengan dibantu *software* seperti MATLAB, prediksi daya listrik lebih optimal dan lebih efisien. Karena memiliki nilai ketepatan yang mencapai hingga 99,9%, dan juga menggunakan metode *feedforward neural network* dengan algoritma *feedforward backpropagation*.

Permasalahan yang diangkat dari penelitian prediksi daya listrik berdasarkan latar belakang penelitian merupakan pemantauan penggunaan daya listrik penggunaannya menggunakan *Internet of Things (IoT)* dan diprediksi untuk jangka waktu satu jam sampai hari berikutnya, dan menganalisa akurasi *error* pada prediksi daya listrik yang dibandingkan dengan data pengujian serta mendapatkan tingkat ketepatan terbaik. Penelitian tersebut bertujuan untuk pemantauan dan prediksi daya listrik pada pembangkit *photovoltaic* dimana pemantauan daya listrik berbasis *Internet of Things* serta dapat diakses dari telepon pintar. Sehingga kebutuhan energi listrik diperlukan pemantauan dan prediksi daya listrik yang digunakan, mendapatkan hasil *error* terkecil pada prediksi daya listrik yang dibandingkan dengan data pengujian dan mencapai tingkat ketepatan terbaik terhadap data daya listrik pengujian pemodelan *monitoring*. Dengan mendapatkan data prediksi daya listrik dan suhu temperatur harian pada pembangkit *photovoltaic* dalam jangka pendek setelah didapatkan hasil prediksi maka perencanaan untuk penyediaan daya listrik menjadi lebih efisien dan presisi dengan didukung fitur kontrol dan pemantauan berbasis *internet of things* pada aplikasi *blynk*.

Adapun beberapa penelitian relevan sebelumnya yang telah dilakukan diantaranya penelitian mengenai peramalan daya listrik

menggunakan metode *neural network* (Ardianto dan Kartini 2019; Aminulloh dan Kartini 2020; Dzikri 2020; Agam dan Kartini 2019; Asfah dan Kartini 2020; Shafiei Chafi dan Afrakhte 2021; Olagoke 2016). Penelitian selanjutnya mengenai *hybrid model combined Fuzzy Multi-Objective Decision Making with Feed Forward Neural Network (F-MODM-FFNN) For Very Short-Term Load Forecasting Based on Weather Data* (Yundra, dkk 2020). Penelitian mengenai *hybrid Convolutional Backpropagation Neural Network* untuk Peramalan Beban Jangka Sangat Pendek Berdasarkan Minimalisasi Biaya Listrik (Sugiarto 2021). Penelitian berikutnya mengenai pemodelan monitoring arus dan tegangan pembangkit listrik tenaga surya berbasis *IoT* (Apriani 2021). Penelitian selanjutnya mengenai sistem monitoring daya listrik berbasis *IoT* (Handarly dan Lianda 2018; Priharti, Rosmawati, dan Wibawa 2019). Penelitian berikutnya mengenai rancang bangun monitoring daya listrik (Gumilang dan Rakhmad 2020; Rus-Casas, dkk. 2020; Apriani 2021; Madadi 2021).

Berdasarkan latar belakang, penulis tertarik membuat penelitian tentang prediksi daya listrik Pembangkit *Photovoltaic* Berbasis *IoT* Menggunakan *Feedforward Neural Network*.

## KAJIAN PUSTAKA

### Prediksi Daya

Proses memprediksi peristiwa atau data untuk masa depan dikenal sebagai peramalan. Seni dan ilmu mengantisipasi peristiwa masa depan adalah nama lain untuk peramalan. Untuk itu perlu dilakukan peramalan dengan menggunakan model matematika untuk memproyeksikan data historis ke masa depan. (Pratama dan Anifah 2016).

### Photovoltaic

*Photovoltaic* adalah suatu alat yang terdiri dari kumpulan sel surya yang mengubah energi radiasi matahari menjadi energi listrik, proses perubahan tersebut berdasarkan efek *photovoltaic*. Sel surya pada *photovoltaic* adalah alat yang berperan mengubah energi radiasi matahari menjadi energi listrik.

### Internet of Things

*Internet of Things (IoT)* adalah suatu konsep yang memiliki tujuan memaksimalkan manfaat dari konektivitas internet yang terhubung secara terus menerus yang kita gunakan untuk menghubungkan mesin, peralatan, dan benda elektronik lainnya

dengan sensor dan aktuasi untuk memperoleh hasil data dan memproses cara kerjanya.

**Transformasi Data**

Untuk mendapatkan hasil prediksi yang lebih presisi dengan memanfaatkan algoritma *machine learning*, maka dilakukan prosedur transformasi data. Prapemrosesan memiliki potensi untuk mengurangi ukuran data tanpa mempengaruhi isinya dalam beberapa keadaan.

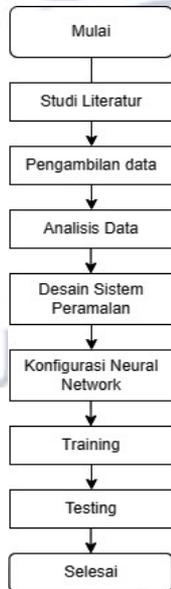
$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \times (BA - BB) + BB \quad (1)$$

Keterangan:

- X' = Transformasi data
- Xmin = Nilai Minimum pada satu hari data
- Xmax = Nilai Maksimum pada satu hari data
- BA = Batas Atas
- BB = Batas Bawah

**METODE**

Penelitian ini menggunakan metode eksperimen dengan pendekatan kuantitatif. Metode eksperimen adalah metode memiliki tujuan untuk menguji pengaruh suatu variabel terhadap variabel lain untuk mengetahui hubungan sebab akibat antara variabel yang satu dengan variabel yang lainnya.



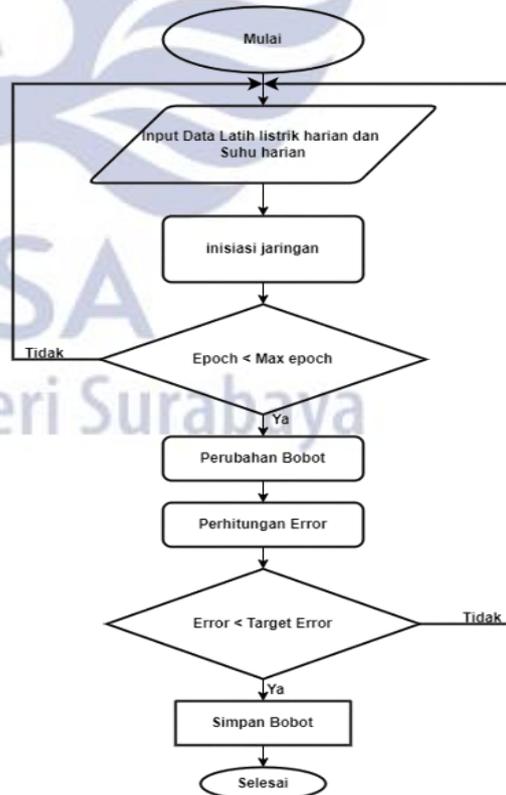
Gambar 1. Rancangan Penelitian

Penelitian dimulai dengan menganalisa masalah dengan cara studi literatur, selanjutnya pengambilan data, dilanjutkan dengan analisis data, lalu membuat desain sistem peramalan, serta konfigurasi neural network, selanjutnya melakukan

pembelajaran (*training*) dan pengujian (*testing*) pada *software* MATLAB.

Data didapatkan dari pengujian alat pemodelan monitoring daya listrik pembangkit *photovoltaic* yang dilakukan pada pukul 07.00 – 13.00 di Gedung A8 Lt. 5 Universitas Negeri Surabaya selama 7 hari pada tanggal 13 Juni 2022 – 19 Juni 2022. Langkah selanjutnya adalah menganalisis data yang akan digunakan untuk prediksi daya. Data yang digunakan daya listrik harian dengan satuan watt dan data *temperature*/suhu harian dengan satuan celcius. Data akan dibagi menjadi dua bagian, yaitu data pelatihan (*training*), dan data pengujian (*testing*). Pada konfigurasi *neural network* dilakukan dengan membangun jaringan *feedforward neural network backpropagation* menggunakan bantuan *software* MATLAB, serta inialisasi awal jaringan *feedforward neural network backpropagation* dengan pelatihan (*training*) dan pengujian (*testing*).

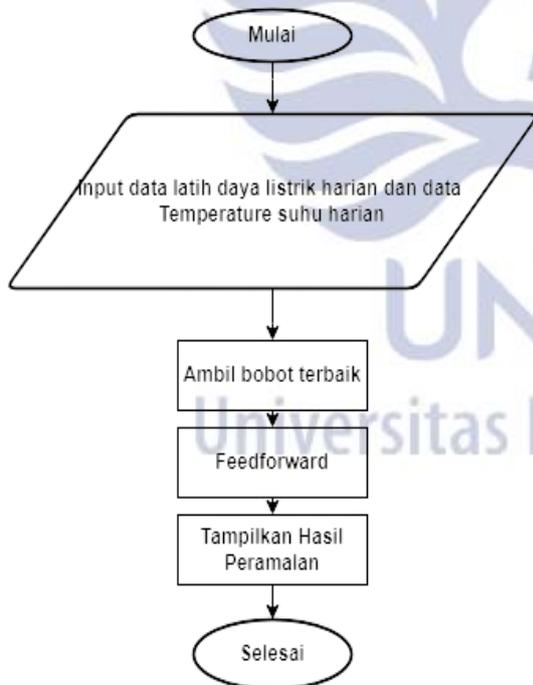
Tujuan dari pelatihan (*training*) adalah untuk melakukan proses pembelajaran dengan *neural network* untuk menentukan nilai bobot baru. Data input daya listrik dan daya suhu dilatih untuk mendapatkan bobot baru.



Gambar 2. Diagram blok simulasi pelatihan (*training*)

Gambar 2 merupakan suatu diagram yang menjelaskan alur pelatihan (*training*) pada *neural network backpropagation*. Tahap pertama dalam proses pelatihan (*training*) adalah menetapkan data yang akan digunakan dalam proses pelatihan (*training*).

Parameter yang diperhatikan dalam inisialisasi jaringan pada jaringan adalah menentukan maksimum error, menentukan fungsi aktivasi, menentukan iterasi (*epoch*), menentukan *hidden layer dan output layer*, menentukan fungsi pelatihan jaringan, menentukan *learning rate*. Tahap selanjutnya menganalisa iterasi (*epoch*) bila  $epoch < \text{maksimum } epoch$  (ya), maka akan diteruskan kebawah dan bila (*tidak*) maka dibawa keatas untuk diproses ulang. Setelah semua tahapan telah dilalui tahap selanjutnya adalah melakukan analisa apakah  $error < \text{errortarget}$ . Perubahan bobot yang terjadi akan dianalisa, bobot manakah yang memiliki *error* terkecil. Jika *error* kurang dari *error target*, maka diteruskan kebawah apabila sebaliknya maka akan dibawa ke atas untuk dianalisa kembali. Semua tahapan akan dilakukan berulang-ulang kali hingga mendapatkan bobot terbaik dengan *error* sekecil mungkin. Bobot terbaik tersebut akan digunakan untuk melakukan pengujian (*testing*).



Gambar 3. Diagram blok proses pengujian (*testing*)

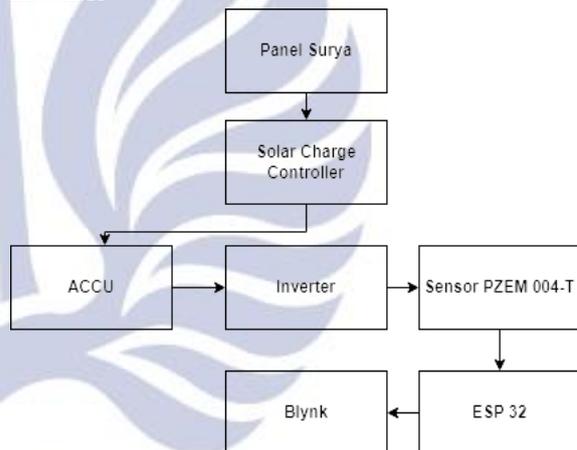
Gambar 3. merupakan suatu diagram blok yang menjelaskan alur pengujian (*testing*) pada *neural network feedforward backprop*. Proses pengujian

(*testing*) adalah proses melakukan tes pembelajaran dengan menggunakan bobot terlatih untuk melakukan peramalan. Dalam proses pengujian ada dua data yang diuji, data daya listrik harian dan data temperatur suhu harian.

Setelah melewati semua tahapan tersebut didapatkan produk penelitian berupa data prediksi daya listrik dan suhu temperatur.

### Desain Sistem Pemodelan Monitoring

Pada Gambar 3, digambarkan *flowchart* untuk alur kerja dari pemodelan monitoring yang dibuat. Pada penelitian ini digunakan satu buah sensor yaitu sensor PZEM-004T. Sensor PZEM-004T menerima input berupa arus dan tegangan yang dialirkan dari *inverter*, sedangkan inverter berperan sebagai pengubah arus dan tegangan *Direct Current (DC)* menjadi *Alternating Current (AC)* dari baterai (*accu*). Panel surya berperan untuk mengisi atau charging baterai yang bersumber dari radiasi matahari.



Gambar 4. *Flowchart* alur kerja pemodelan monitoring pembangkit *photovoltaic*

Pemodelan monitoring ini juga menggunakan mikrokontroler DOIT ESP-32 DEVKIT V1 berfungsi sebagai tempat pengolahan data dan pengirim sinyal bagi relay dan menghubungkan alat dengan software *Blynk*. Untuk mengetahui data yang diperoleh, menggunakan aplikasi *Blynk* pada *smartphone* untuk menampilkan data *display* dalam bentuk angka.

### HASIL DAN PEMBAHASAN

Pada bagian hasil dan pembahasan terdiri dari hasil pengujian pemodelan *monitoring* daya listrik berbasis IoT, Simulasi pengujian data daya listrik menjadi data prediksi pada MATLAB, dan analisis perbandingan data daya harian dengan data prediksi.

Prediksi Daya Listrik Jangka Sangat Pendek Pembangkit *Photovoltaic* Berbasis *Internet of Things* Menggunakan *Feed Forward Neural Network*

Penelitian sebelumnya yang telah membahas tentang peramalan daya listrik jangka pendek Pembangkit Listrik Tenaga Uap (PLTU) Gresik menggunakan metode *decomposition feedforward neural network*, pada penelitian ini menampilkan perbandingan data prediksi menggunakan *decomposition feedforward neural network* dengan data prediksi dari PLN (Dzikri 2020).

**Bentuk Alat Pemodelan Monitoring Daya Listrik**

Bentuk pemodelan monitoring daya listrik berbasis (*Internet of Things*) yang telah dirancang dan dihubungkan dengan panel surya dapat dilihat pada Gambar 5 dan 6.



Gambar 5. Tampilan Pada Aplikasi Blynk



Gambar 6. Pemodelan Monitoring daya listrik berbasis IoT (*Internet of Things*)

Panel surya diletakkan dan menerima radiasi matahari, sel surya berfungsi mengubah dari radiasi matahari menjadi energi listrik dan dihubungkan pada baterai digunakan untuk mengisi baterai. Selanjutnya baterai dihubungkan pada *inverter* yang berperan mengubah arus dan tegangan DC menjadi AC pada kondisi ini sensor PZEM-004T memberikan sinyal ke *mikrokontroler* DOIT ESP-32 DEVKIT V1, kemudian *mikrokontroler* memberikan

data daya listrik yang ditampilkan melalui *smartphone* pada aplikasi *BLYNK*. Beban yang digunakan adalah 2 buah lampu yang masing-masing memiliki daya sebesar 15 W dan 3 W, untuk data suhu temperatur harian diambil menggunakan termometer.

Pengujian pemodelan monitoring daya listrik pembangkit *photovoltaic* dilaksanakan di gedung A5 Universitas Negeri Surabaya selama 7 hari dari pukul 07.00-13.00 untuk mendapatkan data daya listrik.

Tabel 1. Data Daya Listrik Pengujian Pemodelan Monitoring Pembangkit *Photovoltaic* selama 7

Data daya listrik Pengujian dengan satuan Watt (W)							
Waktu	Hari 1	Hari 2	Hari 3	Hari 4	Hari 5	Hari 6	Hari 7
07.00	17.5	17.6	17.7	17.5	17.9	17.1	18.3
08.00	17.1	17.2	18.0	18.0	17.2	17.7	18.3
09.00	17.1	17.4	19.0	18.0	17.7	17.2	17.7
10.00	18.5	17.6	17.6	17.6	17.2	18.0	18.5
11.00	18.0	17.6	17.4	18.0	17.1	18.4	17.8
12.00	18.6	17.4	17.1	18.0	17.9	18.4	18.5
13.00	17.4	17.3	17.8	17.3	18.0	17.5	18.3
Rata-rata	17.7	17.4	17.8	17.8	17.6	17.8	18.2

hari

Berdasarkan Tabel 1, didapatkan hasil pengujian pada hari pertama yaitu nilai rata-rata pada daya listrik yang diterima sensor PZEM-004T sebesar 17,7 W, pada hari kedua nilai rata-rata daya listrik yaitu 17,4 W, pada hari ketiga nilai rata-rata daya listrik yaitu 17,8 W. Selanjutnya pada hari keempat nilai rata-rata daya listrik sebesar 17,8 W, pada hari kelima nilai rata-rata daya listrik sebesar 17,6 W, pada hari keenam nilai rata-rata daya listrik yaitu 17,8 W, dan pada hari ketujuh nilai rata-rata daya listrik yaitu 18,2 W.

Tabel 2. Data Suhu harian Pengujian Menggunakan Termometer selama 7 hari

Data Suhu Harian Pengujian dengan satuan Celcius (°C)							
Waktu	Hari 1	Hari 2	Hari 3	Hari 4	Hari 5	Hari 6	Hari 7
07.00	34.6	33.6	34.9	34.8	33.7	34.8	33.5
08.00	34.8	34.3	35	35.7	33.9	35.7	34.1
09.00	36.5	33.8	35.3	33.6	34.2	33.6	34.5
10.00	36.3	33.7	33.1	36.6	33.6	36.6	35.3
11.00	34.9	33.9	36.1	36.7	35.8	36.7	35.2
12.00	36	33.5	36.8	36.9	36.2	36.9	35.8
13.00	34.3	33.7	35.2	36.3	36.4	36.3	35
Rata-rata	35.3	33.8	35.2	35.8	34.8	35.8	34.8

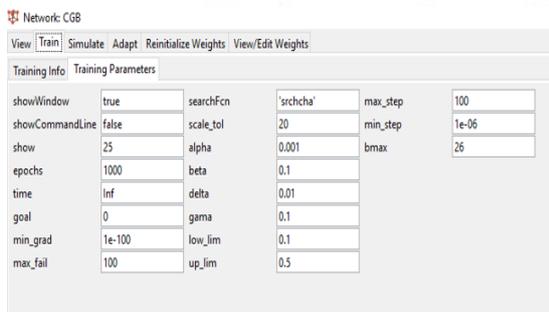
Berdasarkan Tabel 2, didapatkan hasil pengujian pada hari pertama yaitu nilai rata-rata suhu temperatur sebesar 35,34 °C, pada hari kedua nilai rata-rata suhu temperatur sebesar 33,79 °C, pada hari didapatkan ketiga nilai rata-rata suhu temperatur sebesar 35,20 °C. Selanjutnya pada hari keempat didapatkan nilai rata-rata sebesar 35,80 °C, pada hari kelima nilai rata-rata sebesar 34,83 °C, pada hari keenam didapatkan nilai rata-rata sebesar 35,80 °C, pada hari ketujuh didapatkan nilai rata-rata sebesar 34,77 °C.

**Simulasi Prediksi Daya listrik dan suhu temperatur udara menggunakan *traincgb* (Training Conjugate Gradient with Bealle-Powell Restarts) dengan Feedforward Neural Network**

Pada proses simulasi dengan software MATLAB, Memasukkan/Menginput data daya listrik dan suhu temperatur pada workspace MATLAB. Rancangan model arsitektur *feedforward* dikembangkan dan disesuaikan dengan aplikasi / *software*.

Untuk melakukan prediksi daya listrik yang membutuhkan data bobot atau input yang cukup besar, jaringan *layer* dengan banyak lapisan (*multilayer net*) dengan algoritma *feedforward backprop* dan metode pelatihan yang terawasi adalah pilihan metode yang baik. Pada jaringan *feedforward neural network* diberikan sepasang pola yang terdiri dari bobot masukan dan bobot yang diinginkan atau target.

Teknik pembelajaran yang digunakan dengan model *feedforward backprop* adalah algoritma *feedforward backprop*, yang merupakan pembelajaran terawasi dan sering menggunakan perceptron dengan beberapa lapisan untuk memodifikasi bobot yang melekat pada neuron di lapisan tersembunyi.



Gambar 7. Parameter Pembelajaran (*traincgb*)

Berdasarkan Gambar 7. dijelaskan bahwa pembelajaran yang dilakukan menggunakan epoch sebanyak 1000 dan *max fail* sebanyak 100. Pembelajaran (*Train*) dilakukan hingga

mendapatkan hasil grafik regression yang fit ( $R=1$ ) atau mendekati 1. Setelah mendapatkan hasil yang diinginkan, langkah selanjutnya mengutip output dari luaran pembelajaran dan menjadikan output tersebut sebagai input uji atau pengujian pada MATLAB. Hasil pengujian akan didapatkan setelah melakukan proses pengujian (*Simulate Networks*).

Tabel 3. Hasil Prediksi Daya listrik menggunakan *traincgb* untuk 7 hari berikutnya

Daya listrik Prediksi <i>traincgb</i> dengan satuan Watt (W)							
Waktu	Hari 1	Hari 2	Hari 3	Hari 4	Hari 5	Hari 6	Hari 7
07.00	17.4	17.5	17.6	17.5	17.6	17.5	17.6
08.00	17.5	17.5	17.6	17.6	17.6	17.6	17.6
09.00	17.6	17.9	17.6	17.5	17.6	17.5	17.6
10.00	17.9	17.9	17.9	17.9	17.9	17.9	17.9
11.00	18.0	18.0	17.7	17.7	17.7	17.8	18.1
12.00	17.9	18.0	17.9	18.0	18.0	18.0	17.9
13.00	18.1	18.0	18.2	18.1	18.2	18.1	18.2
Rata-rata	17.8	17.8	17.8	17.8	17.7	17.7	17.8

Berdasarkan Tabel 3 dan Tabel 4, didapatkan hasil prediksi data daya listrik dan suhu temperatur pada hari pertama hingga hari ketujuh.

Tabel 4. Hasil Prediksi Suhu Temperatur menggunakan *traincgb* untuk 7 hari berikutnya

Data Suhu Prediksi <i>traincgb</i> dengan satuan Celcius (°C)							
Waktu	Hari 1	Hari 2	Hari 3	Hari 4	Hari 5	Hari 6	Hari 7
07.00	35.1	34.2	34.3	34.7	34.4	34.7	34.2
08.00	35.1	34.2	34.3	34.7	34.4	34.7	34.2
09.00	35.3	34.1	34.4	34.6	34.4	34.5	34.3
10.00	35.3	34.1	34.0	34.9	34.4	34.9	34.3
11.00	35.2	34.1	34.4	34.8	34.4	34.8	34.3
12.00	35.2	34.1	34.6	35.1	34.7	35.1	34.4
13.00	35.2	34.2	34.3	34.7	34.4	34.7	34.2
Rata-rata	35.2	34.1	34.3	34.8	34.4	34.8	34.3

Setelah melakukan proses pembelajaran atau *training* keluaran yang didapatkan pada *software* adalah rata-rata MSE (*Mean Squared Error*) pada prediksi yang dilakukan. MSE adalah adalah rata-rata pada kesalahan kuadrat meliputi nilai aktual dan nilai peramalan. MSE secara umum digunakan untuk mengecek estimasi berapa nilai kesalahan pada peramalan. Didapatkan MSE pada kedua hasil prediksi yaitu pada prediksi daya listrik dan prediksi suhu temperatur yang digunakan. Pembelajaran yang dilakukan adalah *traincgb*, *traincgb* memiliki tingkat rata-rata kesalahan relatif kecil atau konvergen.

Maka jika nilai MSE sebesar 0.0001 dapat dikatakan nilai tersebut konvergen.

Tabel 5. Hasil MSE (*Mean Squared Error*) Prediksi Daya listrik menggunakan *traincgb*

Waktu	Hari 1	Hari 2	Hari 3	Hari 4	Hari 5	Hari 6	Hari 7
07.00	0.002	0.05	0.02	0.007	0.03	0.06	0.01
08.00	0.09	0.03	0.17	0.04	0.04	0.05	0.17
09.00	0.13	0.01	0.15	0.03	0.007	0.09	0.07
10.00	0.02	0.01	0.03	0.01	0.09	0.04	0.03
11.00	0.05	0.01	0.004	0.001	0.003	0.03	0.08
12.00	0.04	0.001	0.008	0.004	0.04	0.000	0.05
13.00	0.11	0.02	0.02	0.02	0.17	0.04	0.01
Rata-rata MSE :				0.043424			

Berdasarkan Tabel 5, didapatkan nilai MSE pada hari pertama hingga hari ketujuh pada simulasi prediksi daya listrik. Rata-rata MSE pengujian menggunakan *traincgb* untuk prediksi daya listrik adalah sebesar 0.043424, angka MSE tersebut relatif kecil.

Tabel 6. Hasil MSE (*Mean Squared Error*) Prediksi Suhu Harian Menggunakan *traincgb*

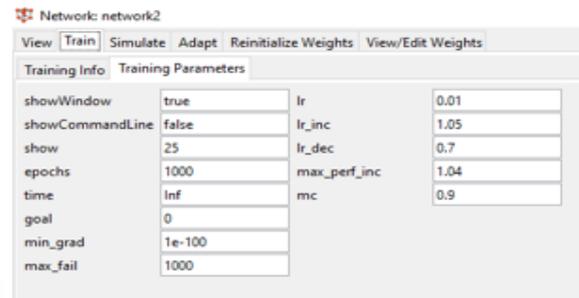
	Hari 1	Hari 2	Hari 3	Hari 4	Hari 5	Hari 6	Hari 7
07.00	0.020	0.008	0.008	0.005	0.022	0.008	0.038
08.00	0.024	0.008	0.004	0.001	0.008	0.000	0.015
09.00	0.005	0.004	0.009	0.005	0.033	0.002	0.008
10.00	0.019	0.021	0.038	0.005	0.040	0.021	0.046
11.00	0.010	0.003	0.002	0.002	0.062	0.005	0.103
12.00	0.019	0.020	0.019	0.005	0.039	0.024	0.047
13.00	0.031	0.003	0.018	0.000	0.021	0.002	0.029
Rata-rata MSE :				0.002723			

Berdasarkan Tabel 6, didapatkan nilai MSE pada hari pertama hingga hari ketujuh pada simulasi prediksi suhu. Rata-rata MSE pengujian menggunakan *traincgb* untuk prediksi suhu harian adalah sebesar 0.02723.

### Simulasi Prediksi Daya Listrik dan Suhu Temperatur udara menggunakan *traingdx* (*Gradient Decsent with momentum & adaptive LR*)

Langkah yang dilakukan pada simulasi *traingdx* kurang lebih sama dengan *traincgb*, tetapi parameter yang digunakan cukup berbeda dari *traincgb*. Parameter yang digunakan seperti pada Gambar 8. Parameter dibutuhkan untuk memberikan pengaturan pada suatu simulasi prediksi, dengan berapa nilai error, target error dan lain-lain.

Konfigurasi pada simulasi diperlukan dan diperhatikan dengan baik untuk mendapatkan hasil ketepatan terbaik pada prediksi daya listrik.



Gambar 8. Parameter pembelajaran (*traingdx*)

Dijelaskan pada gambar 8, epoch yang digunakan sebesar 1000 dan *max\_fail* 1000 dengan *lr* 0.01 dengan jumlah *hidden layer* 7 dan neuron 10. Selanjutnya simulasi pembelajaran (*train*) dapat dilakukan dan mencari hasil pembelajaran (*train*) terbaik yaitu  $R=1$  atau mendekati 1.

Setelah mengkonfigurasi parameter pembelajaran, didapatkan hasil pembelajaran (*traingdx*) seperti yang ditunjukkan pada Tabel 7 dan Tabel 8.

Tabel 7. Hasil Prediksi Daya listrik Menggunakan *traingdx* untuk 7 Hari berikutnya

Daya listrik Prediksi <i>traingdx</i> dengan satuan Watt (W)							
Waktu	Hari 1	Hari 2	Hari 3	Hari 4	Hari 5	Hari 6	Hari 7
07.00	17.6	17.5	17.6	17.5	17.4	17.6	17.4
08.00	17.6	18.1	17.6	17.6	17.6	17.6	17.5
09.00	17.6	17.6	17.7	17.6	17.6	17.6	17.7
10.00	17.9	17.9	17.9	17.9	17.9	17.9	17.9
11.00	17.8	17.9	17.9	17.9	18.0	17.8	17.9
12.00	17.9	17.9	17.9	17.9	17.8	17.9	17.8
13.00	18.2	18.2	18.1	18.2	18.1	18.2	18.1
Rata-rata	17.8	17.9	17.8	17.8	17.8	17.8	17.8

Tabel 8. Hasil Prediksi Suhu menggunakan *traingdx* untuk 7 hari berikutnya

Data Suhu Prediksi <i>traingdx</i> dengan satuan Celcius (°C)							
Waktu	Hari 1	Hari 2	Hari 3	Hari 4	Hari 5	Hari 6	Hari 7
07.00	35.2	34.1	34.5	35.0	34.5	34.8	34.4
08.00	35.1	34.1	34.2	34.8	34.5	34.8	34.2
09.00	35.2	34.1	34.5	35.0	34.6	34.8	34.4
10.00	35.2	34.1	34.2	35.0	34.6	35.1	34.4
11.00	35.2	34.1	34.3	34.9	34.6	35.1	34.4
12.00	35.2	34.1	34.3	35.0	34.6	35.1	34.4
13.00	35.1	34.1	34.3	34.9	34.6	35.0	34.3
Rata-rata	35.2	34.1	34.3	34.9	34.6	35.0	34.3

Setelah melakukan pembelajaran dan mendapatkan hasil bobot terbaik, langkah selanjutnya melakukan pengujian (*Simulate Network*). Dan mendapatkan hasil *output* pengujian sekaligus prediksi untuk daya listrik dan suhu temperatur. Tabel 7 dan Tabel 8 menunjukkan bahwa nilai rata-rata prediksi daya listrik sebesar 17,9 W dan nilai rata-rata prediksi suhu temperatur sebesar 34,6 °C. Pada pengujian didapatkan juga nilai MSE seperti yang dijelaskan pada Tabel 9.

MSE didapatkan untuk mengukur keberhasilan suatu train atau pelatihan yang dilakukan pada *software* MATLAB. Jika MSE berada diangka terkecil pada suatu pelatihan prediksi daya maka, prediksi tersebut dapat dibilang berhasil atau memprediksi dengan tepat hingga sebesar 99,9% kemungkinan.

Tabel 9. Hasil MSE (*Mean Squared Error*) Prediksi Daya Listrik Menggunakan *traingdx* Selama 7 Hari

Waktu	Hari 1	Hari 2	Hari 3	Hari 4	Hari 5	Hari 6	Hari 7
07.00	0.092	0.064	0.003	0.081	0.071	0.017	0.036
08.00	0.006	0.018	0.009	0.019	0.008	0.01	0.004
09.00	0.000	0.004	0.001	0.046	0.074	0.046	0.104
10.00	0.11	0.018	0.006	0.015	0.045	0.034	0.075
11.00	0.157	0.049	0.02	0.017	0.068	0.154	0.116
12.00	0.069	0.004	0.01	0.031	0.152	0.059	0.030
13.00	0.023	0.012	0.01	0.004	0.038	0.004	0.055
Rata-rata MSE :	0.00784472						

Rata-rata MSE (*Mean Squared Error*) yang didapatkan pada *traingdx* adalah sebesar 0.002203 hasil tersebut juga konvergen seperti *traincgb* tetapi MSE *traingdx* dibanding dengan *traincgb* cenderung lebih kecil.

Tabel 10. Hasil MSE (*Mean Squared Error*) Prediksi Suhu Harian Menggunakan *traingdx* Selama 7 Hari

Waktu	Hari 1	Hari 2	Hari 3	Hari 4	Hari 5	Hari 6	Hari 7
07.00	0.058	0.009	0.023	0.027	0.013	0.025	0.031
08.00	0.019	0.010	0.001	0.003	0.011	0.001	0.010
09.00	0.051	0.011	0.050	0.044	0.054	0.079	0.011
10.00	0.100	0.002	0.133	0.011	0.001	0.004	0.005
11.00	0.058	0.028	0.057	0.065	0.007	0.018	0.035
12.00	0.053	0.017	0.101	0.054	0.039	0.039	0.039
13.00	0.096	0.007	0.054	0.015	0.011	0.004	0.005
Rata-rata MSE :	0.01918						

Rata-Rata MSE (*Mean Squared Error*) yang didapatkan pada prediksi suhu menggunakan

*traingdx* adalah sebesar 0.01918 hasil tersebut lebih besar dari hasil MSE yang didapatkan pada *traincgb*. Setelah mendapatkan semua hasil MSE pada prediksi daya listrik maupun suhu temperatur, maka dilakukan perbandingan data. Setelah mendapatkan angka MSE dan semua rata-rata MSE, langkah selanjutnya adalah melakukan perbandingan dengan data pengujian atau data *real*. Data yang dibandingkan didapatkan selisih dan persentase keberhasilan prediksi atau disebut MAPE (*Mean Percentage Absolut Error*).

MAPE dan MSE memiliki perbedaan jika MSE tidak memiliki satuan, dan MAPE memiliki satuan yaitu persen. Dengan menggunakan MAPE, penelitian dapat diukur tingkat keberhasilan atau tingkat ketepatan prediksi dengan bentuk persentase (%).

**Analisis Perbandingan Data Hasil prediksi dengan Data Pengujian pemodelan monitoring menggunakan MAPE (*Mean Absolut Percentage Error*)**

Perhitungan *Mean Absolut Percentage Error* (MAPE) memiliki persamaan, dimana MAPE digunakan untuk menentukan tingkat ketepatan suatu prediksi.

$$MAPE = \frac{i}{n} \sum \left| \frac{Ai-Fi}{Ai} \right| \times 100\% \quad (2)$$

Keterangan:  
 Ai = nilai data aktual  
 Fi = nilai data prediksi

Nilai error pada MAPE memiliki satuan persen yang dapat dijadikan acuan untuk tingkat ketepatan suatu peramalan yang dibandingkan dengan data pengujian atau data *real*. Perbandingan data pengujian dan data yang diprediksi dapat dilihat pada Tabel 11.

Tabel 11. Tabel Perbandingan data Suhu temperatur

Waktu	Suhu Real (°C)	Suhu Prediksi (°C)	Selisih Prediksi (°C)	MAPE (%)
07.00	34.6	35.13	-0.53	1.5
08.00	33.6	35.13	-1.53	4.4
09.00	34.9	35.30	-0.40	1.1
10.00	34.8	35.28	-0.48	1.4
11.00	33.7	35.20	-1.50	4.3
12.00	34.8	35.24	-0.44	1.3
13.00	33.5	35.15	-1.65	4.7
Rata-rata MAPE:				2.65

Untuk perbandingan diambil sample pada data tanggal 13 juni 2022 diperoleh *error* terkecil pada prediksi yaitu 1,1%, serta *error* terbesar yaitu 4,7% dan diperoleh rata-rata MAPE diperoleh sebesar 2,65%.

Tabel 12. Tabel Perbandingan Daya Listrik Data Pengujian dengan Data Prediksi

Waktu	Daya Real (W)	Daya Prediksi (W)	Selisih Prediksi (W)	MAPE (%)
07.00	17.5	17.56	0.06	0.34
08.00	17.1	17.57	0.47	2.69
09.00	17.1	17.59	0.49	2.77
10.00	18.5	17.88	-0.62	3.45
11.00	18.0	17.85	-0.15	0.83
12.00	18.6	17.91	-0.69	3.88
13.00	17.4	18.17	0.77	4.26
Rata-rata MAPE :				2.6

Pada Tabel 12. ditunjukkan perbandingan prediksi daya listrik dengan data real (pengujian) pada data tanggal 13 juni 2022 diperoleh *error* terkecil pada prediksi yaitu 0,34%, serta *error* terbesar yaitu 4,26% dan rata-rata MAPE diperoleh sebesar 2,6%. Selanjutnya dilakukan Perbandingan rata-rata MSE (*Mean Squared Error*) dan tingkat ketepatan prediksi menggunakan *traincgb* dan *traingdx*.

**Perbandingan Rata-Rata MSE (*Mean Squared Error*) dan Tingkat Ketepatan Prediksi menggunakan *traincgb* dan *traingdx***

Perbandingan rata-rata MSE harian ditunjukkan pada Tabel 13, MSE diperoleh pada melakukan *simulate network* pada *Neural Network tool*.

Tabel 13. Tabel Perbandingan Rata-Rata MSE Prediksi Daya Listrik untuk 7 hari kedepan

Hari	Traincgb	Traingdx	Selisih MSE	Keterangan
1	0.11	0.004	0.12	Cgb > gdx
2	0.03	0.002	0.02	Cgb > gdx
3	0.03	0.0002	0.02	Cgb > gdx
4	0.02	0.008	0.01	Cgb > gdx
5	0.18	0.01	0.17	Cgb > gdx
6	0.04	0.03	0.01	cgb > gdx
7	0.02	0.007	0.013	cgb > gdx
Rata-Rata	0.043	0.007	0.005	

Perbandingan rata-rata MSE *traingdx* lebih kecil dari *traincgb*. Pada pengujian ini *traingdx* lebih presisi dibanding *traincgb*, diperoleh MSE dari

*traincgb* pada simulasi dengan menginput data daya listrik yang sudah ditransformasi dan didapatkan MSE sebesar 0.04324. Pada *traingdx* diperoleh MSE sebesar 0.007844.

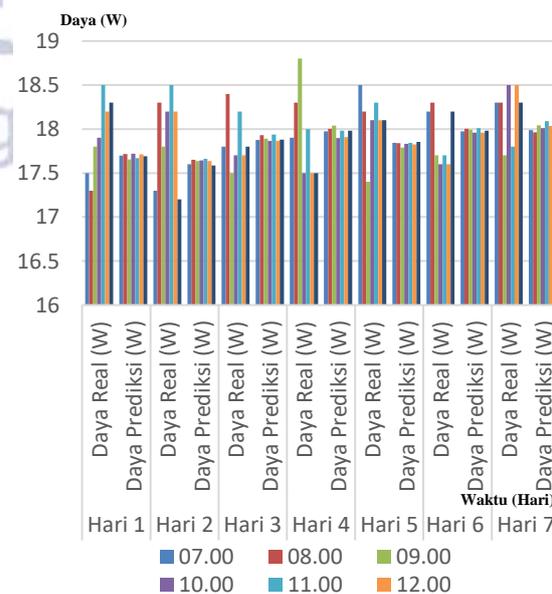
Tabel 14. Tabel Perbandingan Rata-Rata MSE Prediksi Suhu Temperatur

Hari	Traincgb	Traingdx	Selisih MSE	Keterangan
1	-0.0182	-0.0620	0.007	cgb < gdx
2	0.0062	-0.0028	-0.017	cgb > gdx
3	-0.0140	-0.054	-0.009	cgb < gdx
4	0.0001	-0.0238	0.004	cgb > gdx
5	0.0259	0.0013	0.010	cgb > gdx
6	-0.0066	0.0130	0.011	cgb < gdx
7	0.025	-0.00633	0.005	cgb > gdx
Rata-Rata	0.002	-0.0191	0.0109	

Tabel 15. Tabel Rata – Rata Tingkat Ketepatan pada Prediksi Daya Listrik dan suhu

Rata – Rata Tingkat Ketepatan Prediksi (%)		
Prediksi	<i>traincgb</i>	<i>traingdx</i>
Daya Listrik	97,15%	97,4%
Suhu	97,42%	97,45%

Pada Tabel 14. perbandingan MSE prediksi pada *traincgb* cenderung lebih kecil pada hari 1, 3, dan 6. Sisanya nilai MSE prediksi pada *traingdx* lebih kecil dari *traincgb*. Pada prediksi yang dilakukan didapatkan rata-rata tingkat ketepatan prediksi dalam satuan persen menggunakan MAPE (*Mean Absolut Percentage Error*) seperti pada Tabel 15.



Gambar 9. Kurva Perbandingan Data Daya Listrik

hari 1-7

Berdasarkan Kurva pada Gambar 9, merupakan perbandingan hasil prediksi/peramalan daya listrik dengan model *feedforward neural network* dan daya hasil pengujian dari tanggal 13 Juni 2022 s/d 19 Juni 2022. Hasil prediksi memperlihatkan bahwa hasil prediksi dibandingkan dengan daya pengujian (*real*) cenderung lebih stabil. Serta Pada analisis perbandingan *traincgb* dan *traingdx*, dengan faktor kesalahan pada MSE dan MAPE. Terlihat jika *traingdx* lebih presisi atau memiliki nilai MSE dan MAPE lebih kecil dibandingkan dengan *traincgb*. Semakin banyak melakukan jenis *Train* pada pembelajaran, semakin baik dan presisi hasil yang didapatkan pada simulasi prediksi daya listrik.

### SIMPULAN

Setelah melakukan pengujian dan simulasi pada prediksi daya listrik pembangkit *photovoltaic* berbasis IoT (*Internet of Things*) menggunakan *feedforward neural network* dapat disimpulkan jika.

Prediksi daya listrik dilakukan untuk mengetahui daya listrik yang presisi dengan menginput data real (pengujian pemodelan monitoring), dengan simulasi pada MATLAB maka akan didapatkan hasil prediksi atau data daya yang prediksi. Semakin banyak pola dan jenis pembelajaran (*train*) yang dilakukan semakin baik pula hasil daya listrik menggunakan metode *feedforward neural network* ini. Kesalahan tertinggi atau persen error tertinggi terjadi pada 13 Juni 2022 sebesar 4,26% pada pukul 11.00 WIB dan terendah pada pukul 09.00 WIB sebesar 0,34%. Secara keseluruhan hasil prediksi daya listrik menggunakan *feedforward neural network* dan menggunakan *traingdx* mendapatkan hasil lebih baik dan presisi dibandingkan menggunakan *TrainCGB*.

MSE (*Mean Squared Error*) *traingdx* sebesar 0.007844 lebih kecil dari *traincgb* sebesar 0.043241 dan rata-rata MAPE pada *traingdx* sebesar 2.65% dan Pada *traincgb* sebesar 2.6%. Tingkat ketepatan prediksi daya terbaik didapat pada *traingdx* sebesar 97,45% dan terkecil sebesar 97,15% pada *traincgb* pula.

### SARAN

Penelitian ini masih dapat dikembangkan dengan metode lainnya yang lebih baik atau lebih efisien dibandingkan dengan metode *feedforward neural network*. Dengan menambahkan data input sebagai data pelatihan juga meningkatkan akurasi (*Train*).

Hasil pengujian (*Simulasi*) lebih baik jika menggunakan data suhu dan daya listrik harian yang lebih banyak karena kedua jenis data ini merupakan data input. Penelitian juga dapat dilanjutkan dengan meneliti arus atau *output* lain.

### DAFTAR PUSTAKA

- Agam. Masviki dan Kartini. Unit Three 2019. *Peramalan Daya Listrik PLTS On Grid Pada Rumah Tinggal Menggunakan Metode K-Nearest Neighbor Decomposition Feed Forward Neural Network Berdasarkan Data Meteorologi*. Jurnal Teknik Elektro Vol. 9 (2), 241–249.
- Aminulloh. Habib Rakshawi dan Kartini. Unit Three. 2020. *Peramalan Beban Listrik Jangka Pendek Menggunakan Metode Fuzzy Multi-Attribute Decision Making Decomposition Feed Forward*. Jurnal Teknik Elektro Vol. 9 (3), 649–657.
- Apriani. Yosi. 2021. *Monitoring Arus Dan Tegangan Pembangkit Listrik Tenaga Surya Menggunakan Internet Off Things*. JATISI (Jurnal Teknik Informatika Dan Sistem Informasi) 8 (2), 889–895.
- Ardianto. Dwi dan Kartini. Unit Three. 2019. *Peramalan Daya Listrik Jangka Sangat Pendek Pembangkit Termal Berdasarkan Data Meteorologi Menggunakan Metode K-Nearest Neighbor-Artificial Neural*. Jurnal Teknik Elektro Vol. 8 (1), 101–109
- Asfah. Rani Fijriyah Ismawati dan Kartini. Unit Three. 2020. *Peramalan Radiasi Global Matahari Jangka Pendek Menggunakan Modeltriple Exponential Smoothing-Feed Forward Neural*. Jurnal Teknik Elektro Vol. 9 (3), 677 – 684.
- Dzikri. Muhajir El fahmi 2020. *Peramalan Daya Listrik Jangka Pendek Pada Pltu Gresik Menggunakan Metode Decomposition Feed Forward Neural Network Berdasarkan Indeks Keandalan*. Jurnal Teknik Elektro Vol. 9 (1), 749 – 755.
- Gumilang. Mukhamad Angga dan Hariyono. Rakhmad. 2020. *Rancang Bangun Monitoring Daya Listrik Untuk Aplikasi Sistem Tenaga Surya Berteknologi Smart Grid Pada Skala Rumah Tinggal*. Jurnal Teknologi Informasi Dan Terapan Vol.7 (2), 66–70.
- Handarly. Dolly dan Lianda. Jefri. 2018. *Sistem Monitoring Daya Listrik Berbasis IoT (Internet of Thing)*. JEECAE (Journal of Electrical, Electronics, Control, and Automotive Engineering) Vol. 3 (2), 205–208.

Madadi. Srilakshmi. 2021. *A Study of Solar Power Monitoring System Using Internet of Things (IoT)*. International Journal of Innovative Science and Research Technology Vol. 6 (5), 347–350.

Olagoke. Mahrufat D. 2016. *Short Term Electric Load Forecasting Using Neural Network and Genetic Algorithm General Terms Short Term Electric Load Forecasting , Generic Algorithm , Artificial Neural Network Key Short Term Electric Load Forecasting Using Neural Network and Geneti*. International Journal of Applied Information Systems Vol. 10 (4), 22 – 28.

Pratama. Ricky Ardian dan Anifah. Lilik. 2016. *Peramalan Beban Listrik Jangka Panjang Provinsi D.I. Yogyakarta Menggunakan Neural Network Backpropagation*. Jurnal Teknik Elektro Vol. 5 (3), 40 – 47.

Priharti. W, A. F. K. Rosmawati, dan I. P.D. Wibawa. 2019. *IoT Based Photovoltaic Monitoring System Application*. Journal of Physics: Conference Series Vol. 1367 (1), 1 - 10.

Rus-Casas. Catalina, Gabino. Jiménez-Castillo, Juan Domingo. Aguilar-Peña. Juan Ignacio Fernández Carrasco, dan Rodríguez. Francisco Josémuñoz. 2020. *Development of a Prototype for Monitoring Photovoltaic Self-Consumption Systems*. Electronics (Switzerland) Vol. 9 (1), 1 - 39.

Shafiei. Chafi, Zahra, dan Hossein. Afrakhte. 2021. *Short-Term Load Forecasting Using Neural Network and Particle Swarm Optimization (PSO) Algorithm*. HINDAWI (Mathematical Problems in Engineering) Vol. 2021, 1-10.

Sugiarto. Nofianto. 2021. *Pemodelan Hybrid Convolutional Backpropagation Neural Network Untuk Peramalan Beban Jangka Sangat Pendek Berdasarkan Minimalisasi Biaya Listrik*. Jurnal Teknik Elektro Vol. 10 (2), 463–72.

Yundra. Eppy, Kartini. Unit Three, Wardani. Laili Ika dan Ardianto. Dwi. 2020. *Hybrid Model Combined Fuzzy Multi-Objective Decision Making with Feed Forward Neural Network (F-MODM-FFNN) for Very Short-Term Load Forecasting Based on Weather Data*. International Journal of Intelligent Engineering and Systems Vol. 13 (4), 182–95.