



TESIS – TE185401

**PREDIKSI DAYA PEMBANGKIT LISTRIK PV
SATU HARI KE DEPAN UNTUK
MEMUDAHKAN MANAJEMEN ENERGI
PADA SISTEM MENGGUNAKAN
*NEURAL NETWORK***

KHAIRUNNISA'
07111850010003

DOSEN PEMBIMBING

Dr.Eng., Ardyono Priyadi, S.T., M.Eng

Vita Lystianingrum Budiharto Putri, S.T., M.Sc., Ph.D .

PROGRAM MAGISTER
BIDANG KEAHLIAN TEKNIK SISTEM TENAGA
DEPARTEMEN TEKNIK ELEKTRO
FAKULTAS TEKNOLOGI ELEKTRO DAN INFORMATIKA CERDAS
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2020



TESIS – TE185401

**PREDIKSI DAYA PEMBANGKIT LISTRIK PV
SATU HARI KE DEPAN UNTUK
MEMUDAHKAN MANAJEMEN ENERGI
PADA SISTEM MENGGUNAKAN
*NEURAL NETWORK***

KHAIRUNNISA'
07111850010003

DOSEN PEMBIMBING
Dr.Eng., Ardyono Priyadi, S.T., M.Eng
Vita Lystianingrum Budiharto Putri, S.T., M.Sc., Ph.D .

**PROGRAM MAGISTER
BIDANG KEAHLIAN TEKNIK SISTEM TENAGA
DEPARTEMEN TEKNIK ELEKTRO
FAKULTAS TEKNOLOGI ELEKTRO DAN INFORMATIKA CERDAS
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2020**

LEMBAR PENGESAHAN TESIS

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar

Magister Teknik (MT)

di

Institut Teknologi Sepuluh Nopember

Oleh:

KHAIRUNNISA'

NRP: 07111850010003

Tanggal Ujian: 06 Januari 2020

Periode Wisuda: Maret 2020

Disetujui oleh:

Pembimbing:

1. Dr.Eng., Ardyono Priyadi, S.T., M.Eng

NIP: 197309271998031004



.....

2. Vita Lystianingrum B.P, S.T., M.Sc., Ph.D

NIP: 198208292006042001



..... 23/1/2020

Penguji:

1. Dr.Ir. Soedibyo, M.MT

NIP: 195512071980031004



.....

2. Dr.Ir. Margo Pujiantara, M.T

NIP: 196603181990101001



.....

3. Heri Suryoatmojo, S.T.,M.T., Ph.D

NIP: 198006032006041003



.....

Kepala Departemen Teknik Elektro
Fakultas Teknologi Elektro dan Informatika Cerdas



Dedet Candra R, S.T., M.Eng., Ph.D

NIP: 197311192000031001

Halaman ini sengaja dikosongkan

PERNYATAAN KEASLIAN TESIS

Dengan ini saya menyatakan bahwa isi keseluruhan Tesis saya dengan judul **“PREDIKSI DAYA PEMBANGKIT LISTRIK PV SATU HARI KE DEPAN UNTUK MEMUDAHKAN MANAJEMEN ENERGI PADA SISTEM MENGGUNAKAN *NEURAL NETWORK*”** adalah benar-benar hasil karya intelektual mandiri, diselesaikan tanpa menggunakan bahan-bahan yang tidak diijinkan dan bukan merupakan karya pihak lain yang saya akui sebagai karya sendiri.

Semua referensi yang dikutip maupun dirujuk telah ditulis secara lengkap pada daftar pustaka. Apabila ternyata pernyataan ini tidak benar, saya bersedia menerima sanksi sesuai peraturan yang berlaku.

Surabaya, Januari 2020



Khairunnisa'

07111850010003

Halaman ini sengaja dikosongkan

**PREDIKSI DAYA PEMBANGKIT LISTRIK PV UNTUK SATU
HARI KE DEPAN UNTUK MEMUDAHKAN MANAJEMEN
ENERGI SISTEM MENGGUNAKAN
*NEURAL NETWOK***

Nama mahasiswa : Khairunnisa'
NRP : 07111850010003
Pembimbing : 1. Dr.Eng., Ardyono Priyadi, ST., M.Eng
2. Vita Lystianingrum B.P., ST., M.Sc., Ph.D

ABSTRAK

Pembangkit listrik tenaga surya (PLTS) koneksi dengan jaringan PLN atau biasa dikenal sistem PV *on-grid*, sistem ini bertujuan untuk mengurangi tagihan listrik, dan memberikan nilai tambah kepada penggunanya, selain itu menghasilkan listrik ramah lingkungan dan bebas emisi. Oleh karena itu, daya yang dihasilkan dari panel surya harus dimaksimalkan untuk mencapai target yang diharapkan oleh pengguna. Dalam penelitian ini, penulis bertujuan melakukan prediksi daya keluaran PV menggunakan *Elman Neural Network* (ENN) dan *Feedforward Neural Network* (FFNN). Algoritma *Levenberg-marquard* digunakan untuk proses *learning* sebagai fungsi aktivasi dari deret waktu daya PV produksi dan variabel meteorologi yang diukur digunakan sebagai *input Neural Network* (NN). Beberapa nilai kesalahan dari hasil simulasi akan dievaluasi untuk memperkirakan keakuratan metode peramalan. Hasil dari prediksi daya PV yang didapatkan akan dibandingkan dengan data aktual untuk energi manajemen sistem dan bisa menjadi acuan dalam merencanakan pembagunan pembangkit PV kedepannya.

Kata kunci: *Elman Neural Network, Feedforward Neural Network, Levenberg-marquardt, Manajemen Energi Sistem, dan Neural Network.*

Halaman ini sengaja dikosongkan

ONE DAY AHEAD PREDICTION OF PV POWER PLANT FOR ENERGY MANAGEMENT SYSTEM USING NEURAL NETWORK

By : Khairunnisa'
Student Identity Number : 07111850010003
Supervisor(s) : 1. Dr.Eng., Ardyono Priyadi, ST., M.Eng
2.Vita Lystianingrum B.P., ST.,M.Sc., Ph.D

ABSTRACT

Solar power plant connected with the PLN network known as the PV system on-grid, this system aims to reduce electricity bills and provide added value to its users, besides producing environmentally friendly and emissions-free electricity. Therefore, the power generated from solar panels must be maximized to achieve the target expected by the user. In this study, the author aims to predict power output using Elman Neural Network (ENN) and Feedforward Neural Network (FFNN). The Levenberg-Marquardt algorithm is used for the learning process as an activation function of the time series of PV power production and measured meteorological variables are used as Neural Network (NN) input. Some error values from the simulation results will be evaluated to estimate the accuracy of the forecasting method. The results of the predicted PV power obtained will be compared with actual data for energy management systems and as a reference in planning the development of solar panel power plants in the future.

Key words: Elman Neural Network, Energy Management System, Feedforward Neural Network, Neural Network, and Levenberg-Marquardt.

Halaman ini sengaja dikosongkan

KATA PENGANTAR

Allhamdulillah rabbi'l'amin, puji syukur penulis ucapkan kepada Allah SWT, yang telah memberi Rahmat dan Hidayah-Nya kepada penulis sehingga dapat melaksanakan penelitian dan telah menyelesaikan buku tesis dengan judul "PREDIKSI DAYA PEMBANGKIT LISTRIK PV SATU HARI KE DEPAN UNTUK MEMUDAHKAN MANAJEMEN ENERGI PADA SISTEM MENGGUNAKAN *NEURAL NETWORK*".

Pada kesempatan ini penulis mengucapkan terima kasih kepada semua pihak yang telah membantu penulis dalam menyelesaikan buku tesis, baik berupa bantuan moral, materi, atau berupa pikiran yang tidak akan pernah terlupakan, antara lain kepada:

1. Ayahanda Drs. Hanifulkhair, M.T., dan Ibunda tercinta Delita Febriana, BSc., yang telah memberikan dukungan dan selalu mendoakan penulis agar memudahkan mengerjakan buku tesis ini.
2. Adinda tercinta Karim Abdullah dan Abdul Hamid Khalilullah yang selalu mendoakan penulis agar memudahkan dalam menyelesaikan buku tesis ini.
3. Bapak Dr.Eng., Ardyono Priyadi, ST., M.Eng dan Ibu Vita Lystianingrum Budiharto Putri.,S.T.,M.Sc.,Ph.D, selaku dosen pembimbing yang telah membimbing dan memberikan bantuan demi kelancaran pengerjaan buku tesis.
4. Seluruh Bapak-Ibu dosen dan karyawan Teknik Elektro ITS yang telah memberikan bayak ilmu kepada penulis.
5. Eki Rovianto yang selalu membantu dan memberikan semangat.
6. Rezi Delfianti, Nasyith Hananur Rohiem, Rahmat Febrianto serta seluruh angkatan S2 Teknik Sistem Tenaga ITS 2018 atas dukungan semangat dan bantuannya.
7. Seluruh sahabat penulis dari Pekanbaru yang sama-sama berjuang S2 di ITS, yang selalu memberi dukungan dan doa kepada penulis

Surabaya, Januari 2020

Penulis

Halaman ini sengaja dikosongkan

DAFTAR ISI

LEMBAR PENGESAHAN TESIS	iii
PERNYATAAN KEASLIAN TESIS	v
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR GAMBAR	xv
DAFTAR TABEL	xvii
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Tujuan	3
1.4 Batasan Masalah	4
1.5 Kontribusi	4
BAB 2 KAJIAN PUSTAKA	5
2.1 Kajian Penelitian Terkait	5
2.2 Teori Dasar	6
2.2.1 <i>Solar Photovoltaic (PV) System / Pembangkit Listrik Tenaga Surya</i>	6
2.2.2 <i>Artificial Neural Network</i>	7
2.2.2.1 <i>Elman Neural Network</i>	8
2.2.2.2 <i>Feedforward Neural Network</i>	9
2.2.3 Fungsi Aktivasi	10
2.2.4 <i>Forecasting</i> atau Peramalan	11
BAB 3 METODE PENELITIAN	13
3.1 Studi Literatur	14
3.2 Data <i>Input</i> dan Metode Perhitungan	14
3.3 Pengolahan Data	20

3.3.1	<i>Elman Neural Network (ENN)</i>	20
3.3.2	<i>Feedforward Neural Network</i>	23
3.4	Pelatihan (<i>training</i>), Pengujian (<i>testing</i>) , dan Validasi	25
3.5	Integrasi Model <i>Neural Networks</i>	25
3.6	Sistem Manajemen Energi.....	26
BAB 4 HASIL DAN PEMBAHASAN		27
4.1	Hasil Simulasi menggunakan Elman Neural Network.....	27
4.1.1	Percobaan I menggunakan <i>Elman Neural Network</i>	27
4.1.2	Percobaan II menggunakan <i>Elman Neural Network</i>	28
4.1.3	Percobaan III menggunakan <i>Elman Neural Network</i>	29
4.2	Hasil <i>Training</i> Simulasi menggunakan <i>FeedForward Neural Network</i> 30	
4.2.1	Percobaan I menggunakan <i>Feed Forward Neural Network</i>	30
4.2.2	Percobaan II menggunakan <i>Feed Forward Neural Network</i>	33
4.2.3	Percobaan III menggunakan <i>Feed Forward Neural Network</i>	36
4.3	Analisa Manajemen Energi Sistem	39
BAB 5 KESIMPULAN		43
5.1	Kesimpulan.....	43
5.2	Penelitian Selanjutnya	43
DAFTAR PUSTAKA.....		45
LAMPIRAN		47
RIWAYAT PENULIS		63

DAFTAR GAMBAR

Gambar 2.1 Skematik sistem fotovoltaik yang terhubung ke jaringan [9]	7
Gambar 2.2 Struktur Neural Network	8
Gambar 2.3 Struktur umum <i>Elman Neural Network</i> [11].....	9
Gambar 2.4 Struktur <i>FeedForward Neural Network</i>	10
Gambar 2.5 (a-c) Contoh dari Fungsi Transfer[12]	10
Gambar 2.6 Perbedaan antara PV aktual dan Prediksi PV [13].....	11
Gambar 3.1 Diagram Alir Penelitian	13
Gambar 3.2. (a). Struktur Percobaan I ENN, (b). Struktur Percobaan II ENN, dan (c) Struktur Percobaan III ENN.	16
Gambar 3.3(a). Struktur Percobaan I FFNN, (b). Struktur Percobaan II FFNN, dan	17
Gambar 3.4. <i>Training Elman Neural Network</i> Percobaan I.....	21
Gambar 3.5. <i>Training Elman Neural Network</i> Percobaan II	21
Gambar 3.6 <i>Training Elman Neural Network</i> Percobaan III.....	22
Gambar 3.7 <i>Training Feed Forward Neural Network</i> Percobaan I.....	23
Gambar 3.8. <i>Training Feed Forward Neural Network</i> Percobaan II.....	24
Gambar 3.9. <i>Training Feed Forward Neural Network</i> Percobaan III	24
Gambar 4.1 Hasil <i>training</i> Simulasi Prediksi Menggunakan <i>Elman Neural Network</i> pada Bulan Maret -April 2019.....	27
Gambar 4.2 Hasil <i>Testing</i> 2 hari 3-4 April 2019.....	27
Gambar 4.3. <i>Training</i> 23 Maret 2019-2 April 2019.....	28
Gambar 4.4 <i>Testing</i> selama 2 hari 3-4 April 2019.....	28
Gambar 4.5. <i>Training</i> 23 Maret 2019-2 April 2019.....	29
Gambar 4.6 <i>Testing</i> selama 2 hari 3-4 April 2019.....	29
Gambar 4.7 <i>Plottrainstate training</i> FFNN.....	31
Gambar 4.8 <i>Performance</i> FFNN Percobaan 1	31
Gambar 4.9 Hasil target dari <i>training</i> Percobaan I	32
Gambar 4.10 Hasil percobaan I hari ke-3 pada bulan April 2019	32
Gambar 4.11 Hasil percobaan I hari ke-4 pada bulan April 2019	33
Gambar 4.12 <i>Plottrainstate training</i> FFNN.....	34

Gambar 4.13 <i>Performance</i> FFNN Percobaan II.....	34
Gambar 4.14 Hasil target dari <i>training</i> Percobaan II	35
Gambar 4.15 Hasil percobaan II hari ke-3 pada bulan April 2019.....	35
Gambar 4.16 Hasil percobaan II hari ke-4 pada bulan April 2019.....	36
Gambar 4.17. <i>Plottrainstate training</i> FFNN Percobaan III.....	37
Gambar 4.18 <i>Performance</i> FFNN Percobaan III.....	37
Gambar 4.19. Hasil target dari <i>training</i> Percobaan III.....	38
Gambar 4.20 Hasil percobaan III hari ke-3 pada bulan April 2019	38
Gambar 4.21 Hasil percobaan III hari ke-4 pada bulan April 2019	39
Gambar 4.22 Hasil Perbandingan data aktual PV dan NN pada percobaan I	40
Gambar 4.23 Hasil Perbandingan data aktual PV dan NN pada percobaan II	40
Gambar 4.24 Hasil Perbandingan data aktual PV dan NN pada percobaan III.....	41

DAFTAR TABEL

Tabel 3.1 Parameter variabel <i>Input</i>	15
---	----

Halaman ini sengaja dikosongkan

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Pertumbuhan konsumsi listrik dari tahun ke tahun terus meningkat, penyebabnya adalah meningkatnya pertumbuhan pembangunan Industri, Gedung-gedung, Perumahan, Tekstil, dll. Hal ini yang menyebabkan permintaan daya listrik terus meningkat setiap tahunnya. Sedangkan daya yang dihasilkan tidak sebanding dengan permintaan daya yang terus bertambah. Untuk mengimbangi itu semua, sumber energi terbarukan menjadi pilihan utama sebagai alternatif dari sumber energi utama dari jaringan PLN. Salah satunya yaitu pembangkit listrik tenaga surya (PLTS), pembangkit yang menggunakan panel surya (fotovoltaik) ini menghasilkan listrik yang ramah lingkungan dan bebas emisi.

PLTS sendiri ada berbagai macam tipe, yaitu *off grid*, *on grid* dan *hybrid*. Umumnya diperkotaan, khususnya komersil banyak menggunakan pembangkit PV tipe *on grid*, sistem ini berhubungan langsung dengan jaringan listrik PLN tanpa adanya cadangan sumber energi lainnya. Dengan adanya sistem ini dapat mengurangi tagihan listrik rumah tangga, dan memberikan nilai tambah pada pemiliknya, dan pemanfaatan energi dari panel surya ini dapat membantu memaksimalkan energi listrik.

Pembangkit listrik tenaga surya sangat bergantung pada kondisi cuaca, sifatnya yang *intermittent* dan tidak pasti ini menjadi suatu hal yang harus diperhatikan. Operasi harian sistem daya yang aman tergantung pada pengiriman pembangkit listrik yang akan datang. Karenanya, rencana hari selanjutnya yang berarti dapat dilakukan hanya jika prediksi dihari ke depannya akurat.

Dalam hal prediksi, pemasok listrik tertarik pada berbagai aspek untuk mengelola pembangkit listrik dan memperkirakan produksinya. Penerapan metode peramalan PV telah menjadi bidang penelitian aktif. Ketersediaan matahari adalah keterbatasan sistem PV. Oleh karena itu kemungkinan untuk memprediksi daya PV (hingga 12 jam atau lebih) dapat menjadi peran yang sangat penting untuk perencanaan efisien sistem PV yang terhubung ke jaringan. Berbagai pendekatan

digunakan tergantung pada data yang tersedia. Metode peramalan dapat diklasifikasikan sebagai fisik atau statistik. Dalam pendekatan fisik, perkiraan PV didasarkan pada penggunaan variabel cuaca, terutama radiasi dan suhu, diprediksi oleh model *Numerical Weather Prediction* (NWP) dan kemudian dimasukkan ke dalam model output daya PV [1].

Prediksi daya PV dilakukan dengan mengacu dari beberapa penelitian sebelumnya berdasarkan parameter *Input* dan metode yang digunakan. Ada banyak metode untuk mendapatkan hasil prediksi yang diinginkan. Metode cerdas diusulkan dalam tesis ini untuk memprediksi daya PV satu hari ke depan. Banyak metode yang telah digunakan pada penelitian sebelumnya berguna untuk prediksi keluaran daya PV, karena keluaran daya PV dipengaruhi oleh beragam variabel, seperti radiasi matahari, suhu sekitar, suhu panel surya, *humidity*, kecepatan angin, curah hujan, sudut kemiringan panel, dan *azimuth*.

Nilai radiasi matahari sangat beragam yang sangat mempengaruhi keluaran daya PV, banyak penelitian fokus pada prediksi radiasi matahari dengan menggunakan informasi cuaca historis. Radiasi matahari yang diramalkan kemudian dikonversi menjadi keluaran daya PV, menggunakan data pabrikan untuk panel surya. Teknik-teknik ini termasuk metode deret waktu. Metode *Artificial Neural Network* (ANN), metode fuzzy logic, dan metode berbasis wavelet. Studi lain secara langsung memperkirakan langsung daya keluaran PV, menggunakan data deret waktu historis dan informasi cuaca terkait [2].

Metode *Elman Neural Networks* dapat digunakan untuk semua masalah klasifikasi dan peramalan, tetapi mengharuskan pengguna untuk menentukan berbagai parameter model, terutama yang terkait dengan topologi jaringan [3]. ENN dapat digunakan juga untuk prediksi pembangkit listrik dari sistem PV yang terhubung ke jaringan. Ketersediaan data meteorologi dan kinerja terukur dari sistem PV saat ini dapat berguna sebagai dataset untuk memperkirakan *output* sistem PV surya dengan akurasi yang wajar, berguna dalam mengelola sistem tenaga listrik untuk memenuhi kebutuhan daya. Peramalan energi dapat digunakan untuk memenuhi kebutuhan daya dan juga digunakan untuk mempelajari kinerja sistem PV dibawah kondisi iklim berbeda [4].

Studi kasus pada tesis ini yaitu di Q Big Mall BSD City, Tangerang Banten. Kapasitas pembangkit PV terpasang adalah 780 kWp sistem *on-grid*. Prediksi daya menggunakan ANN yaitu *Elman Neural Network* (ENN) dan *FeedForward Neural Network* (FFNN). Keduanya akan digunakan dan dilakukan analisa perbandingan hasil dari masing-masing ENN dan FFNN. Hasil prediksi daya keluaran PV akan dibandingkan dengan data aktual keluaran PV, algoritma *Levenberg-marquardt* akan digunakan untuk selama proses *training* dari deret waktu daya PV produksi dan variabel suhu dan radiasi matahari yang terukur digunakan sebagai *Input NN*. Beberapa ukuran kesalahan statistik dievaluasi untuk memperkirakan akurasi metode peramalan.

1.2 Rumusan Masalah

Permasalahan yang dibahas pada tesis ini adalah:

1. Bagaimana implementasi *Elman Neural Network* dan *Feedforward Neural Network* pada prediksi daya keluaran PV dengan mempertimbangkan kondisi cuaca?
2. Bagaimana perbandingan antara data aktual keluaran daya PV dengan hasil prediksi daya PV menggunakan *Elman Neural Network* dan *FeedForward Neural Network*?
3. Bagaimana implementasi manajemen energi pada sistem berdasarkan hasil prediksi daya keluaran PV untuk pembangunan PV kedepannya?

1.3 Tujuan

Tujuan yang ingin dicapai dalam penelitian ini yaitu dapat membuat manajemen energi pada sistem dengan mengimplementasikan hasil prediksi daya keluaran PV berdasarkan kesalahan *error* rata-rata terkecil antara *Elman Neural Networks* dan *Feedforward Neural Network* dari Q Big Mall BSD City, Tangerang Banten, dan kemudian dapat dibuat pertimbangan pada pembangunan pembangkit PV selanjutnya.

1.4 Batasan Masalah

Batasan masalah dalam penelitian ini adalah sebagai berikut:

1. Sistem *Rooftop PV* yang digunakan adalah tipe *on-grid* dimana langsung terinterkoneksi dengan jaringan PLN, dan merupakan tipe *Commercial* dengan kapasitas 780 kWp.
2. Lokasi pemasangan pembangkit PV ini di Q Big Mall BSD City, Tangerang Banten, dibawah *project* PT. SUN (Sinarmas Land).
3. Variabel *Input* simulasi yang digunakan hanya radiasi matahari, suhu sekitar, suhu PV, daya keluaran PV sehari sebelum.
4. Prediksi daya PV menggunakan *Elman Neural Network* dan *FeedForward Neural Network* dan dilakukan hanya 12 jam dimulai dari jam 7 pagi sampai dengan jam 6 sore.
5. Algoritma yang digunakan saat proses *training* menggunakan *Levenberg-marquard*.
6. Perbandingan data kausal daya keluaran PV dengan prediksi daya PV digunakan untuk analisis manajemen energi pada sistem.
7. Tidak mempertimbangkan biaya operasional.

1.5 Kontribusi

Kontribusi dari penelitian ini yaitu metode NN yang digunakan dalam tesis ini nantinya dapat menjadi acuan dalam membuat sistem manajemen energi untuk pembangunan pembangkit PV kedepannya dengan melakukan peramalan daya keluaran PV terhadap kondisi cuaca dengan mempertimbangkan dari data aktual keluaran PV.

BAB 2

KAJIAN PUSTAKA

Bab ini secara garis besar akan dijelaskan tentang manajemen sistem energi untuk pembangkit PV tipe *on grid* menggunakan *Elman Neural Network* dan *Feed Forward*. Secara lebih rinci terdapat sub bab yang terkait dengan kajian pustaka. Pada sub bab 2.1 menjelaskan kajian penelitian terkait, pada 2.2 akan dijelaskan landasan teori yang berkaitan dengan penelitian, untuk sub bab 2.2 ini, nantinya terdapat bagian-bagian yang menjelaskan apa saja parameter terkait sehingga dapat dideskripsikan dengan persamaan yang ada.

2.1 Kajian Penelitian Terkait

Beberapa penelitian telah dilakukan untuk meramalkan daya keluaran PV dengan berbagai metode menggunakan *Artificial Intelligence* untuk mengatasi masalah *intermittent* sehingga dapat memperkirakan daya untuk hari selanjutnya. Seperti yang telah dilakukan pada [1] meramalkan daya PV menggunakan metode statistik dengan mempertimbangkan kondisi cuaca, pada penelitian ini sistem fotovoltaik terhubung ke jaringan dan meramalkan daya keluaran PV pada aspek yang berbeda. Selanjutnya pada penelitian [3] melakukan metode *Hybrid* berbasis cuaca untuk peramalan *output* daya PV setiap hari dan hari selanjutnya bertujuan untuk mengurangi kemungkinan dampak negatif dari sistem fotovoltaik (PV) yang merupakan fungsi penting dalam pengoperasian sistem manajemen energi untuk sumber daya energi yang didistribusikan.

Penelitian [2] melakukan peramalan per jam satu hari ke depan untuk pembangkit listrik fotovoltaik menggunakan metode *Artificial Intelligence* dengan model peramalan berbasis cuaca untuk mengatasi kemungkinan fluktuasi pembangkit listrik PV. Selanjutnya pada [5] melakukan penelitian prediksi daya PV menggunakan regresi linier berganda, regresi logaritmik, regresi polinomial dan metode *artificial neural network* berdasarkan data tahun sebelumnya (Januari 2014 – Desember 2014) untuk pembuatan model peramalan. Model tersebut kemudian dibandingkan dengan data aktual untuk meramalkan keluaran daya PV.

Referensi [6] prediksi daya keluaran PV 3 hari ke depan menggunakan radiasi matahari menggunakan *Elman Neural Network* dengan memasukkan hubungan daya PV dengan radiasi matahari, suhu, kelembaban, dan data kecepatan angin. Pada [7] melakukan studi perbandingan antara sistem *adaptive neuro-fuzzy inference* dan *FeedForward Neural Network* untuk suhu satu jam ke depan dan estimasi radiasi matahari menggunakan data masukan yang berbeda. Dua dan empat jam ke depan peramalan data meteorologi dilakukan dengan menggunakan model *FeedForward Neural Network*.

Referensi terkait [1]–[3], [5]–[7], perbedaan tesis ini dengan penelitian sebelumnya adalah prediksi daya keluaran PV menggunakan dua tipe *Neural Network* yaitu *Elman Neural Network* dan *Feedforward Neural Network* dengan fungsi aktivasi *training* yang sama yaitu *Levenberg-Marquardt*. Hasil dari prediksi daya PV yang didapatkan akan dibandingkan dengan data aktual kemudian akan dilakukan analisa untuk manajemen energi pada sistem pembangunan pembangkit PV kedepannya sehingga pengoperasian sistem akan efisien untuk sumber daya energi yang didistribusikan. Oleh karena itu penulis tertarik melakukan penelitian dengan judul “Prediksi Daya Pembangkit Listrik PV satu hari ke depan untuk memudahkan manajemen energi pada sistem menggunakan *Neural Network*”.

2.2 Teori Dasar

2.2.1 Solar Photovoltaic (PV) System / Pembangkit Listrik Tenaga Surya


Pembangkit listrik tenaga surya melibatkan pembangkitan listrik dari energi matahari yang bebas dan tidak ada habisnya. Keuntungan utama dari sistem PV adalah [8];

- a. Sifat berkelanjutan dari energi surya sebagai bahan bakar
- b. Pengaruh ke dampak lingkungan sedikit
- c. Pengurangan secara signifikan pada tagihan pelanggan, karena ketersediaan sinar matahari
- d. Umur dari modul PV lebih kurang 30 tahun dengan pemeliharaan minimum, dan;
- e. *silent operation*

Sel PV digunakan untuk membuat modul PV yang kemudian dapat digunakan membuat *array* PV, yang merupakan komponen utama dari sistem PV yang terhubung ke jaringan.

Sistem PV dalam skala kecil dapat diterapkan dalam berbagai cara, sistem yang terhubung ke jaringan perumahan merupakan konfigurasi yang paling relevan untuk ruang lingkup pada tesis ini. Dalam sistem ini, setiap kelebihan energi yang diproduksi akan dimasukkan ke dalam *grid* (jaringan PLN).

Pada gambar 2.1 dan 2.2 menggambarkan fungsi sistem PV dan struktur dasar yang diperlukan (*array* PV, Inverter, meteran, pengontrol, dan perangkat listrik) yang memungkinkan interaksi efektif dan aman dengan jaringan listrik[9].




Gambar 2.1 Skematik sistem fotovoltaik yang terhubung ke jaringan [9]

2.2.2 Artificial Neural Network

Teknik ANN didasarkan pada jaringan saraf, yang mana antar neuron saling terhubung oleh synapses. Setiap synapses ditandai dengan bobotnya sendiri, yang menentukan caranya *output* dari neuron yang dipengaruhi oleh dari masing-masing masukan. Kemudian inti melakukan jumlah yang tertimbang dari *Input* sinyal dan mengirim respons, seperti impuls listrik, ke neuron lainnya[1].

ANN akan mensimulasikan sebagian dari sistem saraf, yang mana nanti *Input* akan diubah dengan bobot, dijumlahkan dan diterapkan dalam fungsi tertentu, dan *output* adalah sinyal *Input* untuk neuron lain didalam jaringan tersebut. Selama pelatihan bobot akan terus disesuaikan untuk mendapatkan akurasi yang telah ditentukan. Gambar di bawah ini menjelaskan struktur bentuk neural network.




Gambar 2.2 Struktur Neural Network

Proses pelatihan ANN pada dasarnya yaitu ketika neuron dilapisan tersembunyi menerima jumlah tertimbang dari *Input* dan mengubahnya menjadi *node* keluaran dengan menerapkan fungsi aktivasi. Setelah struktur ANN diterapkan, proses pelatihan berlangsung hingga menemukan bobot yang meminimalkan kesalahan seperti *mean square error* (MSE). Ada sejumlah metode pelatihan seperti *Backpropagation* (BP), *Leveberg-Marquardt* (LM) dan Gauss-Newton [10]

2.2.2.1 *Elman Neural Network*

Elman NN (Elman,1990) merupakan RNN tiga lapis dengan koneksi umpan balik waktu tunda internal di lapisan tersembunyi, dimana setiap neuron tersembunyi memiliki unit waktu tunda yang sesuai.


Koneksi berulang memungkinkan unit waktu tunda untuk menyimpan informasi neuron tersembunyi ini sebagai *Input* tambahan untuk semua neuron tersembunyi pada langkah-langkah waktu berikutnya. Oleh karena itu, Elman NN memiliki memori dinamis yang *inherent* diberikan oleh koneksi berulang dari unit waktu tunda, dan *outputnya* tidak hanya bergantung pada informasi saat ini tapi juga pada keadaan sebelumnya. Dalam penelitian ini, Elman NN juga dilatih oleh algoritma *Backpropagation* yaitu *Leveberg-Marquardt*, dan fungsi transfer lapisan tersembunyi dan output masing-masing adalah tipe sigmoid dan linier [10]. Struktur elman neural network diilustrasikan pada gambar 2.3.



Gambar 2.3 Struktur umum *Elman Neural Network* [11]

2.2.2.2 *Feedforward Neural Network*


Feedforward Neural Network merupakan fungsi *Input* nonlinear, yang merupakan komposisi dari fungsi neuronnya. Seperti yang diilustrasikan Gambar 2.4, informasi berjalan melalui neuron yang terhubung hanya dalam arah pengiriman, dari *Input* ke *output*. Secara grafis, *node* adalah neuron dan *edge* adalah koneksi/penghubung; jenis jaringan ini tidak memiliki *back-loop*. Istilah koneksi diambil secara metaforis karena perhitungan oleh masing-masing neuron diimplementasikan sebagai program perangkat lunak (*software*) [9].



Gambar 2.4 Struktur *FeedForward Neural Network*

2.2.3 Fungsi Aktivasi

Neuron buatan tersusun dari jumlah blok yang terhubung ke fungsi transfer. *Input* dari jumlah blok merupakan vektor yang dikalikan dengan bobot (*weight*) koresponden dan bias. Setelah di jumlah, hasilnya disebut net *Input*, masuk ke fungsi transfer, dan hasil yang dihasilkannya itu disebut *neuron output*. Fungsi transfer ini tergantung pada spesifikasi dari masalah yang akan diselesaikan oleh *neuron* dan bisa *Linier* atau *non-Linier*. Gambar 2.4 a,b,c, dan d menunjukkan bentuk grafik fungsi transfer.




Gambar 2.5 (a-c) Contoh dari Fungsi Transfer[12]

Fungsi aktivasi *purelinier* merupakan fungsi yang membuat *linier* setiap input menjadi nilai liniernya, yang mana nilai masukannya akan sama dengan nilai dari keluarannya itu sendiri $y = x$. Fungsi *sigmoid biner* atau aktivasi *logsig* merupakan fungsi yang menghasilkan nilai outputnya antara 0 dan 1 yaitu dari nilai negatif ke positif, sedangkan pada matlab lebih dikenal fungsi *logsig*. Fungsi aktivasi *tansig*

merupakan *sigmoid tangen* yang mana menghasilkan nilai keluaran antar 1 dan -1. Pada matlab dikenal dengan fungsi *tansig* [12].

2.2.4 Forecasting atau Peramalan

Peramalan bertujuan untuk mengurangi ketidakpastian keluaran daya PV sehingga operator daya akan dapat mengakomodasi variabilitasnya. Gambar 2.5 dibawah ini menggambarkan perbedaan antara variabilitas dan ketidakpastian.



Gambar 2.6 Perbedaan antara PV aktual dan Prediksi PV [13]

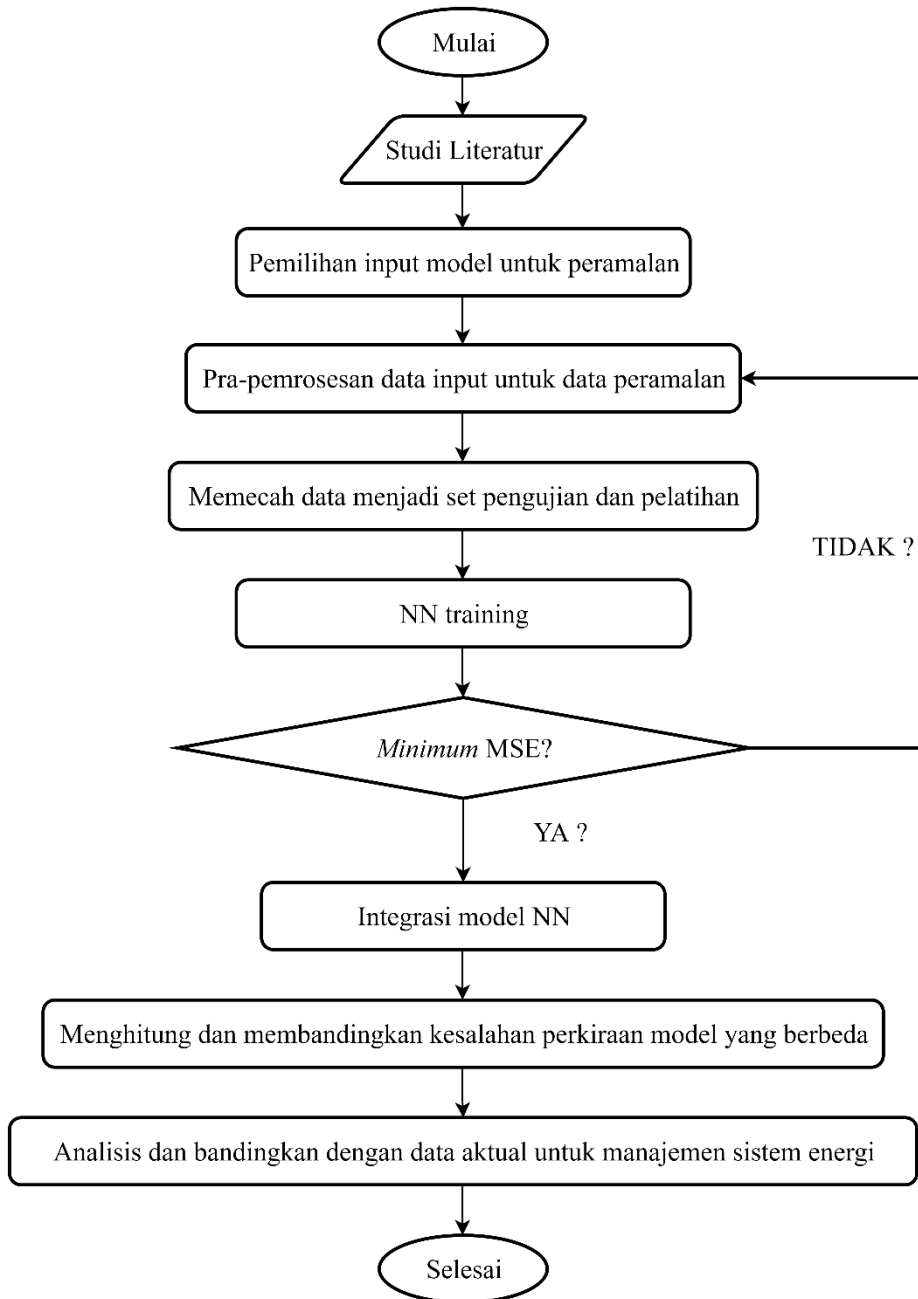
Dari gambar di atas dapat dilihat panah biru merupakan selisih dari variabilitas dan ketidakpastian. Prediksi radiasi matahari adalah *input* mendasar untuk berbagai aplikasi surya. Banyak faktor seperti radiasi matahari dan kondisi cuaca dapat mempengaruhi keluaran sistem PV. Jadi untuk memungkinkan integrasi yang baik, andal dan aman dari sistem PV ke jaringan, sangat penting untuk siap pada setiap perubahan mendadak dalam keluaran PV karena karakteristik tenaga surya yang dapat berubah dan acak. Oleh karena itu, peramalan yang akurat diperlukan. Peramalan matahari dapat dievaluasi untuk horizon waktu yang berbeda. Perkiraan jangka pendek dimulai dari satu jam hingga beberapa jam ke depan. Perkiraan jangka menengah adalah dari beberapa jam hingga satu minggu ke depan. Perkiraan jangka Panjang dari satu minggu ke beberapa tahun ke depan[13].

Halaman ini sengaja dikosongkan

BAB 3

METODE PENELITIAN

Pada bab ini berisikan tentang metodologi dari penelitian yang akan dilakukan. Penelitian yang diusulkan akan melalui beberapa tahapan yang digambarkan pada Gambar 3.1. Diagram alir penelitian.



Gambar 3.1 Diagram Alir Penelitian

Gambar 3.1 dapat dilihat langkah-langkah tahapan penelitian yang dimulai dari studi literatur dengan mencari referensi-referensi dari penelitian sebelumnya. Penelitian sebelumnya diperlukan untuk menjadi acuan penelitian yang akan dilakukan. Studi literatur pada penelitian ini juga meliputi pengambilan data langsung ke PT. Sinarmas Land, yang akan diprediksi merupakan daya keluaran PV dengan menggunakan *Artificial Neural Network (ANN)*.

Model ini diimplementasikan dengan MATLAB @2018a *Neural Networks Toolbox*, yang memfasilitasi pemahaman fungsi dari ANN, tetapi pada akhirnya, penulis membutuhkan waktu untuk belajar dengan mekanisme *neural network* dan beberapa pengetahuan serta pengalaman menangani *dataset* dan fungsi komputasi. Sebelum dilakukan analisis dari hasil prediksi yang didapatkan, maka akan dikalkulasikan dan dibandingkan kesalahan perkiraan model yang berbeda, dan tahapan terakhir dapat ditarik kesimpulan dari penelitian yang telah dilakukan, untuk lebih jelas akan dijelaskan pada sub bab berikut.

3.1 Studi Literatur

Pada tahap ini akan dilakukan pengumpulan data, dan untuk merancang model peramalan *neural network* membutuhkan beberapa langkah berbeda karena melibatkan pemilihan banyak variabel dan parameter. Desain yang sukses dapat tercapai jika masalahnya ditentukan dan dipahami dengan jelas. Dengan demikian, dalam penelitian ini, pemilihan variabel yang dapat diyakini bisa secara langsung atau tidak langsungnya dipengaruhi oleh pergerakan awan.

Lokasi penelitian ini berada di Q Big Mall BSD City, Tangerang Banten, dibawah *project* PT. SUN (Sinarmas Land). memiliki 2400 modul PV silicon merk Trina Solar tipe *polycrystalline* 325 Wp, dan total yang terpasang 780 kWp. Inverter merk Huawei SUN 36KTL, data akan terlampir pada bab **Lampiran**.

3.2 Data Input dan Metode Perhitungan


Oleh karena itu, *input* dasar yang dipilih adalah rangkaian waktu dari suhu sekitar dan radiasi matahari, dan data sistem PV dari PT. Sinarmas Land. Sebagai parameter untuk data yang akan dimasukkan dan *output* yang diinginkan akan dijelaskan pada tabel 3.1.

Tabel 3.1 Parameter variabel *Input*

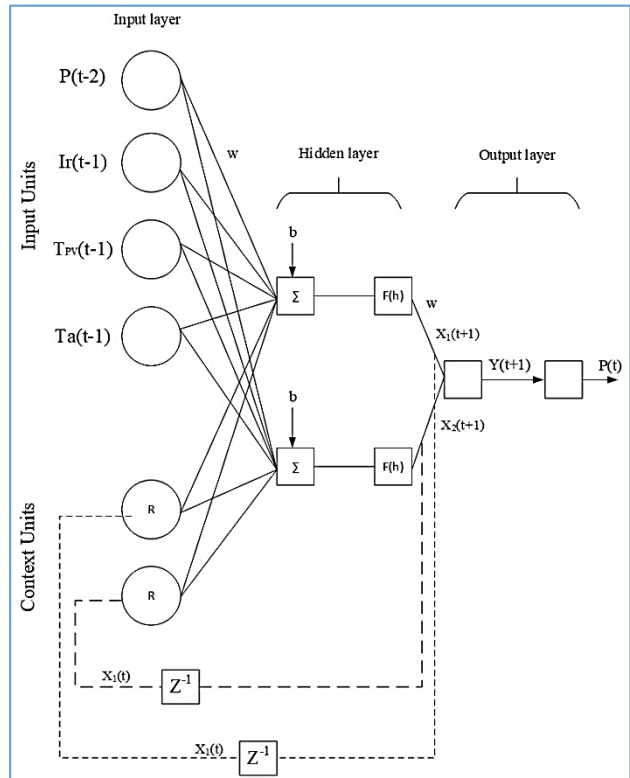
Percobaan	<i>Input</i>	Satuan	<i>Target</i>
Percobaan I	Daya PV 1 hari sebelum	kW	Daya PV saat ini
	Radiasi Matahari saat ini	W/m ²	
	Suhu Sekitar (Ambient) saat ini	°C	
	Suhu Modul PV saat ini	°C	
Percobaan II	Daya PV 2 hari sebelum	kW	Daya PV saat ini
	Radiasi Matahari 1 hari sebelum	W/m ²	
	Suhu Sekitar (Ambient) 1 hari sebelum	°C	
	Suhu Modul PV 1 hari sebelum	°C	
Percobaan III	Daya PV saat ini	kW	Daya PV 1 hari ke depan
	Radiasi Matahari 3 hari sebelum	W/m ²	
	Suhu Sekitar (Ambient) 3 hari sebelum	°C	
	Suhu Modul PV 3 hari sebelum	°C	

Dari tabel 3.1, dapat digambarkan struktur dari masing-masing *neural network*, pada gambar 3.2 a, b, dan c merupakan ilustrasi percobaan I,II dan III menggunakan *elman neural network* dengan parameter sesuai dari tabel 3.1, dengan 4 *input* variabel dan waktu yang berbeda. Pada percobaan 1, jumlah *hidden layer* 2 , dengan masing-masing *hidden layer* memiliki bobot 50, dan 50. Percobaan 2 memiliki jumlah *hidden layer* 2, dengan masing-masing *hidden layer* memiliki bobot 45, dan 45. Percobaan 3 memiliki 2 *hidden layer* yang berbeda nilai bobot pada masing-masing layer, yaitu 50 dan 45. Percobaan I dan II memiliki output yang sama yaitu daya PV saat ini, sedangkan pada percobaan III, daya PV 1 hari kedepan.


(a) Percobaan I ENN




(b) Percobaan II ENN




(c) Percobaan III ENN




Gambar 3.2. (a). Struktur Percobaan I ENN, (b). Struktur Percobaan II ENN, dan (c) Struktur Percobaan III ENN.



(a) Percobaan I



(b) Percobaan II



(c) Percobaan III

Gambar 3.3(a). Struktur Percobaan I FFNN, (b). Struktur Percobaan II FFNN, dan (c) Struktur Percobaan III FFNN.

Gambar 3.3. a,b, dan c merupakan ilustrasi percobaan I,II, dan III menggunakan *feedforward neural network* sesuai pada tabel 3.1 dengan 4 *input* variabel dan waktu yang berbeda.

Analisis deret waktu dari data harian berikut (dikumpulkan setiap 1 jam) yaitu daya PV (W), suhu modul °C, suhu sekitar °C, dan radiasi matahari (W/m²). Data deret waktu yang digunakan dalam waktu 6 bulan sejak PV terpasang. Sedangkan untuk input pada *training* akan dipakai data 3 Minggu, yaitu pada tanggal 22 Maret 2019, terhitung sejak PV terpasang sampai dengan 2 April 2019. Untuk data *testing* akan dipilih 1 minggu setelahnya. Waktu horizons diambil selama 12 jam untuk perkiraan dimulai dari jam 7 dan berakhir pada jam 6 sore.

Persamaan 3.1 merupakan rata-rata *interval* per jam dari tiap 10 menit yang dihasilkan dari keluaran daya PV berdasarkan kondisi *real*. Untuk nilai rata-rata daya $P_m(i)$ yang diproduksi oleh pembangkit PV dalam 60 menit sebelumnya masing-masing untuk i-jam [1].

$$P_m(i) = \frac{1}{6} \sum_{t=i-50}^i P(t), \quad i = 1, \dots, 8760 \quad (3.1)$$

Keterangan:

$P_m(i)$ = nilai rata-rata daya dari PV dalam 60 menit sebelumnya masing-masing untuk i-jam

nilai rata-rata per jam dari radiasi di dataran pada sudut kemiringan modul (W/m²).
dan bentuk umum vektor input sebagai berikut:

$$x(i) = [I(i); P_{bulanan}(i)] \quad (3.2)$$

Keterangan:

$x(i)$ = vektor *input*

$I(i)$ = nilai rata-rata per jam dari radiasi (W/m²)

nilai rata-rata per jam dari suhu modul (°C), suhu sekitar (°C), dan irradiansi (W/m²)

$$x(i) = [T_m(i); T_a(i); I(i); P_{bulanan}(i)] \quad (3.3)$$

Keterangan:

$T_m(i)$ = nilai rata-rata per jam dari suhu modul ($^{\circ}$ C),

$T_a(i)$ = nilai rata-rata per jam dari suhu sekitar ($^{\circ}$ C)

target yang digunakan untuk mengevaluasi prediksi model, diberikan oleh $P_t(i, l)$, jumlah rata-rata daya per jam $P_{bulanan}(r)$ selama horizons waktu perkiraan l , didefinisikan sebagai :

$$P_t(i, l) = \sum_{r=i+1}^{i+l} P_m(r) \quad (3.4)$$

Keterangan:

$P_t(i, l)$ = Target daya PV

$P_m(r)$ = jumlah rata-rata daya per jam $P_m(r)$ selama interval waktu perkiraan l

untuk meminimalkan kesalahan kuadrat rata-rata yang didefinisikan sebagai berikut:

$$RMSE = \sqrt{\frac{1}{M} \sum_{k=1}^M (P_t(k) - T(k))^2} \quad (3.5)$$

Keterangan:

$P_t(k)$ = target daya PV

$T(k)$ = keluaran daya yang diprediksi untuk setiap *node* keluaran k .

untuk penjabaran yang akurat dari nilai yang terukur maka diperlukan untuk pemeriksaan atau pengecekan, setiap bulan, hari-hari dimana parameternya yang tidak cocok. Selanjutnya nilai riil semua data dinormalisasikan kisaran $[-1, 1]$. Tiga vektor input yang berbeda digunakan untuk pelatihan ANN, sedangkan keakuratan akurasi prediksi akan dievaluasi dengan mempertimbangkan dari matriks berikut [1]:

Kesalahan normalisasi

$$E_i(l) = \frac{P_t(i, l) - T(i, l)}{\text{Max}_{i=1}^M(P_t(i, l))} \quad (3.6)$$

Keterangan :

$E_i(l)$ = error normalisasi

$P_t(i, l)$ = target daya PV

$T(i, l)$ = keluaran daya PV untuk setiap jam

$Max_{i=1}^M(P_t(i, l))$ = Maksimum nilai dari masing-masing target dan keluaran

Kesalahan absolut rata-rata (%)

$$NMBE(l) = \left(\frac{1}{M} \sum_{i=1}^M |E_i(l)| \right) * 100 \quad (3.7)$$

Keterangan:

$NMBE(l)$ = error absolut rata-rata (%)

$\frac{1}{M} \sum_{i=1}^M |E_i(l)|$ = jumlah dari prediksi daya PV dikalikan absolut dari error normalisasi


3.3 Pengolahan Data

Observasi data yang hilang dapat ditangani dengan berbagai cara. Pada tesis ini, semua observasi data tersebut dianggap sebagai nilai *Not-a-Number* (NaN), yang merupakan fungsi yang mempertimbangkan angka yang tidak ditentukan dan diabaikan oleh *Artificial Neural Network*. Selain itu, *outlier* dihapus dengan menghitung rata-rata perpindahan 10 poin (rata-rata antara lima langkah berikutnya dan lima langkah sebelumnya dari observasi itu). Untuk menyelesaikan pemrosesan data, deret waktu dinormalisasi antara 0 dan 1 karena setiap dataset memiliki besaran yang berbeda dan mengubahnya menjadi ukuran pada umumnya., dan itu didefinisikan dengan persamaan 3.9 [9].

3.3.1 Elman Neural Network (ENN)


a. Percobaan I ENN

Percobaan I menggunakan variasi *input* berbeda berdasarkan tabel 3.1 dan ilustrasi input seperti pada gambar 3.2.(a), *training* dimulai dari tanggal 21 Maret 2019 sampai 2 April 2019. Berikut merupakan proses *training* dari data *input*, pada proses *training* ini struktur NN meliputi 2 *hidden layer* yang masing-masing 50 dan 50 neuron, dan target *error* $1e^{-8}$ seperti yang ditunjukkan pada gambar 3.3.



Gambar 3.4. Training Elman Neural Network Percobaan I


b. Percobaan II ENN



Gambar 3.5. Training Elman Neural Network Percobaan II

Percobaan II menggunakan variasi *input* berbeda berdasarkan tabel 3.1 dan ilustrasi input seperti pada gambar 3.2.(b), *training* dimulai dari tanggal 21 Maret 2019 sampai 2 April 2019. Berikut merupakan proses *training* dari data *input*, pada proses *training* ini struktur NN meliputi 2 *hidden layer* yang masing-masing 50 dan 50 neuron, dan target *error* $1e^{-6}$ seperti yang ditunjukkan pada gambar 3.4.

c. Percobaan III ENN




Gambar 3.6 Training Elman Neural Network Percobaan III

Percobaan III menggunakan variasi *input* berbeda berdasarkan tabel 3.1 dan ilustrasi input seperti pada gambar 3.2.(b), *training* dimulai dari tanggal 21 Maret 2019 sampai 2 April 2019. Berikut merupakan proses *training* dari data *input*, pada proses *training* ini struktur NN meliputi 2 *hidden layer* yang masing-masing 45 dan 50 neuron, dan target *error* $1e^{-6}$ seperti yang ditunjukkan pada gambar 3.4.

3.3.2 Feedforward Neural Network

a. Percobaan I FFNN




Gambar 3.7 Training Feed Forward Neural Network Percobaan I


Percobaan I menggunakan variasi *input* berbeda berdasarkan tabel 3.1 dan ilustrasi input seperti pada gambar 3.3.(a), *training* dimulai dari tanggal 21 Maret 2019 sampai 2 April 2019. Berikut merupakan proses *training* dari data *input*, pada proses *training* ini struktur NN meliputi *single hidden layer* 129 neuron, dan target *error* $1e^{-6}$ seperti yang ditunjukkan pada gambar 3.7.

b. Percobaan II FFNN

Percobaan II menggunakan variasi *input* berbeda berdasarkan tabel 3.1 dan ilustrasi input seperti pada gambar 3.3.(b), *training* dimulai dari tanggal 21 Maret 2019 sampai 2 April 2019. Berikut merupakan proses *training* dari data *input*, pada proses *training* ini struktur NN meliputi *single hidden layer* 110 neuron, dan target *error* $1e^{-6}$ seperti yang ditunjukkan pada gambar 3.8.



Gambar 3.8. Training Feed Forward Neural Network Percobaan II



Gambar 3.9. Training Feed Forward Neural Network Percobaan III

c. Percobaan III FFNN

Percobaan III menggunakan variasi *input* berbeda berdasarkan tabel 3.1 dan ilustrasi input seperti pada gambar 3.3.(c), *training* dimulai dari tanggal 21 Maret 2019 sampai 2 April 2019. Berikut merupakan proses *training* dari data *input*, pada proses *training* ini struktur NN meliputi *single hidden layer* 100 neuron, dan target *error* $1e^{-6}$ seperti yang ditunjukkan pada gambar 3.9.

3.4 Pelatihan (*training*), Pengujian (*testing*) , dan Validasi

Sebelum NN diaktifkan, rangkaian waktu dibagi menjadi 3 set yang berbeda: pelatihan, pengujian dan set validasi. Umumnya pada set pelatihan ini lebih besar bobot data yang di *input* kedalam data pelatihan karena pola dalam deret waktu dari data tersebut membutuhkan proses pembelajaran. Untuk pengujian biasanya berkisar dalam ukuran dari 10% hingga 30% dari data pelatihan dan mengevaluasi kemampuan generalisasi dari jaringan yang terlatih. Evaluasi akhir dari kinerja *network* diselesaikan menggunakan set validasi.

3.5 Integrasi Model Neural Networks

Skenario berbeda berikut diterapkan untuk membantu memilih arsitektur jaringan terbaik dan untuk mempelajari dampak penggunaan variasi variabel eksogen atau variabel yang memiliki pengaruh terhadap variabel lain, tapi tidak dipengaruhi oleh variabel lain dalam model. Pada tesis ini ada 2 skenario dengan tipe *Neural Network* yang berbeda, yaitu *Elman Neural Network* dan *Feedforward Neural Network*. Dan masing-masing kedua algoritma menggunakan fungsi aktivasi pada set pelatihan *training Lavenberg-Marquardt* ('trainlm'), untuk fungsi aktivasi *hidden layer* menggunakan *sigmoid biner* yaitu ('logsig'), sedangkan pada *output* menggunakan fungsi aktivasi linier ('purelin').

Nilai yang diberikan untuk jumlah *neuron* dan *hidden layer* berdasarkan percobaan yang telah diuji sebelumnya, dan sub bab selanjutnya akan menampilkan input nilai variabel berdasarkan *trial* dan *error* sehingga nilai variabel yang mendekati di ambil dari banyak percobaan, hanya 3 yang digunakan dalam tesis ini.

3.6 Sistem Manajemen Energi

Menerapkan strategi manajemen energi pada sistem PV *on grid* adalah wajib untuk memenuhi permintaan konsumen, dan manajemen aliran daya sangat penting untuk memastikan sistem ini bekerja dengan baik dan aman, pada bab ini manajemen sistem berdasarkan analisis dari hasil prediksi dan data aktual akan dibandingkan dan diperhitungkan kesalahan perkiraan dari model yang berbeda. Selanjutnya hasil kesalahan yang telah didapat akan dipertimbangkan, dan bisa menjadi acuan untuk sistem manajemen energi pada pembangkitan PV selanjutnya.


BAB 4

HASIL DAN PEMBAHASAN


4.1 Hasil Simulasi menggunakan Elman Neural Network

4.1.1 Percobaan I menggunakan *Elman Neural Network*

Gambar 4.1 merupakan hasil *training* dengan durasi waktu 0:20:08, dengan *Input* berdasarkan tabel 3.1 dan *Input error max* yang digunakan adalah $1e^{-8}$, berdasarkan struktur gambar dari 3.2(a), set pelatihan dilakukan dari 22 Maret 2019 – 2 April 2019.



Gambar 4.1 Hasil *training* Simulasi Prediksi Menggunakan *Elman Neural Network* pada Bulan Maret -April 2019

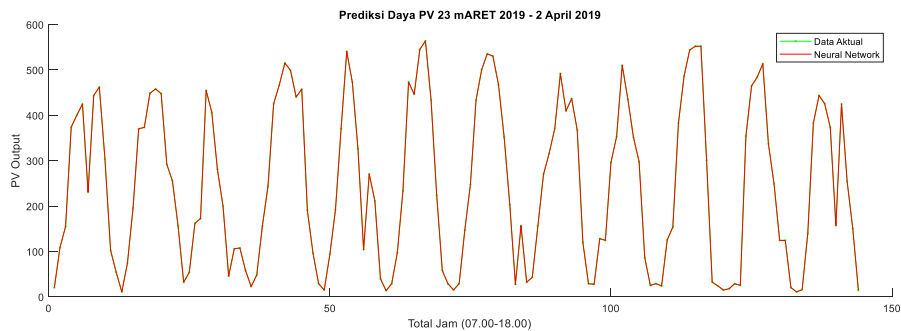


Gambar 4.2 Hasil *Testing* 2 hari 3-4 April 2019

hasil *training* dengan *Input* percobaan I, maka dilakukan pengujian selama 2 hari yaitu 3-4 April 2019, gambar 4.2 merupakan hasil *testing* selama 2 hari tersebut. Dari hasil training tersebut didapatkan *error* MSE sebesar $1.1797e+5$, dari nilai *error* MSE yang didapat, bahwa percobaan 1 ini tidak sesuai dengan data aktual.

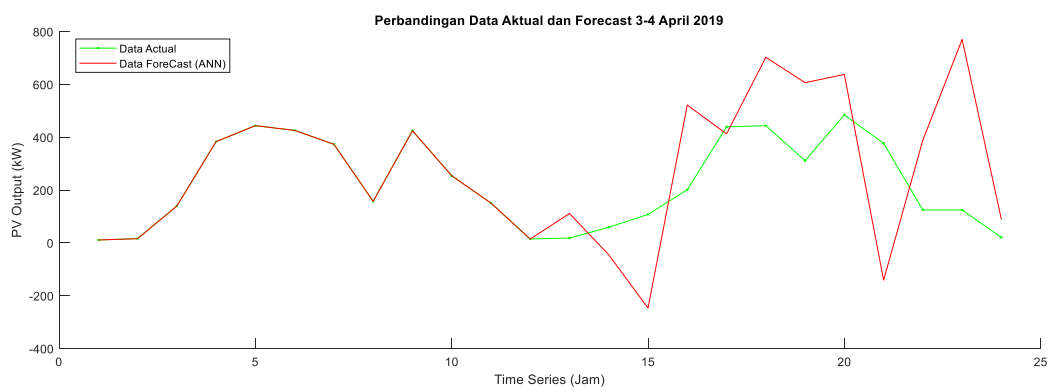
4.1.2 Percobaan II menggunakan *Elman Neural Network*

Berikut merupakan hasil prediksi menggunakan *Elman Neural Network*, gambar 4.3 merupakan hasil *training* dengan durasi waktu 0:44:31. Dengan *Input* berdasarkan tabel 3.1 dan *Input error* max yang digunakan adalah $1e^{-6}$, berdasarkan struktur gambar dari 3.2(b), set pelatihan dilakukan dari 23 Maret 2019 – 2 April 2019. Gambar 4.4 merupakan hasil *training* berdasarkan tabel 3.1.



Gambar 4.3. *Training* 23 Maret 2019-2 April 2019


setelah didapatkan hasil *training*, maka dilakukan pengujian 2 hari yaitu 3-4 April 2019 ditunjukkan pada gambar 4, dari hasil percobaan II didapatkan *error* MSE sebesar $1.5227e+03$, dari nilai *error* MSE yang didapat, bahwa percobaan 2 ini tidak sesuai dengan data aktual.



Gambar 4.4 *Testing* selama 2 hari 3-4 April 2019

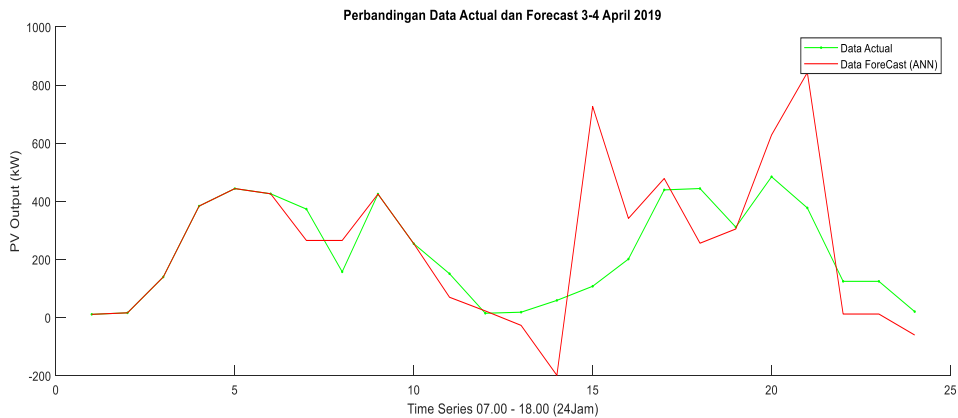
4.1.3 Percobaan III menggunakan *Elman Neural Network*

Gambar 4.5 merupakan hasil *training* dengan durasi waktu 0:20:33. Dengan *Input* berdasarkan tabel 3.1 dan *Input error max* yang digunakan adalah $1e^{-6}$, berdasarkan struktur gambar dari 3.2(c), set pelatihan dilakukan dari 23 Maret 2019 – 2 April 2019, gambar 4.6 merupakan hasil *testing*.



Gambar 4.5. *Training* 23 Maret 2019-2 April 2019

setelah didapatkan hasil *training*, maka dilakukan pengujian 2 hari yaitu 3-4 April 2019 ditunjukkan pada gambar 4.6 dan hasil *testing* akan ditampilkan pada tabel 4.6.



Gambar 4.6 *Testing* selama 2 hari 3-4 April 2019

dari hasil percobaan III didapatkan *error* MSE sebesar $6.5626e+04$, dari nilai *error* MSE yang didapat, bahwa percobaan III ini tidak sesuai dengan data aktual.

Berdasarkan percobaan menggunakan *Elman Neural Network* menggunakan fungsi *training Lavenberg-Marquardt* dari tabel 3.1, bahwa menggunakan Algoritma ENN dengan fungsi *training* tersebut tidak sesuai untuk


kasus pada tesis ini, karena dari 3 percobaan yang sudah di asumsikan dari berbagai kombinasi variabel *Input* berdasarkan penelitian sebelumnya dan yang telah dicoba oleh penulis, didapatkan *error* MSE yang cukup besar, sehingga tidak bisa dijadikan rekomendasi menggunakan algoritma tersebut, untuk itu penulis mencoba menggunakan algoritma *FeedForward Neural Network* berdasarkan percobaan pada penelitian sebelumnya yang sudah dijelaskan didalam kajian terkait pada bab 2.1. Penulis juga menggunakan acuan variabel dari tabel 3.1 untuk diuji ke dalam algoritma *FeedForward Neural Network*, berikut dijelaskan pada sub bab 4.2.

4.2 Hasil Training Simulasi menggunakan *FeedForward Neural Network*


Penulis melakukan perbandingan antara *Elman* dan *Feed Forward*, dapat dilihat pada poin sub bab sebelumnya bahwa hasil menggunakan *Elman* lebih besar didapatkan *error* nya, sedangkan menggunakan *feed forward* bisa didapatkan hasil yang diinginkan dengan *error* bervariasi sesuai batasan *error* yaitu -10% sampai +10% [1].

4.2.1 Percobaan I menggunakan *Feed Forward Neural Network*


Berikut merupakan hasil prediksi menggunakan *FeedForward Neural Network*, tabel 3.1 menjelaskan gambaran *Input* yang digunakan pada algoritma FFNN. Gambar 4.7 dapat dilihat hasil *training* menggunakan percobaan I dengan *Error* max yang digunakan pada percobaan I adalah $1e^{-6}$, dengan durasi waktu 0:08:01, gambar 4.7 merupakan hasil *Plottrainstate* dari *training* dilakukan dari 22 Maret 2019 – 12 April 2019. Percobaan dilakukan selama 3 minggu, dan untuk *testing* diambil seminggu setelahnya, dengan hasil gradient $1.8265e-05$, dan nilai MU sebesar $1e-09$ dengan iterasi 2267. Sedangkan pada gambar 4.8 adalah *best training performance*, pada $1e^{-5}$ grafik sudah stabil, namun diakhir mengalami penurunan, tetapi dari hasil regresi, dapat dilihat bahwa nilai regresi sudah mendekati 1, dimana nilai tersebut berarti sudah mendekati hasil dari data aktual, dapat dilihat pada gambar 4.9 merupakan regresi dari hasil target *training*, nilainya sudah mendekati 1 yaitu 0.9999.



Gambar 4.7 *Plottrainstate training FFNN*

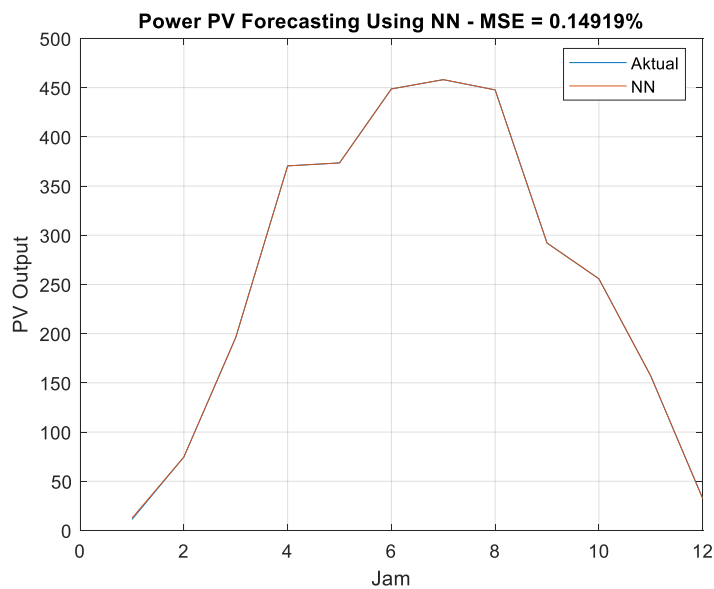


Gambar 4.8 *Performance FFNN Percobaan 1*




Gambar 4.9 Hasil target dari *training* Percobaan I

hasil target *training* yang mendekati dengan nilai aktual, selanjutnya dilakukan *testing* untuk mengetahui bentuk hasil prediksi menggunakan algoritma FFNN. *Testing* dilakukan pada hari ke 3 dan 4 bulan April 2019.



Gambar 4.10 Hasil percobaan I hari ke-3 pada bulan April 2019




Gambar 4.11 Hasil percobaan I hari ke-4 pada bulan April 2019


Hari 3 dan 4 FFNN percobaan I memiliki nilai error MSE 0.14919% dan 0.00031%, bahwa nilai tersebut sesuai batasan yang diperbolehkan. Untuk data masukan data aktual PV akan dilampirkan pada bab **Lampiran**.

4.2.2 Percobaan II menggunakan *Feed Forward Neural Network*


Pada percobaan II FFNN ini, dengan *Error max* yang digunakan training adalah $1e^{-6}$ dengan durasi waktu 0:23:50, gambar 4.12 merupakan hasil *Plottrainstate* dari *training* dengan hasil *gradient* adalah $1.9107e-05$, dan nilai MU sebesar $1e-09$ dengan iterasi 6306. Sedangkan untuk hasil *performance* dapat dilihat pada gambar 4.13 adalah *best training performance* pada $1e^{-6}$ grafik sudah stabil pada iterasi 6000, namun setelah lebih dari 6000 mengalami penurunan, tetapi hasil regresi pada percobaan II ini sudah mencapai nilai yang diinginkan yaitu 1, dimana hasil ini bisa digunakan untuk perhitungan pemilihan genset, hasil regresi ditunjukkan pada gambar 4.14.



Gambar 4.12 *Plottrainstate training* FFNN




Gambar 4.13 *Performance* FFNN Percobaan II




Gambar 4.14 Hasil target dari *training* Percobaan II

hasil target *training* yang mendekati dengan nilai aktual, selanjutnya dilakukan *testing* untuk mengetahui bentuk hasil prediksi menggunakan algoritma FFNN. *Testing* dilakukan pada hari ke 3 dan 4 bulan April 2019.



Gambar 4.15 Hasil percobaan II hari ke-3 pada bulan April 2019




Gambar 4.16 Hasil percobaan II hari ke-4 pada bulan April 2019


Hari 3 dan 4 pada FFNN percobaan II memiliki nilai error MSE 0.01471% dan 0.00097%, bahwa nilai tersebut sesuai batasan yang diperbolehkan. Untuk data masukan data aktual PV akan dilampirkan pada bab **Lampiran**.

4.2.3 Percobaan III menggunakan Feed Forward Neural Network


Pada percobaan III FFNN ini, dengan *Error max* yang digunakan training adalah $1e^{-5}$ dengan durasi waktu 0:02:59, gambar 4.17 merupakan hasil *Plottrainstate* dari *training* dengan hasil *gradient* adalah $2.4693e-05$, dan nilai MU sebesar $1e-09$ dengan iterasi 2284. Sedangkan untuk hasil *performance* dapat dilihat pada gambar 4.18 adalah *best training performance* pada $1e^{-5}$ grafik sudah stabil pada iterasi 2000, namun setelah lebih dari tetap stabil hingga *error max* tercapai, tetapi hasil regresi pada percobaan III ini sudah mendekati nilai yang diinginkan yaitu 0.99995, kurang 0,0005 untuk mencapai nilai 1, dimana hasil ini masih bisa digunakan untuk perhitungan pemilihan genset, hasil regresi ditunjukkan pada gambar 4.19.



Gambar 4.17. *Plottrainstate training* FFNN Percobaan III




Gambar 4.18 *Performance* FFNN Percobaan III




Gambar 4.19. Hasil target dari *training* Percobaan III

setelah didapatkan target *training* yang mendekati dengan nilai aktual, maka dilakukan *testing* untuk mengetahui bentuk hasil prediksi menggunakan algoritma FFNN. *Testing* dilakukan 1 hari ke depan selama 1 minggu pada bulan April 2019.



Gambar 4.20 Hasil percobaan III hari ke-3 pada bulan April 2019

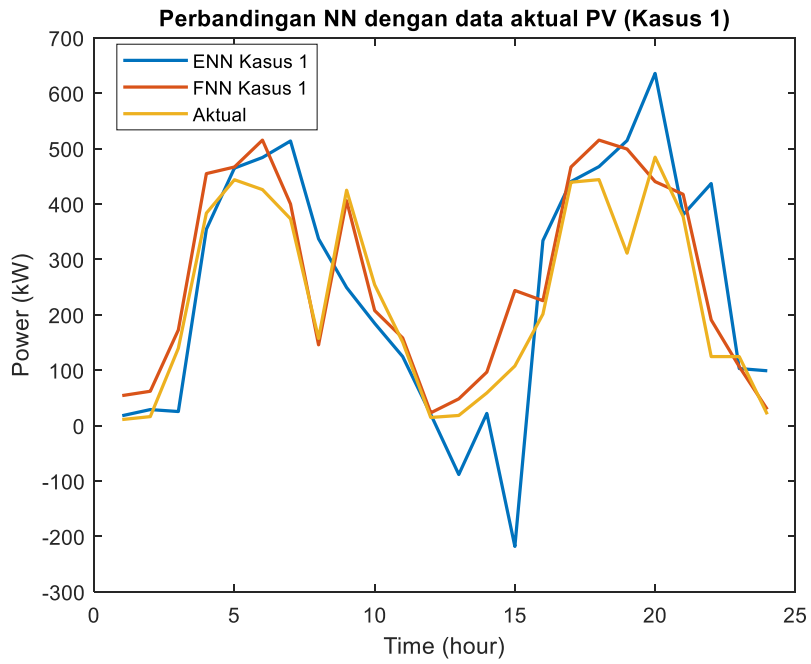


Gambar 4.21 Hasil percobaan III hari ke-4 pada bulan April 2019


Hari 3 dan 4 pada FFNN percobaan II memiliki nilai error MSE 0.01262% dan 3.34230%, bahwa nilai tersebut sesuai batasan yang diperbolehkan. Untuk data masukan data aktual PV akan dilampirkan pada bab **Lampiran**. Dari ketiga percobaan menggunakan *feedforward neural network*, berdasarkan pertimbangan nilai MSE maka, urutan prioritas utama yang direkomendasikan adalah dimulai dari percobaan II, percobaan I, dan terakhir menggunakan percobaan III. Hasil prediksi yang didapatkan dari kedua algoritma *neural network*, yang bisa digunakan untuk analisis manajemen sistem energi menggunakan *feedforward neural network*.

4.3 Analisa Manajemen Energi Sistem


Manajemen Energi pada sistem yang dapat direkomendasikan adalah hasil percobaan II menggunakan FFNN yang memiliki nilai *error* MSE paling kecil diantar percobaan lainnya. Gambar 4.23, 4.24 dan 4.25 menampilkan hasil perbandingan antara data aktual PV dengan menggunakan prediksi NN berdasarkan variabel *input* pada tabel 3.1.



Gambar 4.22 Hasil Perbandingan data aktual PV dan NN pada percobaan I



Gambar 4.23 Hasil Perbandingan data aktual PV dan NN pada percobaan II



Gambar 4.24 Hasil Perbandingan data aktual PV dan NN pada percobaan III

Hasil perbandingan data aktual dan prediksi dengan *Elman Neural Network* dan *Feedforward Neural Network*, dilihat dari grafik, percobaan menggunakan FFNN lebih mendekati nilai dari data aktual, jika diurutkan berdasarkan variabel input dengan 3 kondisi percobaan, terlihat bahwa menggunakan variabel input percobaan 2 memiliki nilai yang hampir mendekati data aktual.

Halaman ini sengaja dikosongkan

BAB 5

KESIMPULAN

5.1 Kesimpulan

Beberapa kesimpulan yang dapat diambil dari studi tentang prediksi daya pembangkit listrik PV satu hari ke depan untuk memudahkan manajemen energi pada sistem menggunakan *Neural Network* adalah sebagai berikut:

1. Fungsi aktivasi pembelajaran (*training*) menggunakan Levenberg-Marquardt pada Elman Neural Network ternyata memiliki nilai MSE yang besar. Sedangkan pada Feedforward Neural Network mendapatkan nilai MSE yang lebih kecil.
2. Sistem Manajemen Energi diperoleh dari prediksi daya PV menggunakan NN dengan nilai MSE terkecil.
3. Prediksi menggunakan FFNN pada percobaan II memiliki nilai kesalahan MSE lebih kecil.

5.2 Penelitian Selanjutnya

Penelitian selanjutnya mengenai prediksi daya PV satu hari ke depan untuk memudahkan manajemen energi pada sistem menggunakan *Neural Network*, untuk mendapatkan hasil *error* yang diharapkan bisa menggunakan beberapa kombinasi fungsi aktivasi yang berbeda dan kombinasi algoritma *Neural Network* yang lebih banyak, sehingga dapat dilihat bahwa fungsi aktivasi yang sesuai dengan kasus yang hampir sama dengan penelitian ini dan bisa dibuat perbandingan serta acuan untuk pembangunan PV kedepannya.

Halaman ini sengaja dikosongkan

DAFTAR PUSTAKA

- [1] M. Malvoni, M. G. De Giorgi, and P. M. Congedo, "Photovoltaic power forecasting using statistical methods: impact of weather data," *IET Sci. Meas. Technol.*, vol. 8, no. 3, pp. 90–97, 2014.
- [2] C.-M. Huang, C.-J. Kuo, S.-J. Chen, and S.-P. Yang, "One-day-ahead hourly forecasting for photovoltaic power generation using an intelligent method with weather-based forecasting models," *IET Gener. Transm. Distrib.*, vol. 9, no. 14, pp. 1874–1882, 2015.
- [3] H. T. Yang, C. M. Huang, Y. C. Huang, and Y. S. Pai, "A weather-based hybrid method for 1-day ahead hourly forecasting of PV power output," *IEEE Trans. Sustain. Energy*, vol. 5, no. 3, pp. 917–926, 2014.
- [4] P. M. Congedo, M. Malvoni, M. Mele, and M. G. De Giorgi, "Performance measurements of monocrystalline silicon PV modules in South-eastern Italy," *Energy Convers. Manag.*, vol. 68, pp. 1–10, 2013.
- [5] T. Verma, A. P. S. Tiwana, C. C. Reddy, V. Arora, and P. Devanand, "Data Analysis to Generate Models Based on Neural Network and Regression for Solar Power Generation Forecasting," *Proc. - Int. Conf. Intell. Syst. Model. Simulation, ISMS*, vol. 0, pp. 97–100, 2016.
- [6] I. Khan, H. Zhu, J. Yao, and D. Khan, "Photovoltaic power forecasting based on Elman Neural Network software engineering method," *Proc. IEEE Int. Conf. Softw. Eng. Serv. Sci. ICSESS*, vol. 2017-Novem, pp. 747–750, 2018.
- [7] R. Ben Ammar, M. Ben Ammar, and A. Oualha, "Photovoltaic power forecasting through temperature and solar radiation estimation," *2019 16th Int. Multi-Conference Syst. Signals Devices*, pp. 691–699, 2019.
- [8] S. Chowdhury, S. P. Chowdhury, and P. Crossley, *H. Molavi and M. M. Ardehali, "Application of Distribution Static Compensator (D-STATCOM) to Voltage Sag Mitigation," vol. 1, no. 2, pp. 11–15, 2013.* 2009.

- [9] A. G. Casaca de Rocha Vaz, “Photovoltaic Forecasting with Artificial Neural Network,” *Fac. CIÊNCIAS\DEPARTAMENTO Eng. GEOGRÁFICA, GEOFÍSICA E Energ.*, 2014.
- [10] F. J. Chang, P. A. Chen, Y. R. Lu, E. Huang, and K. Y. Chang, “Real-time multi-step-ahead water level forecasting by recurrent neural networks for urban flood control,” *J. Hydrol.*, vol. 517, pp. 836–846, 2014.
- [11] T. S. Mehang, D. C. Riawan, and V. L. B. Putri, “Islanding Detection in Grid-Connected Distributed Photovoltaic Generation Using Artificial Neural Network,” *Proceeding - 2018 Int. Semin. Intell. Technol. Its Appl. ISITIA 2018*, pp. 181–186, 2018.
- [12] J. Diogo, “Solar Irradiance Forecast Using Artificial Intelligence Techniques,” no. May, p. 70, 2017.
- [13] M. S. Alanazi, “Solar Power Deployment : Forecasting and Planning,” 2014.
- [14] A. J. Wood and B. Wollenberg, *Power generation operation and control — 2nd edition*, Second edi., vol. 37, no. 3. Canada, 1996.

LAMPIRAN

DATA AKTUAL PV bulan Maret 2019-Juni 2019

Jam	Hari	Bulan	Tahun	EM100 Solar Irradiation (W/m ²)	EM100 Temp Ambient (C)	EM100 Temp PV (C)	Numeric Variables Solar PV (kW)
7	21	3	2019	93.75	25.95	22.50	24.51
8	21	3	2019	316.67	28.90	28.07	160.96
9	21	3	2019	545.00	31.61	40.93	289.84
10	21	3	2019	688.75	33.13	46.40	427.25
11	21	3	2019	823.33	34.08	49.09	507.25
12	21	3	2019	180.63	30.53	32.37	149.32
13	21	3	2019	554.38	31.76	40.03	349.65
14	21	3	2019	648.54	34.39	51.00	420.13
15	21	3	2019	525.63	32.94	43.58	332.01
16	21	3	2019	215.00	30.75	33.64	89.36
17	21	3	2019	39.38	28.67	26.45	23.12
18	21	3	2019	30.00	29.14	27.79	20.38
7	22	3	2019	93.75	26.58	23.34	24.61
8	22	3	2019	268.54	28.14	28.18	146.87
9	22	3	2019	484.38	30.80	40.90	215.17
10	22	3	2019	761.67	32.38	47.48	476.26
11	22	3	2019	847.71	33.23	49.51	432.63
12	22	3	2019	780.42	34.08	50.61	411.53
13	22	3	2019	620.42	32.95	45.20	389.39
14	22	3	2019	313.96	31.74	42.06	211.21
15	22	3	2019	137.92	30.03	31.95	114.06
16	22	3	2019	167.08	30.65	34.25	128.67
17	22	3	2019	131.25	31.34	33.54	105.87
18	22	3	2019	39.38	30.44	30.00	28.02
7	23	3	2019	45.63	26.91	24.31	20.45
8	23	3	2019	162.92	28.28	27.86	108.85
9	23	3	2019	259.17	28.98	31.39	155.22
10	23	3	2019	581.88	30.81	41.84	373.92
11	23	3	2019	626.46	32.35	44.18	400.29
12	23	3	2019	645.63	33.61	49.14	424.90
13	23	3	2019	378.75	30.71	39.10	231.02
14	23	3	2019	685.83	31.27	40.89	443.69
15	23	3	2019	738.54	32.90	44.57	462.28
16	23	3	2019	445.83	31.77	38.37	303.87

17	23	3	2019	130.63	29.78	30.78	102.87
18	23	3	2019	50.42	29.47	28.78	54.26
7	24	3	2019	25.28	26.49	24.25	11.20
8	24	3	2019	85.63	27.51	27.00	74.65
9	24	3	2019	366.04	29.33	34.56	196.14
10	24	3	2019	576.67	31.42	42.32	370.46
11	24	3	2019	580.63	32.37	45.87	373.49
12	24	3	2019	708.54	33.56	49.06	448.68
13	24	3	2019	810.63	34.49	52.92	458.10
14	24	3	2019	625.63	33.73	43.46	447.68
15	24	3	2019	441.04	32.86	41.56	292.09
16	24	3	2019	382.71	32.64	39.67	255.74
17	24	3	2019	220.00	32.51	37.25	156.90
18	24	3	2019	26.25	31.13	30.39	32.51
7	25	3	2019	100.00	27.81	24.12	54.26
8	25	3	2019	352.50	29.61	31.64	162.03
9	25	3	2019	525.21	32.32	44.29	172.69
10	25	3	2019	746.46	33.19	46.34	454.84
11	25	3	2019	681.67	34.07	51.32	406.72
12	25	3	2019	411.67	32.97	41.15	281.12
13	25	3	2019	295.83	31.19	36.93	199.96
14	25	3	2019	70.87	25.97	24.82	45.83
15	25	3	2019	129.38	27.71	28.14	106.01
16	25	3	2019	135.21	28.94	31.50	107.75
17	25	3	2019	62.08	29.27	29.35	58.29
18	25	3	2019	30.00	29.14	27.79	23.12
7	26	3	2019	91.25	26.61	23.52	48.34
8	26	3	2019	290.83	28.96	27.48	156.62
9	26	3	2019	528.54	30.90	38.97	243.92
10	26	3	2019	741.25	32.58	47.25	425.51
11	26	3	2019	731.46	34.11	54.04	466.72
12	26	3	2019	898.75	34.83	55.87	515.31
13	26	3	2019	668.96	35.81	58.32	499.16
14	26	3	2019	721.67	34.69	51.98	440.43
15	26	3	2019	665.00	35.04	51.23	457.51
16	26	3	2019	256.46	34.49	41.81	190.88
17	26	3	2019	121.04	32.02	34.62	96.53
18	26	3	2019	41.88	31.39	30.54	29.29
7	27	3	2019	32.50	26.54	24.00	15.31
8	27	3	2019	118.96	27.26	27.22	93.82
9	27	3	2019	502.08	29.68	40.86	192.41
10	27	3	2019	709.58	31.71	52.83	370.63

11	27	3	2019	961.46	34.20	62.23	540.62
12	27	3	2019	896.88	35.02	60.68	472.92
13	27	3	2019	503.13	34.28	51.97	326.27
14	27	3	2019	125.63	29.43	30.89	104.19
15	27	3	2019	406.25	32.44	41.64	270.67
16	27	3	2019	282.71	31.95	39.65	211.84
17	27	3	2019	65.63	29.56	29.85	39.97
18	27	3	2019	30.26	29.19	26.68	13.91
7	28	3	2019	81.25	27.58	26.22	29.38
8	28	3	2019	135.83	28.92	31.03	97.66
9	28	3	2019	394.79	30.60	37.07	233.71
10	28	3	2019	747.92	32.05	45.08	473.35
11	28	3	2019	710.63	32.89	47.87	446.62
12	28	3	2019	892.71	34.34	51.29	545.18
13	28	3	2019	881.25	35.92	56.37	563.99
14	28	3	2019	677.29	35.58	48.25	433.88
15	28	3	2019	303.13	33.09	45.37	223.95
16	28	3	2019	77.19	30.45	32.12	57.90
17	28	3	2019	41.88	31.39	30.54	29.29
18	28	3	2019	32.50	26.54	24.00	15.31
7	29	3	2019	91.67	26.35	22.10	29.47
8	29	3	2019	271.88	28.66	27.65	147.22
9	29	3	2019	530.42	30.98	42.12	247.88
10	29	3	2019	691.67	33.12	52.40	433.60
11	29	3	2019	826.04	35.67	59.06	500.61
12	29	3	2019	928.54	36.63	64.20	535.57
13	29	3	2019	868.54	36.04	61.01	530.42
14	29	3	2019	779.38	35.72	56.12	466.93
15	29	3	2019	569.38	34.85	49.67	351.92
16	29	3	2019	309.38	33.68	44.32	203.32
17	29	3	2019	128.75	31.97	32.53	27.99
18	29	3	2019	220.00	32.51	37.25	156.90
7	30	3	2019	26.25	31.13	30.39	32.51
8	30	3	2019	49.88	28.01	27.01	43.08
9	30	3	2019	218.33	29.26	33.29	156.69
10	30	3	2019	523.33	30.93	44.59	270.14
11	30	3	2019	485.00	32.46	49.18	316.17
12	30	3	2019	579.38	33.83	50.59	370.91
13	30	3	2019	817.08	35.79	58.62	492.07
14	30	3	2019	678.54	36.33	55.57	409.86
15	30	3	2019	699.38	37.35	59.37	436.73
16	30	3	2019	596.25	37.38	54.39	367.35

17	30	3	2019	177.92	33.88	40.39	119.94
18	30	3	2019	41.88	31.39	30.54	29.29
7	31	3	2019	128.75	26.98	23.73	28.73
8	31	3	2019	205.42	28.53	28.20	128.41
9	31	3	2019	429.79	30.76	41.25	124.52
10	31	3	2019	481.04	32.08	45.90	296.51
11	31	3	2019	510.00	32.66	48.84	353.44
12	31	3	2019	817.50	34.28	57.92	510.03
13	31	3	2019	741.88	35.75	53.81	435.46
14	31	3	2019	606.67	35.70	48.89	351.31
15	31	3	2019	461.88	34.30	46.79	297.85
16	31	3	2019	153.13	28.92	28.62	86.91
17	31	3	2019	62.50	25.76	24.30	25.28
18	31	3	2019	41.88	31.39	30.54	29.29
7	1	4	2019	93.75	25.38	22.83	24.14
8	1	4	2019	283.96	27.06	26.51	125.61
9	1	4	2019	503.75	29.64	37.90	153.88
10	1	4	2019	671.04	31.96	50.95	383.20
11	1	4	2019	798.54	33.91	56.83	486.64
12	1	4	2019	924.79	35.60	59.21	544.04
13	1	4	2019	958.96	36.49	63.25	552.26
14	1	4	2019	958.96	36.49	63.25	552.26
15	1	4	2019	517.08	35.14	46.76	300.96
16	1	4	2019	46.25	29.27	28.28	32.51
17	1	4	2019	32.50	26.54	24.00	24.20
18	1	4	2019	26.25	31.13	30.39	15.31
7	2	4	2019	68.75	26.56	22.35	17.97
8	2	4	2019	136.67	28.04	26.53	29.01
9	2	4	2019	372.25	29.27	36.73	25.45
10	2	4	2019	622.92	32.15	48.54	354.43
11	2	4	2019	807.08	34.28	57.14	464.77
12	2	4	2019	906.25	35.53	61.47	483.93
13	2	4	2019	922.29	35.88	59.62	513.73
14	2	4	2019	710.21	36.66	56.15	337.20
15	2	4	2019	478.50	34.83	44.15	249.27
16	2	4	2019	200.00	34.14	40.04	124.61
17	2	4	2019	200.00	34.14	40.04	124.61
18	2	4	2019	81.25	32.30	31.90	20.47
7	3	4	2019	161.25	25.28	21.27	11.03
8	3	4	2019	173.13	26.97	25.14	16.28
9	3	4	2019	450.63	30.02	38.20	139.67
10	3	4	2019	640.00	31.97	50.83	383.55

11	3	4	2019	767.71	34.11	56.92	443.80
12	3	4	2019	554.79	34.84	58.28	425.95
13	3	4	2019	685.21	35.32	58.04	373.25
14	3	4	2019	235.00	33.30	39.83	157.37
15	3	4	2019	726.25	34.68	53.75	424.90
16	3	4	2019	416.25	34.15	47.39	254.27
17	3	4	2019	392.50	32.09	36.59	150.78
18	3	4	2019	30.15	29.82	29.85	14.78
7	4	4	2019	162.50	27.51	24.06	18.40
8	4	4	2019	111.67	28.58	30.01	59.04
9	4	4	2019	276.88	30.40	37.30	107.66
10	4	4	2019	322.29	31.53	42.25	201.28
11	4	4	2019	782.92	33.54	54.97	439.30
12	4	4	2019	772.29	35.09	61.87	444.01
13	4	4	2019	582.75	35.53	56.18	311.22
14	4	4	2019	855.83	36.00	60.15	484.53
15	4	4	2019	635.21	35.68	55.25	377.21
16	4	4	2019	200.00	34.14	40.04	124.61
17	4	4	2019	200.00	34.14	40.04	124.61
18	4	4	2019	81.25	32.30	31.90	20.47
7	5	4	2019	108.75	26.10	23.28	24.55
8	5	4	2019	228.33	27.74	27.87	135.96
9	5	4	2019	490.00	30.41	41.25	126.70
10	5	4	2019	518.33	32.04	48.39	265.63
11	5	4	2019	501.04	32.91	46.78	312.94
12	5	4	2019	548.75	33.95	52.48	334.90
13	5	4	2019	420.21	33.85	48.60	257.06
14	5	4	2019	146.67	31.18	34.37	114.58
15	5	4	2019	160.63	30.41	34.79	123.76
16	5	4	2019	138.54	30.62	34.56	104.52
17	5	4	2019	208.33	31.45	37.53	137.53
18	5	4	2019	132.50	31.29	31.98	32.46
7	6	4	2019	27.89	26.80	24.25	15.97
8	6	4	2019	176.67	28.14	27.98	97.95
9	6	4	2019	502.29	30.77	42.48	231.08
10	6	4	2019	632.92	32.43	51.87	389.92
11	6	4	2019	659.58	34.07	51.93	372.79
12	6	4	2019	585.21	34.52	51.01	343.49
13	6	4	2019	840.21	35.91	58.90	518.74
14	6	4	2019	677.29	37.21	55.58	396.78
15	6	4	2019	517.92	36.49	51.28	277.91
16	6	4	2019	108.13	31.71	36.43	77.19

17	6	4	2019	177.92	33.88	40.39	119.94
18	6	4	2019	41.88	31.39	30.54	29.29
7	7	4	2019	38.54	25.97	22.28	13.53
8	7	4	2019	288.13	28.29	29.78	19.23
9	7	4	2019	505.42	30.82	43.78	234.23
10	7	4	2019	673.75	32.43	51.39	423.03
11	7	4	2019	804.58	34.48	60.18	492.95
12	7	4	2019	778.96	35.97	60.95	437.92
13	7	4	2019	922.08	37.12	61.84	546.33
14	7	4	2019	727.71	36.08	55.70	388.30
15	7	4	2019	392.92	34.71	45.23	263.80
16	7	4	2019	177.92	33.88	40.39	119.94
17	7	4	2019	57.92	33.16	34.48	62.48
18	7	4	2019	41.88	31.39	30.54	29.29
7	8	4	2019	39.79	29.50	24.32	14.59
8	8	4	2019	184.79	29.50	29.43	19.57
9	8	4	2019	375.63	29.50	40.72	45.37
10	8	4	2019	576.04	30.80	48.53	313.15
11	8	4	2019	825.83	30.90	57.53	501.30
12	8	4	2019	972.50	31.75	60.29	534.50
13	8	4	2019	943.96	33.00	60.26	548.94
14	8	4	2019	827.08	33.00	57.75	505.81
15	8	4	2019	732.29	32.00	56.83	455.27
16	8	4	2019	259.58	32.00	47.07	175.30
17	8	4	2019	218.75	32.00	26.76	44.73
18	8	4	2019	30.00	31.00	27.00	19.65
7	9	4	2019	13.13	28.00	23.75	17.19
8	9	4	2019	199.38	29.00	29.79	30.38
9	9	4	2019	528.75	30.00	47.47	48.42
10	9	4	2019	651.46	30.00	53.24	234.41
11	9	4	2019	835.63	31.00	59.68	481.08
12	9	4	2019	949.79	32.00	64.13	537.71
13	9	4	2019	823.54	33.00	63.48	436.55
14	9	4	2019	647.29	25.00	54.25	406.03
15	9	4	2019	300.18	33.23	49.51	230.44
16	9	4	2019	307.08	34.11	43.48	203.57
17	9	4	2019	102.71	33.30	36.07	80.75
18	9	4	2019	21.46	32.53	31.89	29.89
7	10	4	2019	40.00	26.60	23.48	12.12
8	10	4	2019	170.21	27.85	27.26	21.74
9	10	4	2019	372.29	30.10	37.47	33.53
10	10	4	2019	523.96	31.89	46.25	319.49

11	10	4	2019	612.50	33.26	52.86	380.21
12	10	4	2019	810.00	35.52	58.07	461.91
13	10	4	2019	840.83	36.54	64.32	492.94
14	10	4	2019	596.88	36.28	54.25	379.18
15	10	4	2019	474.79	36.47	51.45	334.54
16	10	4	2019	400.42	36.80	47.98	261.42
17	10	4	2019	224.79	36.38	43.40	148.49
18	10	4	2019	18.54	33.56	33.68	31.48
7	11	4	2019	67.50	26.73	24.04	14.77
8	11	4	2019	219.79	28.80	30.67	18.24
9	11	4	2019	498.54	31.69	46.81	42.55
10	11	4	2019	675.83	33.54	53.39	383.07
11	11	4	2019	832.29	35.28	55.59	507.13
12	11	4	2019	883.96	36.10	57.08	534.75
13	11	4	2019	819.79	36.17	51.45	510.54
14	11	4	2019	797.92	34.66	49.54	521.46
15	11	4	2019	718.96	33.42	44.81	459.39
16	11	4	2019	356.04	32.37	39.17	245.75
17	11	4	2019	188.54	31.48	35.18	147.22
18	11	4	2019	83.75	31.32	31.83	46.24
7	12	4	2019	42.50	26.79	22.56	19.44
8	12	4	2019	209.17	28.82	29.15	20.09
9	12	4	2019	399.58	31.01	40.09	65.93
10	12	4	2019	434.38	32.13	41.59	270.86
11	12	4	2019	508.54	33.07	46.36	329.27
12	12	4	2019	492.50	33.70	46.12	340.91
13	12	4	2019	700.42	34.93	51.14	433.36
14	12	4	2019	301.88	33.04	40.23	164.64
15	12	4	2019	27.81	29.64	26.84	41.79
16	12	4	2019	43.75	27.74	25.86	24.95
17	12	4	2019	101.67	28.42	28.89	81.72
18	12	4	2019	32.50	29.14	27.45	17.42
7	13	4	2019	64.38	26.74	23.34	12.07
8	13	4	2019	164.17	28.35	27.71	18.91
9	13	4	2019	367.71	29.89	37.31	161.77
10	13	4	2019	609.17	32.20	44.87	392.00
11	13	4	2019	811.67	34.01	52.54	507.95
12	13	4	2019	844.17	35.35	57.74	438.89
13	13	4	2019	937.71	36.47	58.33	570.93
14	13	4	2019	845.63	37.14	58.53	493.03
15	13	4	2019	318.54	35.55	46.98	204.87
16	13	4	2019	76.56	30.02	27.23	58.70

17	13	4	2019	40.00	31.26	29.59	19.00
18	13	4	2019	32.50	30.76	27.98	26.67
7	14	4	2019	46.25	26.71	23.67	12.93
8	14	4	2019	226.25	28.47	30.32	19.63
9	14	4	2019	505.21	31.49	45.15	204.91
10	14	4	2019	643.54	33.28	52.51	398.93
11	14	4	2019	778.13	34.61	55.28	489.42
12	14	4	2019	758.96	35.50	56.90	483.83
13	14	4	2019	517.50	36.04	54.43	318.80
14	14	4	2019	815.42	37.41	59.04	507.49
15	14	4	2019	695.00	37.30	59.01	436.43
16	14	4	2019	447.50	35.68	50.89	281.58
17	14	4	2019	131.25	34.43	38.62	95.43
18	14	4	2019	37.50	33.04	32.82	32.12
7	15	4	2019	40.00	27.71	24.26	12.24
8	15	4	2019	146.88	29.03	27.62	21.51
9	15	4	2019	432.71	31.95	43.40	22.00
10	15	4	2019	562.71	33.70	51.62	291.57
11	15	4	2019	672.50	34.79	54.50	427.27
12	15	4	2019	719.17	35.89	58.07	438.76
13	15	4	2019	208.75	33.27	43.65	161.78
14	15	4	2019	138.33	29.85	30.07	118.30
15	15	4	2019	68.75	30.15	31.11	43.72
16	15	4	2019	76.56	30.02	27.23	58.70
17	15	4	2019	40.00	31.26	29.59	19.00
18	15	4	2019	32.50	30.76	27.98	26.67
7	16	4	2019	71.25	26.20	23.42	15.26
8	16	4	2019	265.42	28.33	29.68	25.92
9	16	4	2019	487.08	30.90	43.40	68.12
10	16	4	2019	650.42	32.67	52.04	373.00
11	16	4	2019	795.63	34.72	55.20	486.34
12	16	4	2019	837.50	35.60	59.62	498.33
13	16	4	2019	859.17	37.03	61.96	516.24
14	16	4	2019	526.13	36.42	53.50	304.33
15	16	4	2019	288.00	28.34	26.97	155.00
16	16	4	2019	211.33	27.68	25.26	108.49
17	16	4	2019	153.00	26.90	23.76	85.32
18	16	4	2019	75.00	26.64	24.34	35.48
7	17	4	2019	16.67	25.96	22.40	14.22
8	17	4	2019	211.25	27.43	27.82	22.96
9	17	4	2019	384.38	29.60	38.59	25.08
10	17	4	2019	671.46	32.60	54.76	53.68

11	17	4	2019	828.33	34.53	59.17	442.41
12	17	4	2019	718.33	35.36	59.90	454.40
13	17	4	2019	528.96	35.89	57.81	388.86
14	17	4	2019	673.75	35.63	54.71	414.17
15	17	4	2019	540.42	34.83	50.09	354.66
16	17	4	2019	412.92	34.53	46.18	267.15
17	17	4	2019	207.08	33.63	39.53	142.22
18	17	4	2019	42.50	32.53	31.31	24.98
7	18	4	2019	73.75	28.09	24.46	14.84
8	18	4	2019	191.88	29.41	28.45	24.83
9	18	4	2019	462.08	32.21	44.10	25.62
10	18	4	2019	557.92	33.81	49.53	339.39
11	18	4	2019	668.96	35.31	56.20	457.53
12	18	4	2019	854.58	36.66	63.45	492.19
13	18	4	2019	791.46	36.87	57.22	485.52
14	18	4	2019	373.75	34.75	38.43	273.84
15	18	4	2019	117.71	33.16	35.23	93.41
16	18	4	2019	101.67	28.42	28.89	81.72
17	18	4	2019	46.25	29.69	27.29	27.97
18	18	4	2019	32.50	29.14	27.45	17.42
7	19	4	2019	57.50	27.05	24.59	27.03
8	19	4	2019	57.50	27.73	26.74	27.03
9	19	4	2019	350.63	29.48	33.00	168.61
10	19	4	2019	593.13	32.52	47.68	383.45
11	19	4	2019	547.71	33.33	46.59	317.17
12	19	4	2019	358.54	34.07	47.42	236.01
13	19	4	2019	204.79	32.82	40.06	146.90
14	19	4	2019	255.42	29.28	31.54	175.72
15	19	4	2019	471.25	33.54	50.84	330.88
16	19	4	2019	61.25	33.01	34.21	56.63
17	19	4	2019	76.25	28.61	26.81	28.84
18	19	4	2019	32.50	29.14	27.45	17.42
7	20	4	2019	30.00	25.61	23.83	15.43
8	20	4	2019	41.50	26.03	24.46	20.38
9	20	4	2019	100.63	26.57	26.93	72.43
10	20	4	2019	151.25	27.61	30.57	127.91
11	20	4	2019	334.79	29.04	37.48	245.64
12	20	4	2019	626.46	31.25	49.37	406.63
13	20	4	2019	466.04	32.22	47.62	308.67
14	20	4	2019	755.00	34.63	55.75	455.73
15	20	4	2019	198.54	33.54	43.78	142.89
16	20	4	2019	182.29	32.46	37.48	138.55

17	20	4	2019	94.17	32.07	35.22	82.29
18	20	4	2019	32.50	29.14	27.45	17.42
7	21	4	2019	40.00	27.51	25.48	20.63
8	21	4	2019	113.75	28.37	27.15	26.66
9	21	4	2019	495.00	30.64	39.36	221.10
10	21	4	2019	546.25	32.71	44.09	418.92
11	21	4	2019	685.00	33.90	46.87	447.73
12	21	4	2019	564.38	34.73	46.30	356.37
13	21	4	2019	681.04	35.61	51.79	447.22
14	21	4	2019	304.17	35.71	46.28	248.18
15	21	4	2019	255.42	29.28	31.54	175.72
16	21	4	2019	204.79	32.82	40.06	146.90
17	21	4	2019	35.42	28.11	27.14	49.07
18	21	4	2019	33.30	28.47	27.57	18.75
7	22	4	2019	23.96	26.40	23.06	16.22
8	22	4	2019	279.58	28.00	27.42	19.92
9	22	4	2019	483.75	30.16	42.15	69.00
10	22	4	2019	551.67	32.04	47.18	349.94
11	22	4	2019	709.25	34.80	48.19	445.73
12	22	4	2019	843.54	36.13	50.28	506.26
13	22	4	2019	847.50	37.08	52.43	510.09
14	22	4	2019	610.21	37.40	52.71	381.84
15	22	4	2019	564.79	37.49	49.48	372.48
16	22	4	2019	465.42	37.24	48.62	286.42
17	22	4	2019	157.50	34.81	38.50	117.50
18	22	4	2019	26.25	33.63	32.06	16.32
7	23	4	2019	75.00	27.71	22.28	43.78
8	23	4	2019	263.33	30.01	29.78	111.10
9	23	4	2019	462.29	32.39	43.78	236.56
10	23	4	2019	628.54	34.19	51.39	337.71
11	23	4	2019	824.79	35.76	60.18	504.46
12	23	4	2019	844.79	36.65	60.95	438.23
13	23	4	2019	807.92	37.03	61.84	508.15
14	23	4	2019	526.46	36.64	55.70	330.35
15	23	4	2019	346.00	36.52	45.23	211.32
16	23	4	2019	118.96	32.70	40.39	98.74
17	23	4	2019	87.50	33.27	34.48	41.40
18	23	4	2019	41.40	32.01	30.54	28.14
7	24	4	2019	148.14	27.68	24.32	92.33
8	24	4	2019	144.79	28.08	29.43	92.49
9	24	4	2019	283.96	29.87	40.72	113.21
10	24	4	2019	466.04	31.64	48.53	277.02

11	24	4	2019	339.58	32.09	57.53	232.77
12	24	4	2019	145.63	28.46	60.29	120.90
13	24	4	2019	113.21	29.64	60.26	98.05
14	24	4	2019	109.38	28.75	57.75	82.53
15	24	4	2019	84.17	27.56	56.83	63.97
16	24	4	2019	75.42	27.82	47.07	73.17
17	24	4	2019	86.25	26.79	26.76	38.22
18	24	4	2019	40.00	26.75	27.00	12.15
7	25	4	2019	30.00	25.39	23.75	10.33
8	25	4	2019	302.71	27.34	29.79	170.86
9	25	4	2019	497.71	30.02	47.47	23.86
10	25	4	2019	644.79	32.30	53.24	369.05
11	25	4	2019	757.29	34.47	59.68	476.85
12	25	4	2019	846.25	35.85	64.13	520.46
13	25	4	2019	756.67	36.95	63.48	401.00
14	25	4	2019	155.00	35.25	54.25	125.63
15	25	4	2019	165.21	32.91	49.51	136.10
16	25	4	2019	115.00	31.82	43.48	72.68
17	25	4	2019	94.38	31.94	36.07	32.66
18	25	4	2019	42.66	31.42	31.89	13.77
7	26	4	2019	75.00	26.38	23.48	34.76
8	26	4	2019	94.38	27.51	27.26	43.94
9	26	4	2019	281.46	29.06	37.47	176.64
10	26	4	2019	617.50	32.04	46.25	324.88
11	26	4	2019	746.67	33.84	52.86	459.59
12	26	4	2019	869.79	35.32	58.07	515.18
13	26	4	2019	668.54	36.34	64.32	351.57
14	26	4	2019	496.67	35.72	54.25	314.62
15	26	4	2019	129.38	33.96	51.45	112.58
16	26	4	2019	118.96	31.77	47.98	80.15
17	26	4	2019	87.50	31.57	43.40	34.83
18	26	4	2019	42.66	27.15	33.68	14.76
7	27	4	2019	42.50	26.89	24.04	19.83
8	27	4	2019	110.83	27.58	30.67	86.98
9	27	4	2019	239.58	28.64	46.81	165.88
10	27	4	2019	375.83	29.94	53.39	251.95
11	27	4	2019	405.83	30.83	55.59	277.54
12	27	4	2019	729.58	32.54	57.08	420.30
13	27	4	2019	686.46	33.66	51.45	423.75
14	27	4	2019	319.38	33.27	49.54	234.49
15	27	4	2019	128.96	31.57	44.81	111.58
16	27	4	2019	111.00	28.66	39.17	60.36

17	27	4	2019	70.00	25.91	35.18	30.36
18	27	4	2019	50.00	26.14	31.83	18.36
7	28	4	2019	67.50	25.77	22.56	32.42
8	28	4	2019	264.38	27.55	29.15	118.18
9	28	4	2019	467.08	30.43	40.09	241.14
10	28	4	2019	594.17	32.10	41.59	377.61
11	28	4	2019	566.46	33.29	46.36	428.11
12	28	4	2019	753.75	33.97	46.12	451.00
13	28	4	2019	824.17	34.46	51.14	494.30
14	28	4	2019	603.75	33.21	40.23	406.45
15	28	4	2019	541.25	33.97	26.84	371.47
16	28	4	2019	460.21	34.39	25.86	290.99
17	28	4	2019	120.00	32.32	28.89	80.68
18	28	4	2019	67.50	25.77	27.45	32.42
7	29	4	2019	110.83	27.58	23.34	86.98
8	29	4	2019	260.63	29.03	27.71	119.71
9	29	4	2019	424.58	31.69	37.31	289.25
10	29	4	2019	508.75	32.19	44.87	337.20
11	29	4	2019	625.83	33.64	52.54	336.32
12	29	4	2019	740.63	34.94	57.74	423.06
13	29	4	2019	571.67	35.09	58.33	339.16
14	29	4	2019	438.75	33.36	58.53	318.89
15	29	4	2019	415.63	32.87	46.98	276.33
16	29	4	2019	212.08	32.45	27.23	153.66
17	29	4	2019	163.13	32.01	29.59	57.18
18	29	4	2019	45.69	31.26	27.98	26.74
7	30	4	2019	90.63	27.59	23.67	37.44
8	30	4	2019	107.29	28.61	30.32	90.47
9	30	4	2019	453.54	30.95	45.15	274.99
10	30	4	2019	403.33	31.66	52.51	291.82
11	30	4	2019	417.92	33.97	55.28	302.57
12	30	4	2019	364.38	33.78	56.90	284.57
13	30	4	2019	567.29	34.36	54.43	369.19
14	30	4	2019	488.75	34.47	59.04	331.90
15	30	4	2019	180.63	32.97	59.01	157.37
16	30	4	2019	134.38	26.39	50.89	90.89
17	30	4	2019	53.00	28.66	38.62	21.36
18	30	4	2019	36.25	26.61	32.82	14.16

DATA TESTING ELMAN NEURAL NETWORK

Elman Neural Network						
Tahun	Bulan	Hari	Jam	PV Output (kW) Kasus 1	PV Output (kW) Kasus 2	PV Output (kW) Kasus 3
2019	4	3	7	17.9662	10.9327	11.034
2019	4	3	8	29.0026	15.8981	16.275
2019	4	3	9	25.4442	139.6113	139.6733
2019	4	3	10	354.4209	383.5053	383.548
2019	4	3	11	464.7644	443.7519	443.795
2019	4	3	12	483.9249	425.8857	425.9467
2019	4	3	13	513.7211	373.2285	265.311
2019	4	3	14	337.1936	157.3485	265.311
2019	4	3	15	249.2658	424.7535	424.8967
2019	4	3	16	124.6295	254.2683	254.2717
2019	4	3	17	124.6282	150.7347	69.8461
2019	4	3	18	20.4411	14.5021	22.7381
2019	4	4	7	-88.2328	111.3294	-26.9292
2019	4	4	8	22.0753	-45.2982	-198.7952
2019	4	4	9	-217.999	-246.5624	726.5194
2019	4	4	10	333.9386	521.9969	341.1076
2019	4	4	11	440.4801	412.6775	478.5577
2019	4	4	12	467.4911	702.7525	255.7889
2019	4	4	13	514.4692	606.6974	304.7852
2019	4	4	14	635.7115	637.7945	628.3498
2019	4	4	15	380.6397	-141.1121	843.1563
2019	4	4	16	436.9751	389.1936	12.1133
2019	4	4	17	103.0602	770.2203	12.1133
2019	4	4	18	99.0129	88.7384	-60.1629

DATA TESTING FEEDFORWARD NEURAL NETWORK

Feedforward Neural Network						
Tahun	Bulan	Hari	Jam	PV Output (kW) Kasus 2	PV Output (kW) Kasus 1	PV Output (kW) Kasus 3
2019	4	3	7	11.2	54.26	48.3375
2019	4	3	8	74.65333333	162.0283333	156.6166667
2019	4	3	9	196.135	172.6916667	243.915
2019	4	3	10	370.4566667	454.835	425.51
2019	4	3	11	373.485	406.7183333	466.7216667
2019	4	3	12	448.6833333	281.1216667	515.3133333
2019	4	3	13	458.095	199.955	499.1583333
2019	4	3	14	447.6783333	45.825	440.425
2019	4	3	15	292.0933333	106.01	457.5083333
2019	4	3	16	255.74	107.75	190.8766667
2019	4	3	17	156.8966667	58.28833333	96.53
2019	4	3	18	32.51333333	23.11833333	29.28833333
2019	4	4	7	54.26	48.3375	15.312
2019	4	4	8	162.0283333	156.6166667	93.82
2019	4	4	9	172.6916667	243.915	192.4083333
2019	4	4	10	454.835	425.51	370.6283333
2019	4	4	11	406.7183333	466.7216667	540.6233333
2019	4	4	12	281.1216667	515.3133333	472.9166667
2019	4	4	13	199.955	499.1583333	326.265
2019	4	4	14	45.825	440.425	104.1883333
2019	4	4	15	106.01	457.5083333	270.6666667
2019	4	4	16	107.75	190.8766667	211.8383333
2019	4	4	17	58.28833333	96.53	39.97166667
2019	4	4	18	23.11833333	29.28833333	13.90666667

RIWAYAT PENULIS



Nama lengkap penulis Khairunnisa', lahir di kota Pekanbaru pada 12 April 1995, yang merupakan anak pertama dari 3 bersaudara. Ayahanda penulis bernama Drs.Hanifulkhair, M.T dan Ibunda Delita Febrina, B.Sc. Penulis menempuh pendidikan Sekolah Dasar (SD) di SDN 245 Keputih, Sukolilo pada tahun 2001-2002, kemudian pindah ke kota Pekanbaru, hingga menyelesaikan pendidikan Sekolah Dasar (SD) di SDN 025 Pandau Jaya, Kampar, Riau pada tahun 2002-2007. Penulis melanjutkan ke Madrasah Tsanawiyah Negeri (MTsN) Pekanbaru pada tahun 2007-2010, Sekolah Menengah Atas (SMA) Negeri di SMAN 4 Pekanbaru pada tahun 2010-2013. Kemudian, penulis melanjutkan ke jenjang Strata 1 jurusan Teknik Elektro di Universitas Islam Negeri (UIN) Sultan Syarif Kasim Riau pada tahun 2013-2017, setelah lulus dari Strata 1, penulis sempat bekerja selama lebih kurang 5 bulan di perusahaan yang bergerak dibidang Energi Terbarukan, khususnya PLTS di daerah Bogor, kemudian penulis melanjutkan pendidikan kembali dan mengambil program Magister Teknik Elektro dengan bidang keahlian Teknik Sistem Tenaga di Institut Teknologi Sepuluh Nopember (ITS) pada tahun 2018-2020. Mengenai tesis penulis dapat menghubungi email: khairunnisa1204@gmail.com.

Halaman ini sengaja dikosongkan