

Prediksi Radiasi Matahari Dengan Penerapan Metode Elman Recurrent Neural Network

Novi Yanti¹, Eka Pandu Cynthia², Yelfi Vitriani³, Yusra⁴, Gusven Azmi⁵

Universitas Islam Negeri Sultan Syarif Kasim Riau

Jl. HR Soebrantas Km. 15 No. 155 Kelurahan Simpang Baru Panam – Kecamatan Tampan,
Pekanbaru, Riau 28293

e-mail: novi_yanti@uin-suska.ac.id, eka.pandu.cynthia@uin-suska.ac.id,
yelfi.vitriai@uin-suska.ac.id, yusra@uin-suska.ac.id, gusven.azmi@students.uin-suska.ac.id

Abstrak

Bumi menerima energi panas dari matahari yang disebut sebagai radiasi matahari. Energi panas sekitar 51% yang mencapai bumi dan sisanya diserap oleh awan beserta gas-gas lain yang berada di atmosfer. Radiasi matahari bermanfaat bagi manusia sebagai penghangat dan penerangan ruangan, pengeringan hasil pertanian dan perikanan, proses fotosintesis tumbuhan, sebagai sumber energi baru dan lain sebagainya. Radiasi matahari juga bisa menimbulkan kerugian seperti menyebabkan kulit terbakar, penyakit mata, demam, sakit kepala dan pemanasan bagi lingkungan. Pengamatan terhadap energi panas ini dilakukan oleh Badan Meteorologi dan Geofisika (BMKG) yang tersebar pada beberapa stasiun di seluruh wilayah Indonesia. BMKG melakukan pencatatan besaran radiasi yang sampai ke bumi dengan melihat durasi penyinaran matahari, kemudian besaran pengaruhnya terhadap lingkungan seperti suhu udara, curah hujan dan kelembaban udara. Metode Elman Recurrent Neural Network (ERNN) merupakan salah satu metode kecerdasan buatan pada jaringan syaraf tiruan. Penelitian ini diharapkan dapat memprediksi besaran radiasi dan pengaruhnya pada lingkungan sehingga dapat dilakukanantisipasi pengaruh buruk kedepannya yang dapat diterima manusia dan lingkungan. ERNN akan memprediksi besaran pancaran radiasi matahari (W/m^2) menggunakan data masukan hasil pencatatan BMKG yang dipengaruhinya yaitu durasi penyinaran matahari (%), suhu udara ($^{\circ}Celsius$), curah hujan (mm) dan kelembaban udara (%). Menggunakan beberapa skenario pelatihan dan pengujian dengan pemberian nilai set parameter yang berbeda, menghasilkan nilai akurasi terbaik sebesar 96,33% pada pembagian data latih dan data uji 90%:10% dengan set parameter nilai learning rate 0,1 epoch 500 dan minimal error 0,0001.

Kata kunci: ERNN, Jaringan Syaraf Tiruan, Kecerdasan Buatan, Prediksi, Radiasi Matahari.

Abstract

The earth receives heat energy from the sun called solar radiation. About 51% of this heat energy reaches the earth and the rest is absorbed by clouds and other gases in the atmosphere. Solar radiation is useful for humans as heating and lighting the room, drying agricultural and fishery products, plant photosynthesis process, as a new energy source and so forth. Solar radiation can also cause losses such as causing sunburn, eye disease, fever, headaches, and heating for the environment. Observation of thermal energy is carried out by the Meteorology and Geophysics Agency (BMKG) which is spread over several stations throughout Indonesia. BMKG records the amount of radiation reaching the earth by looking at the duration of the sun's irradiation, then the magnitude of its effect on the environment such as air temperature, rainfall, and humidity. Elman Recurrent Neural Network (ERNN) method is one of the methods of artificial intelligence in artificial neural networks. This research is expected to predict the amount of radiation and its influence on the environment so that it can anticipate adverse effects in the future that can be accepted by humans and the environment. ERNN will predict the amount of solar radiation (W/m^2) using input data from BMKG recording that affects the duration of solar radiation (%), temperature ($^{\circ}Celsius$), rainfall (mm) and humidity (%). Using a number of training and testing scenarios by assigning different parameter sets, the best accuracy value is 96.33% for the distribution of training data and 90%: 10% test data with the set parameter learning rate value of 0.1 epoch 500 and a minimum error of 0 0001.

Keywords: Artificial Intelligence, Artificial Neural Network, ERNN, Prediction, Solar Radiation.

1. Pendahuluan

Radiasi matahari merupakan energi panas yang dipancarkan matahari dan diterima hingga ke bumi yang memiliki pengaruh yang sangat besar bagi kehidupan. Energi panas ini tidak seluruhnya sampai hingga ke permukaan bumi. Sekitar 50,1% energi yang sampai ke bumi tersebut dimanfaatkan untuk memanaskan permukaan bumi dan atmosfer bawah, mencairkan dan menguapkan air, serta proses fotosintesis tumbuhan [1]. Sisanya, sekitar 4% energi panas tersebut direfleksikan kembali ke atmosfer melalui permukaan bumi, 26% dihamburkan dan direfleksikan ke

atmosfer melalui awan dan partikel-partikel atmosfer, dan 19% diserap oleh gas, partikel dan awan. Radiasi yang diserap oleh permukaan bumi kemudian diubah dalam bentuk panas menjadi radiasi gelombang panjang. Radiasi dari permukaan bumi berupa radiasi gelombang panjang, selanjutnya dipantulkan ke atmosfer, sebagian ada yang lolos ke angkasa dan sebagian lagi tertahan oleh gas-gas rumah kaca yang ada di atmosfer. Besar kecilnya kesetimbangan radiasi matahari sangat ditentukan oleh radiasi yang datang (*incoming*) dan radiasi yang dipancarkan (*outgoing*). Masalah kesetimbangan radiasi matahari akan dapat menjelaskan efek rumah kaca yang berperan dalam mempengaruhi temperatur permukaan. Salah satu masalah yang utama pada lingkungan adalah pemanasan yang ditimbulkan oleh radiasi matahari.

Data radiasi surya yang biasanya diamati dan diukur oleh stasiun BMKG (Badan Meteorologi Klimatologi dan Geofisika) umumnya adalah radiasi global dengan jumlah stasiun pengamatan yang terbatas, karena tidak semua stasiun BMKG mengamatinya. Hal tersebut disebabkan karena terbatasnya alat ukur radiasi surya yang dimiliki. Selain itu distribusi stasiun pengamatannya tidak merata di wilayah nusantara. Usaha untuk membuat/memperbanyak stasiun pengamatan radiasi surya di seluruh wilayah nusantara akan memerlukan biaya yang sangat besar dan memakan waktu yang cukup lama. Untuk memenuhi ketersediaan data radiasi yang memadai, maka diperlukan suatu cara yang efektif dan efisien. Salah satu diantaranya adalah dengan cara membuat model prediksi berdasarkan data-data yang ada (data yang diperoleh dari pengamatan beberapa stasiun BMKG) maupun menggunakan beberapa persamaan matematis serta data yang telah dipublikasikan oleh peneliti-peneliti radiasi surya terdahulu. Schuëpp telah mengembangkan persamaan matematis menggunakan data radiasi surya diluar atmosfer atau kondisi atmosfer standar. Sedangkan Angstrom, mengembangkan suatu korelasi untuk memprediksi radiasi surya global pada bidang horizontal menggunakan data Lama Penyinaran Matahari (LPM) yang dikenal dengan korelasi Angstrom. Dengan analisa menggunakan persamaan-persamaan tersebut serta melakukan interpolasi, akan diperoleh beberapa jenis data menyangkut jumlah radiasi surya, baik radiasi global, radiasi langsung ataupun radiasi baur di lokasi dimana tidak terdapat stasiun BMKG [19].

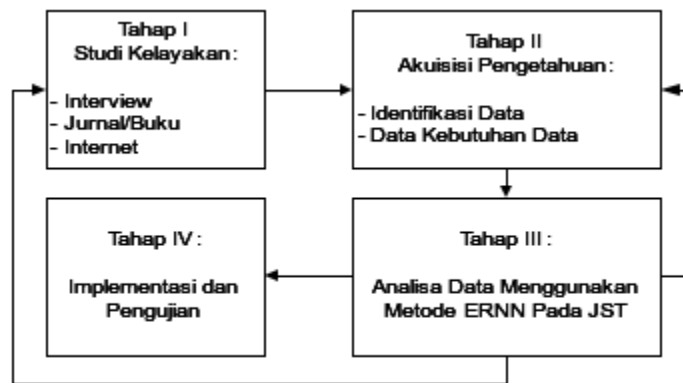
Jaringan Syaraf Tiruan merupakan salah satu representasi buatan dari otak manusia yang selalu mencoba untuk mensimulasikan proses pembelajaran pada otak manusia tersebut. Istilah buatan disini digunakan karena jaringan syaraf ini diimplemintasikan dengan menggunakan program komputer yang mampu menyelesaikan sejumlah proses perhitungan selama proses pembelajaran. [3]. *Elman Recurrent Neural Network* (ERNN) merupakan salah satu pengembangan dari algoritma jaringan syaraf tiruan *Backpropagation*. Perbedaan antara kedua algoritma ini yaitu pada ERNN mempunyai *feedback* di *hidden*. Dari hasil *feedback* tersebut menghasilkan tambahan *layer* yang disebut *context layer*. Adanya *context layer* dapat membuat iterasi dan kecepatan *update* parameter lebih baik. Hal ini memungkinkan untuk melakukan perhitungan berdasarkan nilai dari perhitungan sebelumnya, sehingga membuat jaringan syaraf elman lebih sesuai dalam melakukan peramalan atau [18].

Penelitian terkait algoritma ERNN yang telah dilakukan sebelumnya antara lain "Penerapan *Elman Recurrent Neural Network* Pada Peramalan Konsumsi Listrik Jangka Pendek di PT. PLN APP Malang" [15], dan "Penggunaan *Elman Recurrent Neural Network* dalam Peramalan Suhu Udara sebagai Faktor yang Mempengaruhi Kebakaran Hutan" [8], "Penerapan Metode *Elman Recurrent Neural Network* (ERNN) Untuk Peramalan Penjualan" [4]. Pada penelitian-penelitian tersebut memaparkan kehandalan algoritma ERNN dalam melakukan prediksi atau peramalan dengan menghasilkan nilai *error* pada RMSE dan MAPE yang sangat kecil dan persentasi akurasi yang tinggi.

Berdasarkan permasalahan tersebut, penelitian ini melakukan prediksi besaran radiasi matahari menggunakan algoritma ERNN. Algoritma ERNN ini akan memprediksi besaran pancaran radiasi matahari (W/m^2) menggunakan data-data masukan hasil pencatatan BMKG Kota Pekanbaru yang dipengaruhinya yaitu durasi penyinaran matahari (%), suhu udara ($^{\circ}C$), curah hujan (mm) dan kelembaban udara (%).

2. Metodologi Penelitian

Metodologi penelitian dalam memprediksi radiasi matahari menggunakan metode ERNN pada JST dapat dilihat pada gambar 1.



Gambar 1. Metodologi Metode ERNN pada JST

Tahap I: Studi Kelayakan; Melakukan wawancara dengan para ahli di BMKG Kota Pekanbaru untuk mendapatkan informasi. Kemudian melakukan studi literatur dari jurnal, buku dan internet.

Tahap II: Akuisisi Pengetahuan; Pada tahapan ini merupakan tahapan akuisisi pengetahuan. Dimulai dengan identifikasi permasalahan dan bagaimana melakukan analisis terhadap radiasi matahari ini dengan menggunakan metode ERNN pada JST.

Tahap III: Analisa Data Menggunakan Metode ERNN Pada JST; Tahap ini merupakan tahap analisa terhadap data-data yang telah dikumpulkan. Analisa berguna untuk mengetahui alur proses yang diinginkan. Pada tahap ini dilakukan analisa terhadap faktor yang mempengaruhi intensitas pancaran radiasi matahari yang sampai ke bumi (kota Pekanbaru) dan proses penerapan metode ERNN dalam melakukan prediksi.

Arsitektur *Elman recurrent neural network* hampir sama dengan arsitektur *feed forward backpropagation*, namun ditambah dengan *layer context* untuk menampung *output* dari *hidden layer* [10]. Perbedaan utama yang terdapat pada ERNN adalah masukan jaringan tidak hanya nilai masukan dari luar jaringan tetapi juga ditambah dengan nilai keluaran dari *neuron* tersembunyi sebagai nilai masukan. Jaringan Elman terdiri dari *input layer*, *hidden layer*, *context layer*, dan *output layer*. Lapisan pertama memiliki bobot-bobot yang diperoleh dari lapisan *input*. Seperti halnya jaringan saraf yang lain, setiap lapisan akan menerima bobot dari lapisan sebelumnya. Semua lapisan kecuali lapisan terakhir memiliki satu bobot *recurrent*, semua lapisan memiliki bias.

Algoritma *Elman Recurrent Neural Network* terdiri dari dua tahapan, yaitu *feed forward* dan *backpropagation*. Secara umum langkah dalam pelatihan *Elman backpropagation* sama dengan *backpropagation* biasa hanya saja dalam *Elman backpropagation* menggunakan nilai keluaran dari *hidden layer*, $y_{hidden}(t-1)$ sebagai masukan tambahan yang disebut dengan *context layer*. Galat dalam *hidden layer* hanya digunakan untuk memodifikasi bobot untuk masukan tambahan ini. Algoritma pembelajaran ini juga juga disebut sebagai algoritma pembelajaran *Back Propagation Trough Time* (BPTT). Berikut algoritma ERNN Secara Lengkap :

1. Memberikan nilai inisialisasi bobot antara *input-hidden layer* dan *hidden-output layer*, *learning rate*, toleransi *error*, dan maksimal *epoch*.
2. Setiap unit *input* x_i akan menerima sinyal *input* dan kemudian sinyal *input* tersebut akan dikirimkan pada seluruh unit yang terdapat pada *hidden layer*.
3. Setiap unit *hidden layer* $net_j(t)$ akan ditambahkan dengan nilai masukannya x_i yang akan dikalikan dengan v_{ji} dan dikombinasikan dengan *context layer* $y_h(t-1)$ yang dikalikan bobot uji dijumlahkan dengan bias θ_j dengan persamaan :

$$net_j = \left(\sum_i^n x_i(t) v_{ji} + \sum_h^m y_h(t-1) u_{jh} + \theta_j \right) \quad (1)$$

Kerangan:

- x_i = *input* dari 1, ..., n
- v_{ji} = bobot dari *input* ke *hidden layer*
- y_h = hasil *copy* dari *hidden layer* waktu ke (t-1)

- u_{jn} = bobot dari *context* ke *hidden layer*
- θ = bias
- n = jumlah *node* masukan
- i = *node input*
- m = jumlah *node hidden*
- h = *node context*

Untuk fungsi pengaktif neuron yang digunakan adalah *sigmoid biner* dengan persamaan :

$$y_j(t) = f(\text{net}_j(t)) \quad (2)$$

$$f(\text{net}_j) = \frac{1}{1 + e^{-\text{net}_j}} \quad (3)$$

4. Setiap unit yang terdapat pada y_k akan ditambahkan dengan nilai keluaran pada *hidden layer* y_j yang dikalikan dengan bobot w_{kj} dan dijumlahkan dengan bias bagian *hidden layer* untuk mendapatkan keluaran, maka net_k akan dilakukan perhitungan dalam fungsi pengaktif menjadi y_k dengan persamaan :

$$\text{net}_k(t) = (\sum_j^m y_j(t)w_{kj}) + \theta_k \quad (4)$$

$$y_k(t) = g(\text{net}_k(t)) \quad (5)$$

Keterangan:

- y_j = hasil fungsi net_j
- w_{kj} = bobot dari *hidden* ke *output layer*
- θ_k = bias
- y_k = hasil fungsi net_k
- $g(\text{net}_k(t))$ = fungsi $\text{net}_k(t)$

5. Setiap unit *output* akan menerima pola target t_k sesuai dengan pola masukan pada saat proses pelatihan dan akan dihitung nilai *error* nya dan dilakukan perbaikan terhadap nilai bobot. Proses perhitungan nilai *error* dalam turunan fungsi pengaktif dengan persamaan :

$$\delta_k = g'(\text{net}_k) (t_k - y_k) \quad (6)$$

Keterangan:

- $g'(\text{net}_k)$ = fungsi turunan $g(\text{net}_k)$
- t_k = target
- y_k = hasil fungsi $g(\text{net}_k)$

Perhitungan perbaikan nilai bobot dengan persamaan :

$$\Delta w_{kj} = \alpha \delta_k y_j \quad (7)$$

Perhitungan perbaikan nilai kolerasi dengan persamaan :

$$\Delta \theta_k = \alpha \delta_k \quad (8)$$

Keterangan:

- $\Delta \theta_k$ = hasil perbaikan nilai bias, dan nilai yang diperoleh akan digunakan pada semua unit lapisan sebelumnya.

6. Setiap *output* yang menghubungkan antara unit *output* dan unit *hidden layer* akan dikalikan dengan δ_k dan dijumlahkan sebagai masukan unit yang selanjutnya dengan persamaan :

$$\delta_{net_j} = \sum \delta_k w_{kj} \quad (9)$$

Kemudian dikalikan dengan turunan fungsi aktivasi untuk memperoleh galat dengan persamaan :

$$\delta_j = \delta_{net_j} f'(net_j) \quad (10)$$

Selanjutnya lakukan perhitungan perbaikan terhadap nilai bobot dengan persamaan :

$$\Delta v_{kj} = \alpha \delta_j x_i \quad (11)$$

Hitung perbaikan nilai kolerasi dengan persamaan :

$$\Delta \theta_j = \alpha \delta_j \quad (12)$$

7. Setiap unit *output* akan dilakukan perbaikan terhadap nilai bobot dan biasanya dengan persamaan :

$$w_{kj}(\text{baru}) = w_{kj}(\text{lama}) + \Delta w_{kj} \quad (13)$$

Keterangan:

$w_{kj}(\text{baru})$ = nilai bobot baru dari *input* ke *hidden layer*
 $w_{kj}(\text{lama})$ = nilai bobot lama dari *input* ke *hidden layer*

Tiap unit *hidden layer* juga dilakukan perbaikan terhadap nilai bobot dan biasanya dengan persamaan :

$$v_{kj}(\text{baru}) = v_{kj}(\text{lama}) + \Delta v_{kj} \quad (14)$$

Keterangan:

$v_{kj}(\text{baru})$ = nilai bobot baru dari *hidden* ke *output layer*
 $v_{kj}(\text{lama})$ = nilai bobot lama dari *hidden* ke *output layer*

8. Setiap *ouput* akan dibandingkan dengan target t_k yang diinginkan, agar memperoleh nilai *error* (E) keseluruhan dengan persamaan :

$$E(t) = \frac{1}{2} \sum_{i=1}^k (t_k - y_k)^2 \quad (15)$$


9. Lakukan pengujian kondisi pemberhentian (akhir iterasi).

Proses pelatihan berhasil apabila nilai *error* pada saat iterasi pelatihan nilainya semakin mengecil hingga diperoleh nilai bobot yang baik pada setiap *neuron* untuk data pelatihan yang diberikan. Sedangkan proses pelatihan tidak berhasil yaitu apabila nilai *error* pada saat iterasi pelatihan tidak memberikan nilai yang cenderung mengecil.

Tahap IV: Implementasi dan Pengujian; Implementasi metode *ERNN* dalam memprediksi radiasi matahari dilakukan dengan membangun sebuah sistem berbasis web. Pengujian pada penelitian ini mencakup pengujian akurasi dari penerapan metode *ERNN* dan pengujian fungsionalitas sistem yang dibuat.

3. Hasil dan Pembahasan

Arsitektur jaringan syaraf tiruan menggunakan metode *Elman Recurrent Neural Network (ERNN)* yang dibangun dapat dilihat pada Gambar 2.



Gambar 2. Arsitektur JST Metode *ERNN* dalam Memprediksi Radiasi Matahari

Penjelasan Gambar 2 di atas sebagai berikut:

1. Data masukan merupakan data yang berasal dari BMKG Pekanbaru selama lima tahun yaitu Januari 2013 sampai Desember 2017 dengan variabel suhu udara, curah hujan, lama penyinaran matahari dan kelembapan udara yang diinisialisasikan sebagai X_1 , X_2 , X_3 dan X_4 .
2. Nilai masukan dinormalisasi terlebih dahulu kemudian ditransfer dari *input layer* menuju *hidden layer* menggunakan fungsi aktivasi *sigmoid biner*.
3. Pada *hidden layer* terdapat empat *neuron* yang disimbolkan dengan net_j , setiap *neuron* akan diteruskan menuju *context layer* yang disimbolkan dengan Y_h . Jumlah *neuron* yang terdapat pada *hidden layer* sama dengan jumlah *neuron* yang terdapat pada *context layer*.
4. Proses perhitungan dapat dilakukan dengan pemberian nilai parameter awal, yaitu nilai bobot v , nilai bobot w dan nilai bias.

Pengujian Akurasi

Pengujian akurasi dilakukan dengan membuat beberapa skenario uji yaitu dengan merubah nilai-nilai parameter *learning rate* (dimulai dari 0,1 hingga 0,9) dan pembagian data latih dan data uji. Nilai maksimum *epoch* pada skenario uji ini tetap yaitu 500, begitu juga nilai *minimum error* sebesar 0,0001. Hasil yang diperoleh adalah nilai akurasi terbaik dicapai sebesar 96,531% pada pembagian data latih dan data uji 90% : 10% dengan set parameter *learning rate (alpha)* bernilai 0,9 untuk seluruh skenario perbandingan pembagian data latih dan data uji.

Tabel 1. Hasil Pengujian Implementasi Metode *ERNN* dalam Memprediksi Radiasi Matahari

Perbandingan Data Latih dan Data Uji = 70 % : 30%				Perbandingan Data Latih dan Data Uji = 80 % : 20%				Perbandingan Data Latih dan Data Uji = 90 % : 10%			
<i>Epoch</i>	<i>Min. Error</i>	<i>Al-pha</i>	Nilai Akurasi	<i>Epoch</i>	<i>Min. Error</i>	<i>Al-pha</i>	Nilai Akurasi	<i>Epoch</i>	<i>Min. Error</i>	<i>Al-pha</i>	Nilai Akurasi
500	0,0001	0,1	92,446%	500	0,0001	0,1	92,906%	500	0,0001	0,1	96,334 %
500	0,0001	0,2	91,945%	500	0,0001	0,2	93,341%	500	0,0001	0,2	96,531

	1				1						%
500	0,000 1	0,3	91,864%	500	0,000 1	0,3	93,502%	500	0,0001	0,3	96,066 %
500	0,000 1	0,4	91,164%	500	0,000 1	0,4	93,303%	500	0,0001	0,4	95,422 %
500	0,000 1	0,5	90,056%	500	0,000 1	0,5	92,961%	500	0,0001	0,5	95,243 %
500	0,000 1	0,6	88,649%	500	0,000 1	0,6	92,687%	500	0,0001	0,6	94,960 %
500	0,000 1	0,7	87,974%	500	0,000 1	0,7	92,944%	500	0,0001	0,7	94,622 %
500	0,000 1	0,8	87,966%	500	0,000 1	0,8	92,878%	500	0,0001	0,8	94,282 %
500	0,000 1	0,9	87,991%	500	0,000 1	0,9	92,948%	500	0,0001	0,9	93,966 %

4. Kesimpulan

Pada tahap pelatihan dan pengujian sistem jaringan syaraf tiruan memiliki beberapa kelebihan, antara lain proses yang akurat, cepat, serta meminimalisir kesalahan. Pada JST yang perlu dilakukan adalah melatih jaringan untuk “belajar” dengan cara memasukkan set data yang berisi sekumpulan kasus kedalam jaringan.

Berdasarkan hasil dari evaluasi pelatihan dan pengujian penerapan metode ERNN dalam memprediksi radiasi matahari didapatkan kesimpulan :

1. Metode ERNN pada jaringan syaraf tiruan melakukan perhitungan variabel secara menyeluruh, sehingga hasil *output* yang dikeluarkan jelas dan nilai selisih antara *output* dan target dapat tergambar dengan jelas.
2. Metode JST dapat memberikan nilai prediksi, persentase *error* dan nilai *error* rata-rata.
3. Hasil pengujian akurasi pada beberapa skenario uji yang dilakukan adalah :
 - a. Pembagian data latih dan data uji sebesar 70% : 30% menghasilkan nilai akurasi terbaik pada *Epoch* 500, *Minimum Error* 0,0001, *Learning Rate (Alpha)* 0,1 yakni sebesar 92,446%.
 - b. Pembagian data latih dan data uji sebesar 80% : 20% menghasilkan nilai akurasi terbaik pada *Epoch* 500, *Minimum Error* 0,0001, *Learning Rate (Alpha)* 0,3 yakni sebesar 93,502%.
 - c. Pembagian data latih dan data uji sebesar 90% : 10% menghasilkan nilai akurasi terbaik pada *Epoch* 500, *Minimum Error* 0,0001, *Learning Rate (Alpha)* 0,2 yakni sebesar 96,531%.

Daftar Pustaka

- [1] Budiati, T. dkk. *Dampak Kelembapan Udara Terhadap Radiasi Matahari Dan Temperatur Di Bandung*. 2011. 12–13.
- [2] Chandra, R. *Competition and Collaboration in Cooperative Coevolution of Elman Recurrent Neural Networks for Time-Series Prediction*. 2015. 26 (12), 3123–3136.
- [3] Cynthia, E.P. dan Ismanto, E. *Jaringan Syaraf Tiruan Algoritma Backpropagation Dalam Memprediksi Ketersediaan Komoditi Pangan Provinsi Riau*. 2017. Seminar Nasional Teknologi Informasi, Komunikasi dan Industri (SNTIKI) ke-9: Pekanbaru, UIN Sultan Syarif Kasim Riau. 271-282.
- [4] Cynthia, et.al. *Penerapan Metode Elman Recurrent Neural Network Untuk Peramalan Penjualan*. 2019. Journal of Education and Information Technology, Vol.2 No.1: Pekanbaru, FKIP Universitas Muhammadiyah Riau. 49-61.
- [5] Desvina, A. *Analisis Time Series Pencemaran Udara Oleh Karbon Monoksida (CO) di Pekanbaru*. Pekanbaru. 2011: Pusaka Riau.
- [6] Halim, S., & Wibisono, A. M. *Penerapan jaringan saraf tiruan untuk peramalan*. 2011. 2(2), 106–113.
- [7] Humairah, E. *Penerapan Jaringan Saraf Tiruan Elman Recurrent Neural Network untuk Prediksi Penjualan Garuda Food*. 2017.
- [8] Maulida. *Penggunaan Elman Recurrent Neural Network dalam Peramalan Suhu Udara sebagai Faktor yang Mempengaruhi Kebakaran Hutan*. 2011.

- [9] Ningsih, R. A. *Aplikasi Model Vector Autoregressive (VAR) Untuk Peramalan Suhu Udara Kota Pekanbaru*. 2016.
- [10] Permana, A. A. J., Prijodiprodjo, W. *Sistem Evaluasi Kelayakan Mahasiswa Magang Menggunakan Elman Recurrent Neural Network*. 2014. 8(1), 37–48.
- [11] Pujiastuti, D., & Ilahi, A. F. *Fluktuasi Konsentrasi Ozon Permukaan Di Bukit Kototabang Tahun 2005-2010*. 2014. 3(3), 177–183.
- [12] Purnomo, D. S., Wibowo, A. T., & Suliiyo, M. D. *Analisis Dan Implementasi Elman Recurrent Neural Network Dan Firefly Algorithm Pada Prediksi Harga Minyak Mentah*. 2014.
- [13] Salman, A. G., Prasetio, Y. L. *Implementasi Jaringan Saraf Tiruan Recurrent Dengan Metode Pembelajaran Gradient Descent Adaptive Learning Rate Untuk Pendugaan Curah Hujan Berdasarkan Peubah Enso*. 2010. 1(2), 418–429.
- [14] Sani, D. L. *Penerapan Elman- Recurrent Neural Network Pada Peramalan Konsumsi Listrik Jangka Pendek Di Pt. Pln App Malang*. 2014. 441– 444.
- [15] Sanny, L., Sarjono, H., Smoothing, E., Trend, W., Smoothing, E., & Moving, W. *Peramalan Jumlah Siswa / I Sekolah Menengah Atas Swasta Menggunakan Enam Metode*. 2013. 10, 198–208.
- [16] Suhartono, Endharta, A. *Peramalan Konsumsi Listrik Jangka Pendek Dengan Arima Musiman Ganda Dan Elman-Recurrent Neural*. 2009, 183– 192.
- [17] Syafitri, M. *Penerapan Metode Elman Recurrent Neural Network Untuk Prediksi Hasil Produksi Pabrik Kelapa Sawit*. 2019. Pekanbaru: Uin-Suska Riau.
- [18] Talahatu, J., Benarkah, N., Jimmy. *Penggunaan Aplikasi Sistem Jaringan Saraf Tiruan Berulang Elman Untuk Prediksi Pergerakan Harga Saham*. 2015. 4(1), 1–12.
- [19] Utomo, Y. S. *Prediksi radiasi surya global bulanan kota bandung menggunakan data lpm (lama penyinaran matahari)*. *Jurnal Material Dan Energi Indonesia FMIPA Universitas Padjadjaran*, 2017. 07(02), 21–27.
- [20] Yanti, N. *Prediksi Stok Obat di Apotek Menggunakan Metode Neural Network dengan Struktur Backpropagation*. 2014. Pekanbaru: LPPM UIN-SUSKA RIAU.
- [21] Zhang, N., & Williams, C. *Solar Radiation Prediction Based On Particle Swarm Optimization And Evolutionary Algorithm Using Recurrent Neural Networks*. 2013.