

Algoritma *Backpropagation Neural Network* dalam Memprediksi Harga Komoditi Tanaman Karet

Julius Rinaldi Simanungkalit ^{a,1}, Haviluddin Haviluddin ^{a,2,*} dan Herman Santoso Pakpahan ^{a,3},
Novianti Puspitasari ^{a,4} dan Masna Wati ^{a,5}

^a Universitas Mulawarman, Jl. Kuaro I, Kampus Sempaja, Samarinda, Kalimantan Timur 75119

¹simanungkalit100@gmail.com; ²haviluddin@unmul.ac.id; ³pakpahan.herman891@gmail.com;

⁴novianti_miechan@yahoo.com; ⁵masnawati.ssi@gmail.com

* corresponding author

INFORMASI ARTIKEL	ABSTRAK
<p>Dikirim: 11 Februari 2020 Diulas: 19 Februari 2020 Direvisi: 10 April 2020 Diterbitkan: 27 April 2020</p> <p>Kata Kunci: Komoditas Harga Karet Prediksi BPNN MSE</p>	<p>Sektor perkebunan tanaman karet merupakan salah satu komoditas unggulan Provinsi Kalimantan Timur yang memberikan kontribusi besar terhadap ekspor nonmigas. Saat ini, harga tanaman karet di dunia semakin bersaing. Tujuan penulisan artikel ini adalah melakukan prediksi harga tanaman karet dimana hasil prediksi digunakan sebagai acuan instansi pemerintahan dan perusahaan dalam mengambil suatu kebijakan dan penyusunan rencana kerja. Penelitian ini menerapkan algoritma <i>Backpropagation Neural Network</i> (BPNN) dalam memprediksi harga tanaman karet. Sebanyak 60 bulan atau periode tahun 2014-2018 yang berasal dari Dinas Perkebunan Provinsi Kalimantan Timur telah digunakan untuk dianalisa. Berdasarkan hasil pengujian, parameter algoritma BPNN dengan rasio data 4:1, model arsitektur 5-10-10-10-1, fungsi pembelajaran <i>trainlm</i>, <i>learning rate</i> sebesar 0.5, toleransi <i>error</i> sebesar 0.01 dan <i>epoch</i> sebesar 1000 telah mendapatkan akurasi baik dengan nilai <i>mean square error</i> (MSE) sebesar 0.00015464. Hasil penelitian memperlihatkan bahwa algoritma BPNN dapat dijadikan salah satu alternatif metode peramalan.</p>
<p>Keywords: Commodity Rubber prices Prediction BPNN MSE</p>	<p>ABSTRACT</p> <p>Rubber plantation sector is one of the leading commodities in East Kalimantan Province contributing greatly to non-oil and gas exports. Currently, the price of rubber in the world is increasingly competitive. The aim of this research is to predict the rubber prices as a reference for the government and companies in making policies and preparing work plans. Data of 60 months during the period of 2014-2018 taken from Plantation office of East Kalimantan Province has been analyzed using Backpropagation Neural Network (BPNN) algorithm in predicting rubber prices. Based on the testing results, parameters of the BPNN algorithm with ratio of 4: 1, architectural models 5-10-10-10-1, trainlm learning function, learning rate of 0.5, error tolerance of 0.01, and epoch of 1000 have gained good accuracy with a mean square error (MSE) of 0.00015464. The results showed that the BPNN algorithm can be used as an alternative method in forecasting.</p>

This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.



I. Pendahuluan

Indonesia merupakan negara penghasil karet terbesar di dunia setelah Thailand. Karet merupakan komoditas perkebunan yang memiliki peran cukup strategis dalam perekonomian bangsa. Produksi karet Indonesia cukup besar dalam pasar Internasional Sehingga, dalam neraca perdagangan negara, sektor perkebunan karet merupakan penyumbang devisa negara kedua terbesar setelah kelapa sawit. Karet merupakan komoditi yang tingkat permintaan dan produksinya sering mengalami peningkatan yang signifikan setiap waktu. Pada tahun 2002, volume ekspor sebesar 1,496 juta ton atau senilai USD 1038 juta, sedangkan pada tahun 2010 meningkat sebesar 2.35 juta ton atau 57% atau senilai USD 7330 juta [1], [2]. Provinsi Kalimantan Timur merupakan salah satu provinsi yang memiliki pertumbuhan perkebunan karet yang cukup baik. Pada tahun 2018, total luas lahan perkebunan tanaman karet mencapai 115.082 hektar (ha) terdiri dari Perkebunan Rakyat (PR) sebesar 92.354 ha, Perkebunan Besar Swasta (PSR) sebesar 22.329 ha, dan Perkebunan Besar

Negara (PBN) sebesar 339 ha yang tersebar di 10 kota/kabupaten. Dari luas lahan tersebut, produksi perkebunan tanaman karet sebanyak 57.389 ton dan produktivitas sebanyak 1.220 kg/ha dengan harga rata-rata komoditi tanaman karet untuk tahun 2018 sebesar Rp. 6.800 per kilogram. Sedangkan, Tenaga Kerja Perkebunan (TKP) sebanyak 64.825 [2][3].

Peneliti, Rofiq, menggunakan metode *Backpropagation Neural Network* (BPNN) untuk memprediksi komoditas strategis pertanian cabai. Tingkat akurasi yang didapatkan dari rata-rata error perbandingan data aktual dan data peramalan (MAPE) yaitu sebesar 16.193% [4]. Sedangkan, menggunakan metode BPNN berbasis *Particle Swarm Optimization* (PSO) untuk memprediksi harga karet spesifik teknis. Hasil pengujian menggunakan BPNN saja menghasilkan nilai *root mean square error* (RSME) sebesar 0.043 sedangkan dengan menggunakan model BPNN yang dioptimasi dengan PSO menghasilkan nilai RSME yang lebih kecil yaitu 0.040 [5]. Lebih lanjut, menggunakan metode BPNN untuk memprediksi harga saham (IHSG). Proses prediksi menghasilkan tingkat keakuratan sebesar 99.98% dan MSE sebesar 0.9915 [6]. Penelitian prediksi harga komoditi kopi arabika menggunakan algoritma *K-Nearest Neighbor* (KNN) yang dikombinasikan dengan metode *Backward Elimination* (BE) untuk mendapatkan akurasi prediksi yang baik telah dilakukan. Hasil eksperimen penelitian ini menunjukkan kombinasi algoritma tersebut dapat memperkecil nilai error, dibandingkan dengan KNN tanpa seleksi fitur dan BPNN, BPNN dengan BE [7]. Selanjutnya, prediksi harga komoditi jagung menggunakan algoritma *K-Nearest Neighbor* (KNN) berbasis Particle PSO. Hasil eksperimen penelitian ini menunjukkan bahwa algoritma ini menghasilkan nilai RMSE 0.06 yang berarti akurasi prediksi cukup baik [8].

Para peneliti telah memperlihatkan berbagai algoritma kecerdasan buatan yang digunakan untuk melakukan prediksi, klasifikasi, cluster dalam berbagai bidang seperti pertanian [9], [10], kesehatan [11], perbankan [12], keteknikan [13], [14] dan lain-lain. Hal ini menunjukkan bahwa algoritma cerdas menjadi pilihan bagi para peneliti untuk melakukan analisa [15]. Tujuan penelitian ini adalah menerapkan algoritma kecerdasan buatan yaitu BPNN untuk mendapatkan hasil prediksi harga karet secara akurat. Artikel ini terdiri dari motivasi penulisan pada bagian Pendahuluan. Bagian kedua, metodologi BPNN dijelaskan dengan detail. Bagian ketiga, menjelaskan hasil dan analisa pengolahan data dengan kedua metode tersebut. Bagian terakhir, kesimpulan yang diperoleh.

II. Metode

Bagian ini menjelaskan dengan detail metode BPNN, pengukuran hasil simulasi prediksi dan data yang digunakan dalam penelitian ini.

A. *Backpropagation Neural Network*

Metode *Backpropagation Neural Network* (BPNN) pertama kali diperkenalkan oleh Paul Werbos pada tahun 1974, kemudian dikemukakan kembali oleh David Parker di tahun 1982 dan kemudian dipopulerkan oleh Rumelhart dan McClland pada tahun 1986. Pada Algoritma BPNN arsitektur jaringan menggunakan jaringan multilayer [16–19]. Secara prinsip, arsitektur BPNN terdiri dari tiga *layer*, yaitu *input layer*, *hidden layer* dan *output layer*. Pada *input layer* tidak terjadi proses komputasi, namun pada *input layer* terjadi pengiriman sinyal input X ke *hidden layer*. Pada *hidden* dan *output layer* terjadi proses komputasi terhadap bobot dan bias dan dihitung pula besarnya *output* dari *hidden* dan *output layer* tersebut berdasarkan fungsi aktivasi tertentu. Adapun, fungsi aktivasi biasanya digunakan *sigmoid biner* dengan *output* [0-1]. Flowchart BPNN dapat dilihat pada Gambar 1.

Langkah-langkah yang perlu dilakukan untuk pelatihan BPNN adalah:

- 1) Inisialisasi bobot dengan bilangan nilai acak kecil.
- 2) Selama kondisi berhenti tidak terpenuhi, kerjakan langkah 3 – 8.

Tahap 1: Umpan Maju (*Feed forward*)

- 3) Tiap unit masukan ($x_i, i = 1, \dots, n$) menerima isyarat masukan x_i dan diteruskan ke unit-unit tersembunyi (*hidden layer*).
- 4) Tiap unit tersembunyi ($z_j, j = 1, \dots, p$) menjumlahkan bobot sinyal *input* dengan persamaan (1).

$$Z_{injk} = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (1)$$

Dimana, Z adalah *neuron hidden*; v_{0j} adalah bobot *bias neuron input* ke- j ; x_i adalah *neuron input* ke- i ; v_{ij} adalah bobot *neuron input* ke *neuron hidden*.

Dengan menerapkan fungsi aktivasi yang dihitung dengan persamaan (2).

$$Z_j = f(Z_{in_j}) \quad (2)$$

Dimana, Z_j adalah unit ke- j pada lapisan tersembunyi; Z_{in_j} adalah keluaran untuk unit Z_j

Misal, fungsi aktivasi yang digunakan yaitu *sigmoid* dengan persamaan (3).

$$Y = f(x) = \frac{1}{1+e^{-x}} \quad (3)$$

Dan mengirimkan isyarat ini kesemua unit pada unit keluaran.

- 5) Tiap unit keluaran ($y_k, k = 1, \dots, m$) menjumlahkan isyarat masukan berbobot dengan menggunakan persamaan (4).

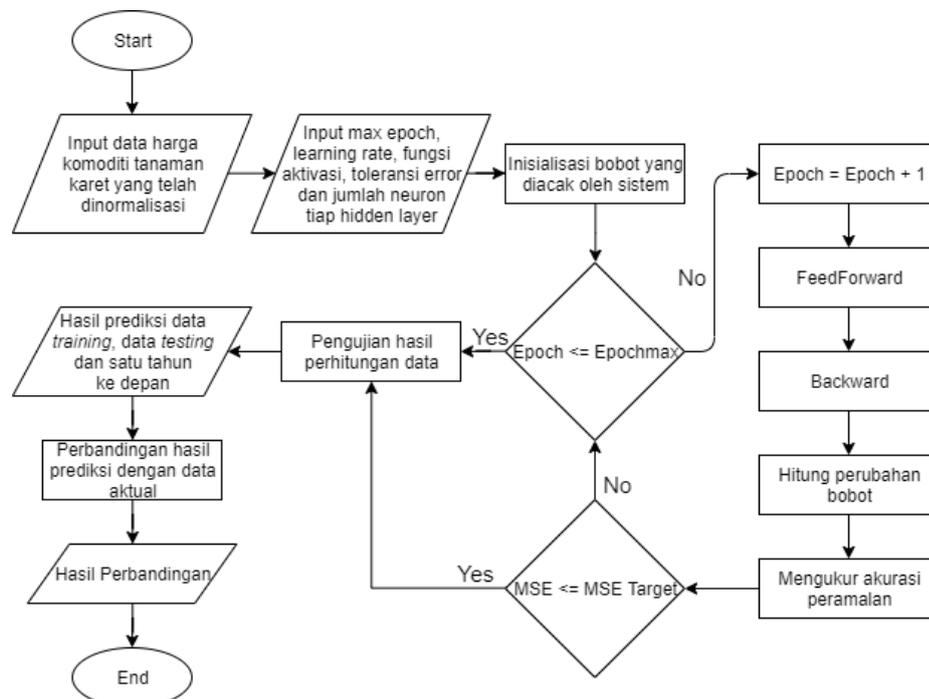
$$Y_{in_k} = w_{0k} + \sum_{j=1}^p z_j w_{jk} \quad (4)$$

Dimana, Y_{in_k} adalah keluaran untuk unit y_k ; w_{0k} adalah bobot *bias* untuk *neuron hidden* ke- k ; z_j adalah unit ke- j pada lapisan tersembunyi; w_{jk} adalah bobot *neuron hidden* ke *neuron output*.

Dengan menerapkan fungsi aktivasi yang dihitung dengan persamaan (5).

$$Y_k = f(Y_{in_k}) \quad (5)$$

Dimana, Y_{in_k} adalah keluaran untuk unit Y_k .



Gambar 1. Flowchart algoritma BPNN

Tahap 2: Perambatan Galat Mundur (*Backward*)

- 6) Tiap unit keluaran ($y_k, k = 1, \dots, m$) menerima pola pelatihan masukannya. Hitung galat (*error*) setiap *layer* dengan persamaan (6).

$$\delta_k = (t_k - y_k) f'(y_{in_k}) \quad (6)$$

Dimana, δ_k adalah faktor koreksi bobot w_{jk} ; t adalah target; y_k adalah *neuron output* ke- k ; y_{in_k} adalah keluaran untuk unit y_k .

Hitung koreksi bobot dan *bias*-nya dengan persamaan (7).

$$\Delta w_{jk} = \alpha \delta_k x_j \quad (7)$$

$$\Delta w_{0k} = \alpha \delta_k$$

Dimana, Δw_{jk} adalah selisih antara $w_{jk}(t)$ dengan $w_{jk}(t+1)$; Δw_{0k} adalah bobot *bias* untuk *neuron hidden* ke- k ; α adalah *learning rate*; δ_k adalah faktor koreksi bobot w_{jk} ; x adalah *input*.

- 7) Tiap unit tersembunyi ($z_j, j = 1, \dots, p$) menjumlahkan *delta* masukannya (dari unit-unit yang berada pada lapisan atasannya) dengan persamaan (8).

$$\delta_{in_j} = \sum_{k=1}^m \delta_k w_{jk} \quad (8)$$

Dimana, δ_k adalah faktor koreksi bobot w_{jk} ; w_{jk} adalah bobot *neuron hidden* ke *neuron output*. Hitung galat (*error*) setiap *layer* dengan persamaan (9).

$$\delta_j = \delta_{in_j} f'(x_{in_j}) \quad (9)$$

Dimana, δ_j adalah faktor koreksi bobot v_{ij} ; δ adalah faktor koreksi; x adalah *input*. Hitung koreksi bobot dan *bias*-nya dengan persamaan (10).

$$\Delta v_{ij} = \alpha \delta_j x_i \quad (10)$$

Dimana, Δv_{ij} adalah bobot *neuron input* ke *neuron hidden*; α adalah *learning rate*; δ_j adalah faktor koreksi bobot v_{ij} ; x_i adalah *neuron input* ke- i .

Tahap 3: Perbaiki bobot dan *bias* (*Update Weight*)

- 8) Tiap unit keluaran ($y_k, k = 1, \dots, m$) memperbaharui bobot dan *bias* ($j = 0, 1, \dots, p$) dihitung dengan persamaan (11).

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad (11)$$

Dimana, w_{jk} adalah bobot *neuron hidden* ke *neuron output*; Δw_{jk} adalah selisih bobot *neuron hidden* ke *neuron output*.

Tiap unit tersembunyi ($z_j, j = 1, \dots, p$) memperbaharui bobot dan *bias*-nya ($i = 0, 1, \dots, n$) dihitung dengan persamaan (12).

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad (12)$$

Dimana, v_{ij} adalah bobot *neuron input* ke *neuron hidden*; Δv_{ij} adalah selisih bobot *neuron input* ke *neuron hidden*.

- 9) Uji syarat berhenti.

B. Akurasi Prediksi

Dalam penelitian ini, metode *Mean Squared Error* (MSE) untuk mengevaluasi kesalahan peramalan pada setiap periode dan membaginya dengan jumlah periode peramalan telah digunakan [20]. Adapun rumus untuk melakukan perhitungan pengukuran akurasi MSE dapat dilihat dalam persamaan (13).

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (13)$$

Dimana, Y_i adalah nilai aktual; \hat{Y}_i nilai prediksi; n jumlah periode atau target.

C. Sampel Data

Dalam penelitian ini, data harga karet dari Januari 2014 hingga Desember 2018 atau sebanyak 60 dataset yang telah diperoleh dari Dinas Perkebunan Provinsi Kalimantan Timur telah digunakan. Tabel 1 menunjukkan Dataset data pelatihan yang telah dinormalisasi dalam jarak (*range*) 0,1 - 0,9 menggunakan persamaan (14).

$$X' = \frac{0,8(X - b)}{(a - b)} + 0,1 \quad (14)$$

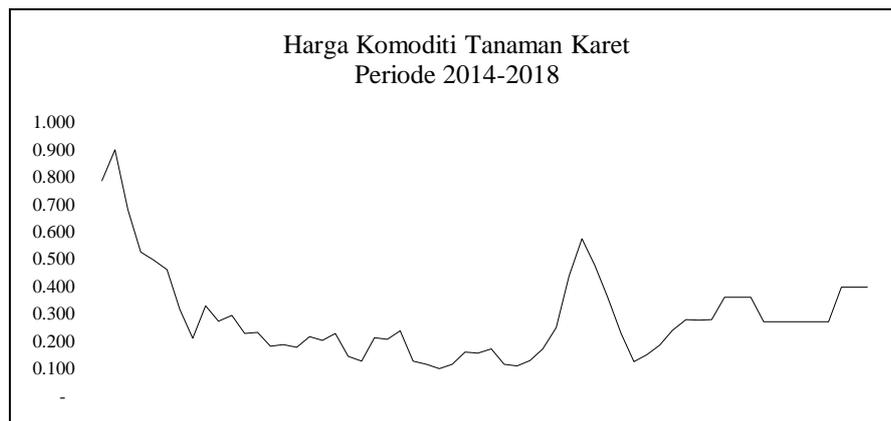
Dimana, X' adalah data hasil normalisasi; X adalah data aktual; a adalah nilai maksimum data aktual; b adalah nilai minimum data aktual. Gambar 2 menunjukkan pola data harga tanaman karet dalam periode tersebut.

Kemudian dilakukan proses perhitungan prediksi dengan kedua metode tersebut. Hasil prediksi didenormalisasi untuk mendapatkan hasil prediksi ke bentuk semula. Adapun rumus untuk melakukan denormalisasi data dapat dilihat dalam persamaan (15).

$$X = \frac{(X' - 0,1)(b - a) + 0,8 a}{0,8} \quad (15)$$

Tabel 1. Data Harga Komoditi Tanaman Karet Periode 2014-2018

Bulan	Tahun				
	2014	2015	2016	2017	2018
Januari	0.78648406	0.23237539	0.12658285	0.43767400	0.36115851
Februari	0.90000000	0.18208352	0.11508756	0.57436013	0.36115851
Maret	0.68123035	0.18747194	0.10000000	0.47754827	0.36115851
April	0.52604401	0.17831163	0.11670409	0.36169735	0.27135159
Mei	0.49622811	0.21746744	0.16142793	0.22806466	0.27135159
Juni	0.46192187	0.20399641	0.15711720	0.12514594	0.27135159
Juli	0.31697351	0.22914234	0.17148630	0.15047149	0.27135159
Agustus	0.21082173	0.14418500	0.11580602	0.18675348	0.27135159
September	0.33062416	0.12819937	0.11059722	0.24027840	0.27135159
Oktober	0.27242928	0.21243826	0.12927705	0.27871576	0.39708128
November	0.29470139	0.20740907	0.17256399	0.27745846	0.39708128
Desember	0.22914234	0.23740458	0.24979793	0.27997306	0.39708128



Gambar 2. Harga komoditi tanaman karet 2014-2018

III. Hasil dan Pembahasan

Bagian ini menjelaskan hasil temuan pengujian dan analisa metode BPNN dalam melakukan prediksi harga karet.

Pembagian data aktual sebagai data training dan data testing untuk mendapatkan hasil perbandingan yang baik telah dilakukan. Dalam percobaan ini, rasio data training dan data testing yaitu 4:1 dan 3:2 telah dilakukan. Rasio data 4:1 dengan pembagian data training dari tahun 2014-2017 atau 48 bulan dan data testing tahun 2018 atau 12 bulan. Sedangkan rasio data 3:2 dengan pembagian data training dari tahun 2014-2016 atau 36 bulan dan data testing tahun 2017-2018 atau 24 bulan telah diimplementasikan. Dalam percobaan ini variabel-variabel BPNN yang telah diimplementasikan dapat dilihat pada Tabel 2.

Tabel 2. Variabel BPNN

Variabel	Nilai		
	Hidden Layer	Neuron Hidden Layer	Architectures
Hidden Layer	2	4 4	5-4-4-1
	2	7 7	5-7-7-1
	3	5 5 5	5-5-5-5-1
	3	10 10 10	5-10-10-10-1
Fungsi Pembelajaran	<i>trainlm, traingd, traingdx</i>		
Learning Rate	0.1, 0.3, 0.5, 0.7		
Toleransi Error	0.01		
Max Epoch	1000		

Tabel 3 menunjukkan bahwa berdasarkan percobaan, parameter BPNN dengan rasio data 4:1, model arsitektur 5-10-10-10-1, fungsi pembelajaran *trainlm*, *learning rate* sebesar 0.5, toleransi *error* sebesar 0.01 dan *epoch* sebesar 1000 telah mendapatkan akurasi baik dengan nilai MSE sebesar 0.00015464. Sedangkan, parameter BPNN dengan rasio data 3:2, model arsitektur 5-10-10-10-1, fungsi pembelajaran *trainlm*, *learning rate* sebesar 0.5, toleransi *error* sebesar 0.01 dan *epoch* sebesar 1000 telah mendapatkan akurasi baik dengan nilai MSE sebesar 0.00148924. Dimana, rasio data 4:1 lebih baik dibandingkan 3:2. Hal ini menunjukkan bahwa pembagian data *training* dan data *testing* telah mempengaruhi tingkat akurasi.

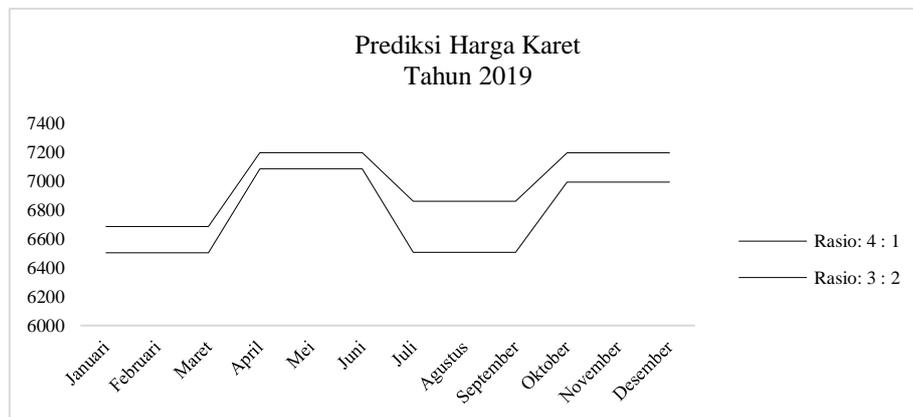
Tabel 3. Akurasi Metode BPNN

Algoritma	Rasio Data	
	4:1	3:2
BPNN	0.00015464	0.00148924

Hasil prediksi harga karet tahun 2019 dengan menggunakan rasio 4:1 dan 3:2 diberikan pada Tabel 4 dan pola harga dapat dilihat pada Gambar 3.

Tabel 4. Hasil Prediksi Harga Karet Tahun 2019

Bulan	BPNN	
	4:1	3:2
Januari	Rp. 6503	Rp. 6685
Februari	Rp. 6503	Rp. 6685
Maret	Rp. 6503	Rp. 6685
April	Rp. 7084	Rp. 7196
Mei	Rp. 7084	Rp. 7196
Juni	Rp. 7084	Rp. 7196
Juli	Rp. 6505	Rp. 6860
Agustus	Rp. 6505	Rp. 6860
September	Rp. 6505	Rp. 6860
Oktober	Rp. 6993	Rp. 7194
November	Rp. 6993	Rp. 7194
Desember	Rp. 6993	Rp. 7194



Gambar 3. Hasil Prediksi Harga Karet Tahun 2019

IV. Kesimpulan dan saran

Analisa prediksi harga komoditi tanaman karet di Provinsi Kalimantan Timur dengan menggunakan metode *Backpropagation Neural Network* (BPNN) telah diimplementasikan. Berdasarkan hasil percobaan, metode BPNN dengan rasio data 4:1, model arsitektur 5-10-10-10-1, fungsi aktivasi *trainlm*, *learning rate* sebesar 0.5, toleransi error sebesar 0.01 dan epoch sebesar 1000 telah mendapatkan tingkat kesalahan prediksi yang cukup baik dengan nilai MSE sebesar 0.00015464. Dari hasil pengujian kedua metode, menunjukkan bahwa metode BPNN dapat menjadi alternatif dalam memprediksi harga komoditi tanaman karet di Provinsi Kalimantan Timur. Penelitian berikutnya dapat menggunakan metode prediksi lainnya untuk meningkatkan nilai prediksi saat ini.

Daftar Pustaka

- [1] K. Dirjen Kerjasama Industri Internasional, "Perkembangan Kerjasama ASEAN di Sektor Industri (s.d. 2011)," 2012.
- [2] D. Perkebunan, "Harga Komoditas Tanaman Karet," 2019. [Online]. Available: <https://disbun.kaltimprov.go.id/kategori-download/harga-tbs-kelapa-sawit-tahun-2011-2017>.
- [3] S. D. Perkebunan, "Komoditas Karet 2011-2013," 2012.
- [4] M. A. Rofiq, *Peramalan Komoditas Strategis Pertanian Cabai Menggunakan Metode Backpropagation Neural Network*. 2017.
- [5] M. A. Puspa, "Backpropagation Neural Network Berbasis *Particle Swarm Optimization* ntuk Prediksi Harga Karet Spesifik Teknis," *J. Teknosains*, Vol. 10, Nomor 2, Juli-Desember 2016, hlm. 197 – 210, vol. Volume 10, pp. 197–210, 2016.
- [6] A. J. P. Triyono, Andri Santoso, "Penerapan Metode Jaringan Syaraf Tiruan *Backpropagation* Untuk

- Meramalkan Harga Saham (IHSG),” *J. Sist. Dan Inform.*, vol. Vol 11, No, pp. 165–172, 2016.
- [7] A. Bode, “K-Nearest Neighbor dengan Feature Selection menggunakan Backward Elimination untuk Prediksi Harga Komoditi Kopi Arabika,” *Ilk. J. Ilm.*, 2017.
- [8] M. E. Lasulika, “Prediksi Harga Komoditi Jagung Menggunakan K-NN dan *Particle Swarm Optimization* sebagai Fitur Seleksi,” *Ilk. J. Ilm.*, 2017.
- [9] I. Santoso, U. Effendi, and C. Fauziya, “Penerapan Jaringan Syaraf Tiruan Untuk Peramalan Permintaan Komoditas Karet di PT Perkebunan Nusantara XII Surabaya,” *J. Teknol. Pertan.*, vol. 8, no. 1, pp. 46–54, 2007.
- [10] S. Wolfert, L. Ge, C. Verdouw, and M. J. Bogaardt, “Big Data in Smart Farming – A review,” *Agricultural Systems*. 2017.
- [11] M. I. Jordan and T. M. Mitchell, “Machine learning: Trends, perspectives, and prospects,” *Science*. 2015.
- [12] T. Fischer and C. Krauss, “Deep learning with long short-term memory networks for financial market predictions,” *Eur. J. Oper. Res.*, vol. 270, no. 2, pp. 654–669, 2018.
- [13] D. Rajasekar, C. Dhanamani, and S. K. Sandhya, “A Survey on Big Data Concepts and Tools,” *Int. J. Emerg. Technol. Adv. Eng.*, vol. 5, no. 2 February 2015, pp. 80–84, 2015.
- [14] C. H. Fajardo-toro, J. Mula, and R. Poler, *Engineering Digital Transformation*. Springer International Publishing, 2019.
- [15] S. Athey, “The Impact of Machine Learning on Economics,” in *The Economics of Artificial Intelligence: An Agenda*, University of Chicago Press, 2018.
- [16] H. Aini and H. Haviluddin, “Crude Palm Oil Prediction Based on Backpropagation Neural Network Approach,” *Knowl. Eng. Data Sci.*, 2019.
- [17] M. Lehtokangas, “Modelling with constructive backpropagation,” *Neural Networks*, 1999.
- [18] Mislán, Haviluddin, S. Hardwinarto, Sumaryono, and M. Aipassa, “Rainfall Monthly Prediction Based on Artificial Neural Network: A Case Study in Tenggarong Station, East Kalimantan - Indonesia,” in *Procedia Computer Science*, 2015.
- [19] P. Purnawansyah, H. Haviluddin, H. J. Setyadi, K. Wong, and R. Alfred, “An Inflation Rate Prediction Based on Backpropagation Neural Network Algorithm,” *Int. J. Artif. Intell. Res.*, vol. 3, no. 2, p. 2019, 2019.
- [20] R. Rojas, “The Backpropagation Algorithm,” in *Neural Networks*, 2011.