

# Prediksi Produksi Minyak Kelapa Sawit Menggunakan Metode Backpropagation Neural Network

<sup>1</sup>Hijratul Aini, <sup>2</sup>Haviluddin, <sup>3</sup>Edy Budiman, <sup>4</sup>Masna Wati, <sup>5</sup>Novianti Puspitasari

*Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Mulawarman*  
*hijratulaini10@gmail.com; haviluddin@unmul.ac.id; edy.budiman@fkti.unmul.ac.id; masnawati.ssi@gmail.com; miechan.novianti@gmail.com*

---

## INFORMASI ARTIKEL

### *Histori Artikel*

Diterima : 20 April 2019  
Direvisi : 29 April 2019  
Diterbitkan : 30 April 2019

### *Kata Kunci:*

Minyak Kelapa Sawit  
Prediksi  
BPNN  
MSE

## ABSTRAK

Artikel ini bertujuan untuk memprediksi produksi minyak kelapa sawit mentah (CPO) di PT. Perkebunan Nusantara (PTPN) XIII, Desa Long Pinang, Kabupaten Paser, Kalimantan Timur dengan menggunakan algoritma cerdas, jaringan saraf tiruan (JST) yang disebut Backpropagation Neural Network (BPNN). Data penelitian berasal dari produksi CPO periode Januari 2015 hingga Januari 2018. Pengukuran akurasi prediksi algoritma BPNN menggunakan metode mean square error (MSE). Berdasarkan hasil percobaan, metode BPNN dengan parameter arsitektur 5-10-11-12-13-1; fungsi pembelajaran adalah trainlm; fungsi aktivasi adalah logsig dan purelin; laju pembelajaran adalah 0.7 mampu menghasilkan tingkat kesalahan prediksi yang baik dengan nilai MSE sebesar 0.0069. Hasil penelitian menunjukkan bahwa model ini dapat digunakan sebagai alternatif metode dalam memprediksi produksi CPO pada tahun 2019.

2019 SAKTI – Sains, Aplikasi, Komputasi dan Teknologi Informasi.

Hak Cipta.

---

## I. Pendahuluan

Saat ini, Indonesia merupakan produsen minyak kelapa sawit mentah (CPO) terbesar di dunia. Kondisi pada tahun 2018 ini ditunjang oleh sebanyak 43 juta ton CPO dengan perkebunan kelapa sawit seluas 14,03 juta hektar, dan 40% di antaranya adalah perkebunan rakyat (PR). Akibatnya, sektor perkebunan dan industri CPO adalah sektor strategis yang berkontribusi signifikan terhadap perekonomian nasional (Kementan, 2018; Norhidayu, Nur-Syazwani, Radzil, Amin, & Balu, 2017; Statistik, 2018). Karena itu, manajemen produksi CPO sangat diperlukan. Hal ini dimaksudkan agar produksi dapat sesuai dengan target dan mencegah kerugian dari biaya produksi dan mendukung manajemen dalam pengambilan keputusan (Meryana, 2017). Untuk memudahkan perencanaan produksi di masa depan, proses estimasi produksi harus didasarkan pada data produksi pada tahun-tahun sebelumnya (Gunawan, Khodra, & Harlili, 2013; Haviluddin & Alfred, 2014; Haviluddin & Jawahir, 2015; Kanchymalay, Sallehuddin, Salim, & Hashim, 2017).

Berbagai metode dalam statistik dan kecerdasan buatan banyak digunakan untuk melakukan prediksi. (Ahmad & Latif, 2011) telah menerapkan metode SARIMA (Seasonal Autoregressive Integrated Moving Average) untuk melakukan prediksi produksi CPO di Malaysia. Dataset yang digunakan untuk prediksi berasal dari perkebunan Kuala Terengganu, Malaysia mulai dari Juni 2001 hingga Mei 2011. Berdasarkan percobaan model SARIMA (0,1,2)(1,1,3)<sup>12</sup> telah menghasilkan nilai akurasi yang cukup baik. (Wan Ahmad & Ahmad, 2013) telah mengidentifikasi metode Autoregressive Moving Average (ARIMA) dan metode Exponential Smoothing (ES) dalam melakukan prediksi. Adapun, dataset berasal dari berbagai sumber seperti harga Crude Palm Oil (RM/tonne), nilai tukar mata uang Ringgit Malaysia (RM) dan Great Britain Pound (GBP), serta harga tipe SMR 20 Rubber Type (cents/kg). Akurasi prediksi yang digunakan seperti Mean Squared Error (MSE), Mean Absolute Percentage Error (MAPE), dan Mean Absolute deviation (MAD). Berdasarkan hasil pengujian, metode ARIMA dan ES mampu menghasilkan nilai prediksi yang cukup baik. Namun demikian, metode statistik masih memiliki kekurangan seperti jika data yang digunakan dalam jumlah yang besar maka prediksi yang dihasilkan kurang akurat. Sehingga beberapa peneliti menerapkan metode kecerdasan buatan untuk meningkatkan hasil akurasi prediksi mengingat kinerja algoritma yang bersifat cerdas karena ada tahapan pembelajaran (Haviluddin & Dengen, 2017; Mislan, Gaffar, Haviluddin, & Puspitasari, 2018). Peneliti (Gunawan et al., 2013) menerapkan metode neural network yaitu joint network dan separated network untuk memprediksi minyak kelapa sawit Indonesia. Hasil penelitian menunjukkan bahwa metode neural network telah menghasilkan akurasi yang baik dalam memprediksi minyak kelapa sawit. Hal ini ditandai dengan nilai MAPE sebesar 2.10 % dan nilai RMSPE sebesar 2.61 % yang berarti prediksi mendekati nilai data sebenarnya.

(Kanchymalay et al., 2017) juga menerapkan metode kecerdasan buatan yaitu Backpropagation Neural Network (BPNN) untuk memprediksi minyak kelapa sawit (CPO) di Malaysia. Hasil penelitian menunjukkan bahwa metode BPNN mampu memprediksi CPO dengan akurat berdasarkan nilai root mean square error (RMSE) dan R2 yang masing-masing menghasilkan nilai 41.884536 dan 0.99600.

Oleh karena itu, artikel ini menerapkan metode Backpropagation Neural Network (BPNN) untuk melakukan prediksi produksi minyak kelapa sawit (CPO) yang berasal dari perkebunan TBS Inti Tabara, PT. Perkebunan Nusantara XIII, Kampung Long Pinang, Kabupaten Paser, Kalimantan Timur, Indonesia. Lebih lanjut, hasil penelitian ini diharapkan dapat membantu memberikan informasi bagi para pengambil keputusan untuk lebih mengantisipasi produksi CPO. Paper ini terdiri dari empat bagian. Bagian pertama adalah motivasi penelitian ini. Bagian kedua adalah menjelaskan metodologi dan teknik yang digunakan. Bagian ketiga adalah menerangkan hasil pengujian dengan metode dan data yang telah ditetapkan. Dan, bagian terakhir adalah kesimpulan dan saran yang diperoleh setelah pengujian, serta rencana penelitian selanjutnya.

## II. Metodologi

Pada bagian ini, akan dijelaskan secara singkat deret waktu, metode BPNN dan pengukuran hasil simulasi peramalan yang digunakan dalam penelitian ini.

### A. Metode Backpropagation Neural Network (BPNN)

Metode BPNN diperkenalkan oleh Paul Werbos pada tahun 1974, kemudian dikembangkan oleh David Parker pada tahun 1982. Selanjutnya, tahun 1986 dikembangkan lagi oleh Rumelhart dan McClland. Metode BPNN banyak digunakan dalam memecahkan berbagai persoalan simulasi termasuk peramalan. Metode BPNN terdiri dari tiga tahapan, yaitu umpan maju (*feedforward*), umpan mundur (*backward*) dan update bobot. Sebelum masuk pada tiga tahapan tersebut terlebih dahulu melakukan inisialisasi bobot secara acak dengan interval -1 sampai dengan 1 atau 0 sampai dengan 1. Tahap pertama, umpan maju. Selama propagasi maju, sinyal masukan ( $=x_i$ ) dipropagasikan ke *layer* tersembunyi menggunakan fungsi aktivasi. Fungsi aktivasi yang bisa dipakai yaitu, fungsi sigmoid biner yang memiliki range antara 0 sampai dengan 1 atau fungsi *sigmoid bipolar* yang memiliki range antara -1 sampai dengan 1. Keluaran dari setiap unit layar tersembunyi ( $=z_j$ ) tersebut selanjutnya dipropagasikan maju lagi ke layar tersembunyi di atasnya menggunakan fungsi aktivasi. Demikian seterusnya sampai menghasilkan keluaran ( $=y_k$ ). Keluaran dari jaringan ( $=y_k$ ) dibandingkan dengan target yang harus dicapai, lalu selisihnya adalah kesalahan yang terjadi. Tahap kedua, umpan mundur. Berdasarkan kesalahan, dihitung faktor  $\delta_k$  yang akan dipakai untuk mendistribusikan kesalahan di unit  $y_k$  ke semua unit tersembunyi yang berhubungan dengan  $y_k$ . dengan cara yang sama, dihitung faktor  $\delta_j$ , disetiap unit di *layer* tersembunyi sebagai dasar perubahan bobot semua garis yang berasal dari unit tersembunyi dibawahnya. Demikian seterusnya hingga semua faktor  $\delta$  di unit tersembunyi yang berhubungan langsung dengan unit masukan dihitung. Tahap ketiga, update bobot. Setelah semua faktor  $\delta$  dihitung, bobot semua garis dimodifikasi bersamaan. Perubahan bobot suatu garis didasarkan atas faktor  $\delta$  *neuron* di *layer* atasnya. Adapun, tahapan metode BPNN untuk melakukan prediksi dapat dilihat pada Gambar 1.

### B. Performa Akurasi Prediksi

Terdapat beberapa metode dalam statistik untuk melakukan pengukuran suatu model prediksi seperti mean absolute error (MAE), mean square error (MSE), root mean squared error (RMSE), dan normalize mean square error (NMSE). Pengukuran metode prediksi bertujuan untuk mendapatkan nilai terbaik antara nilai asli dan nilai hasil peramalan (Haviluddin, Alfred, Obid, Hijazi, & Ibrahim, 2015; Rojas & Rojas, 2011). Dalam penelitian ini, metode MSE dipilih untuk mengukur akurasi peramalan. Adapun, MSE menggunakan persamaan (2).

$$MSE = \frac{1}{M} \sum_{t=1}^M (x_t - \hat{x}_t)^2 \quad (2)$$

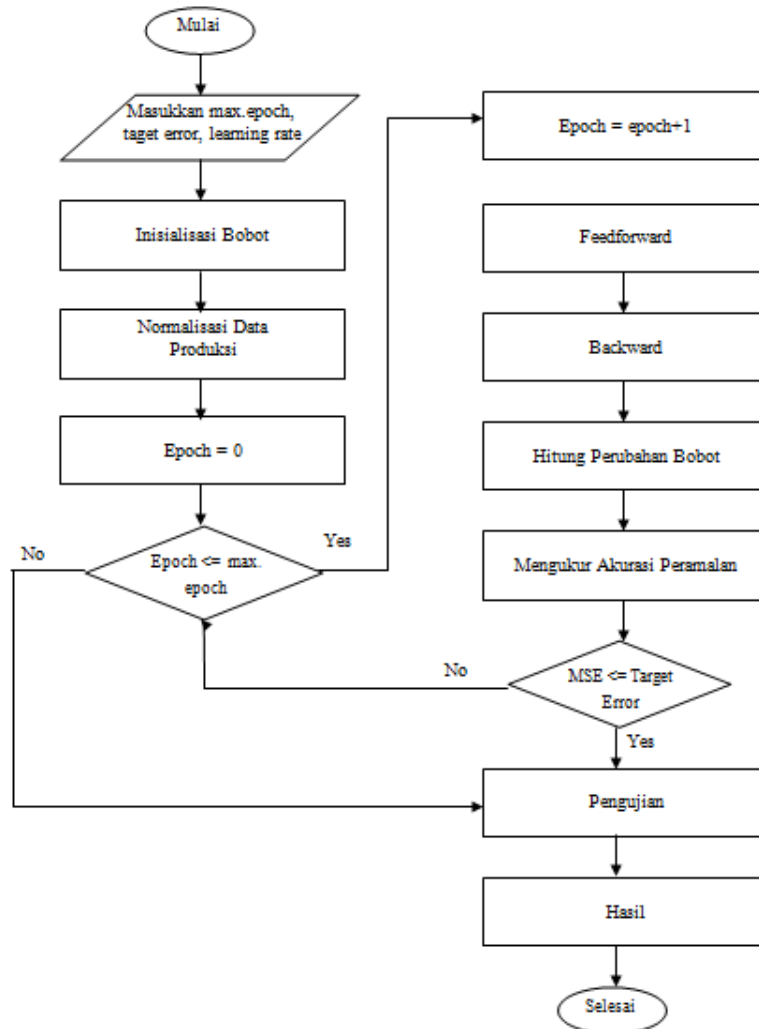
Dimana,  $x_t$  adalah nilai observasi data;  $x_t - \hat{x}_t$  adalah nilai hasil prediksi;  $M$  adalah nilai dari deret waktu.

### C. Sampel Data

Dalam penelitian ini, data produksi minyak kelapa sawit mentah (CPO) dari PT. Perkebunan Nusantara XIII, Kampung Long Pinang, Kabupaten Paser, Kalimantan Timur, Indonesia tahun 2015 hingga 2018. Data hasil produksi tandan buah segar (TBS) dari kebun TBS Inti Tabara telah di normalisasi sebelum proses prediksi dilakukan. Oleh karena itu, proses normalisasi data deret waktu sebaiknya dilakukan dengan menggunakan metode statistik. Hal ini bertujuan untuk mempercepat proses pelatihan JST tanpa mengurangi nilai data sebenarnya (Asteriou & Hall, 2011; Geurts, Box, & Jenkins, 2006). Dalam penelitian ini, data deret waktu dinormalisasi dalam ordo [0, 1] dengan menggunakan rumus (1).

$$\bar{x} = \frac{(x - x_{min})}{(x_{max} - x_{min})} \tag{1}$$


dimana,  $\bar{x}$  adalah nilai data deret waktu normalisasi dari  $x$ ;  $x$  adalah nilai data deret waktu asli;  $x_{max}$  adalah nilai maksimum data deret waktu, dan  $x_{min}$  adalah nilai minimum data deret waktu. Kemudian, untuk mengembalikan ke data asli maka dilakukan proses denormalization. Adapun, bentuk normal dari data tersebut dapat dilihat pada Tabel 1 and Gambar 2.



Gambar. 1. Tahapan prediksi metode BPNN

Tabel 1. Hasil produksi CPO TBS Inti Tabara periode 2015-2018

Bulan/Tahun	2015	2016	2017	2018
Januari	0,1503	0,8934	0,1536	0,1045
Februari	0,1434	0,7468	0,1233	0,1008
Maret	0,1234	0,6131	0,1136	0,1000
April	0,1126	0,1930	0,1118	0,1000
Mei	0,1352	0,1000	0,1147	0,1000
Juni	0,1062	0,1009	0,1698	0,1000
Juli	0,1170	0,3856	0,1213	0,1000
Agustus	0,3415	0,7580	0,1000	0,1194
September	0,3474	0,9000	0,1345	0,3739
Oktober	0,5335	0,2163	0,1593	0,4130
November	0,7732	0,2724	0,1593	0,1000
Desember	0,7423	0,1883	0,1214	0,1000



Gambar. 2. Hasil produksi CPO TBS Inti Tabara periode 2015-2018

### III. Hasil dan Pembahasan

Bagian ini adalah menerangkan hasil pengujian metode BPNN yang diujikan pada data produksi CPO. Berdasarkan aturan pelatihan dalam JST, data produksi CPO sebanyak 48 sampel dibagi menjadi dua bagian; data pelatihan sebanyak 38 sampel dan data pengujian sebanyak 10. Adapun, jumlah masukan yang digunakan sebanyak empat neurons  $P = [p(t-4), p(t-3), p(t-2), p(t-1)]$ , dan jumlah keluaran sebanyak satu neuron [Output Neurons T].

Dalam eksperimen ini, arsitektur metode BPNN yang digunakan terdiri dari dua kategori, yaitu satu lapisan tersembunyi dan dua lapisan tersembunyi. Sedangkan fungsi aktivasi yang digunakan; untuk satu lapisan tersembunyi; dari lapisan masukan ke lapisan tersembunyi adalah *tansig*, dan dari lapisan tersembunyi ke lapisan keluaran adalah *purelin*. Untuk dua lapisan tersembunyi; dari lapisan masukan ke lapisan tersembunyi adalah *tansig* dan *logsig*, dan dari lapisan tersembunyi ke lapisan keluaran adalah *purelin*. Sedangkan algoritma pelatihan yang digunakan untuk semua arsitektur metode BPNN adalah *gradient descent (traingdm)*. Dalam pengujian ini, metode statistik MSE digunakan untuk membandingkan nilai asli dan nilai hasil peramalan. Nilai MSE yang mendekati 1 merupakan nilai hasil pelatihan metode BPNN dengan arsitektur yang terbaik. Model arsitektur BPNN yang akan di uji dapat dilihat pada Tabel 2.

Tabel 2. Variasi Model Arsitektur BPNN


Variabel	Nilai
Arsitektur Hidden Layer	2, 4, 6, 8 5-10-11-1; 5-10-11-12-13-1; 5-10-11-11-12-12-13-1; 5-10-11-11-12-12-13-13-1
Fungsi Pembelajaran	trainlm; traingd; traingdx
Fungsi Aktivasi	logsig; purelin
Laju Pembelajaran	0.1; 0.3; 0.5; 0.7

Proses selanjutnya adalah melakukan pengujian model arsitektur yang telah ditentukan. Pengujian ini dilakukan dengan menggunakan metode try-and-error. Hal ini berarti nilai akhir setiap kali pengujian disimpan dan menjadi perbandingan model sampai mendapat model arsitektur yang baik untuk prediksi. Adapun, hasil pengujian model arsitektur BPNN dapat dilihat pada Tabel 3.

Tabel 3. Hasil Pengujian Model Arsitektur BPNN

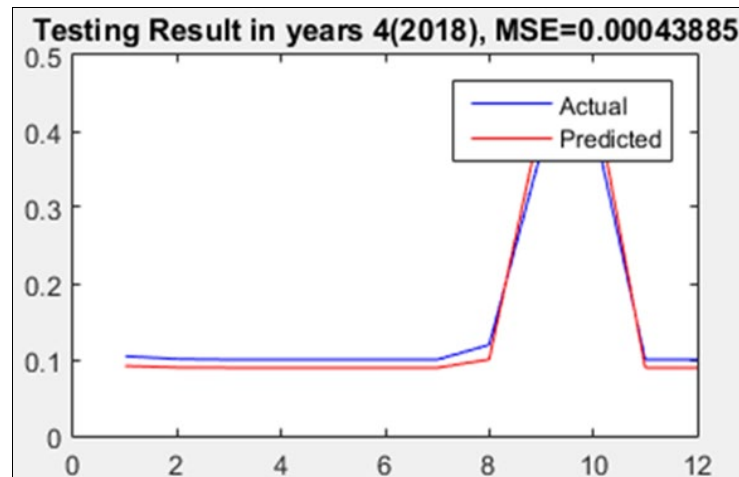
No	Parameter			MSE	
	Hidden Layer	Fungsi Pembelajaran	L.R	Pelatihan	Pengujian
1	2	trainlm	0.1	0.0043	0.0151
2		traingd	0.1	0.0173	0.0035
3		traingdx	0.1	0.0363	0.0314
4		trainlm	0.3	0.0033	0.0103
5		traingd	0.3	2.0562	5.1251
6		traingdx	0.3	0.0310	0.0118

No	Parameter		MSE		
	Hidden Layer	Fungsi Pembelajaran	L.R	Pelatihan	Pengujian
7		trainlm	0.5	0.0067	0.0024
8		traingd	0.5	0.5172	0.0971
9		traingdx	0.5	0.0894	0.0337
10		trainlm	0.7	0.0047	0.0085
11		traingd	0.7	0.6220	0.0506
12		traingdx	0.7	0.0082	0.0055
1		trainlm	0.1	0.0078	0.0079
2		traingd	0.1	0.0088	0.0068
3		traingdx	0.1	0.1156	0.0141
4		trainlm	0.3	0.0061	0.0066
5		traingd	0.3	0.0308	0.0084
6	4	traingdx	0.3	0.0054	0.0041
7		trainlm	0.5	0.0018	0.0004
8		traingd	0.5	0.0089	0.0076
9		traingdx	0.5	0.0186	0.0115
10		trainlm	0.7	0.0031	0.0004
11		traingd	0.7	0.0092	0.0098
12		traingdx	0.7	0.0441	0.0124
1		trainlm	0.1	0.0065	0.0084
2		traingd	0.1	0.0086	0.0143
3		traingdx	0.1	0.0169	0.0038
4		trainlm	0.3	0.0110	0.0181
5		traingd	0.3	0.0419	0.0175
6	6	traingdx	0.3	0.0089	0.0098
7		trainlm	0.5	0.0097	0.0367
8		traingd	0.5	0.0182	0.0043
9		traingdx	0.5	0.0300	0.0700
10		trainlm	0.7	0.0106	0.0105
11		traingd	0.7	0.1524	0.2714
12		traingdx	0.7	0.0214	0.0102
1		trainlm	0.1	0.0092	0.0170
2		traingd	0.1	0.0667	0.0415
3		traingdx	0.1	0.0653	0.0304
4		trainlm	0.3	0.0030	0.0027
5		traingd	0.3	0.3929	0.4875
6	8	traingdx	0.3	0.0662	0.0377
7		trainlm	0.5	0.0015	0.0078
8		traingd	0.5	2.3195	3.4183
9		traingdx	0.5	0.0915	0.1015
10		trainlm	0.7	0.0093	0.0147
11		traingd	0.7	3.6115	4.6128
12		traingdx	0.7	0.1848	0.0421



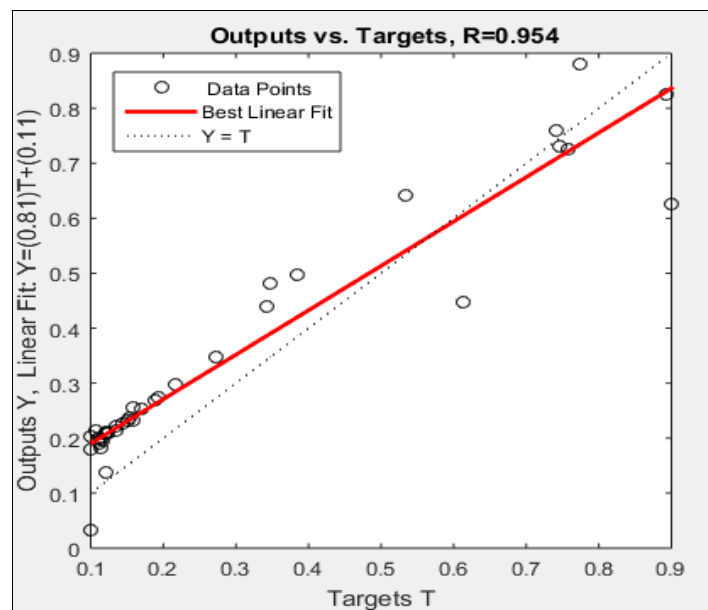
Gambar. 3. Plot grafik hasil pelatihan

Gambar 3, plot grafik hasil pelatihan dimana nilai MSE yang didapatkan sebesar 0.0031. Dapat dilihat dari plot tersebut bahwa hasil pelatihan hampir mendekati dengan target yang diinginkan.




Gambar. 4. Plot grafik hasil pengujian

Gambar 4, plot grafik hasil pengujian dimana nilai MSE yang didapatkan sebesar 0.0004. Dapat dilihat dari plot tersebut bahwa hasil pengujian hampir mendekati dengan target yang diinginkan. Selanjutnya, model terbaik dari hasil uji coba digunakan untuk meramal produksi TBS Inti Tabara pada tahun berikutnya (2019). Berdasarkan hasil uji coba menggunakan LR 0.5 dengan 5 inputan, 4 hidden layer dengan masing-masing neuron yaitu 10-11-12-13 dan 1 output, epoch maksimal sebesar 1.000 dan epoch berhenti pada iterasi kesatu dengan waktu eksekusi selama 3 detik.

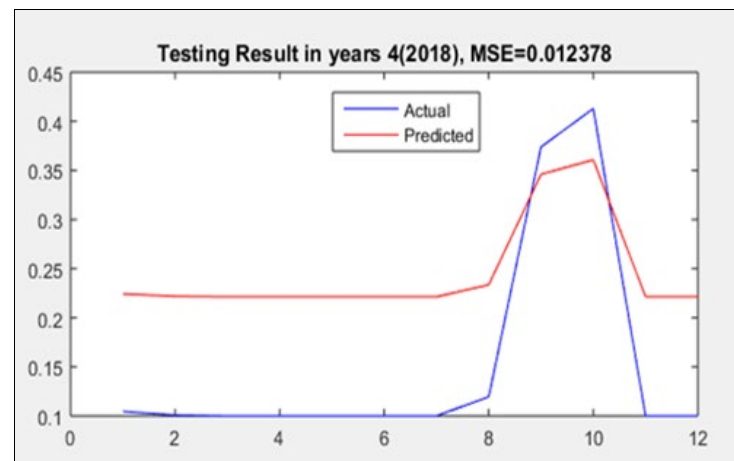


Gambar. 5. Post-Training analisis jaringan BPNN  $\alpha = 0.5$


Gambar 5, analisis pasca pelatihan (Post-training analysis) dengan LR 0.5 menghasilkan koefisien kecocokan sebesar 0.81 dari nilai aktual dan nilai prediksi, sementara intersep kesesuaian dari nilai aktual dan nilai prediksi sebesar 0.11. Koefisien korelasi antara nilai aktual dan nilai prediksi sebesar 0.954. Dapat dilihat target (garis putus-putus) dengan hasil prediksi (garis merah) tidak berada pada titik yang sama, dikarenakan koefisien kecocokan kurang mendekati nilai 1 dan intersep selama pelatihan terlalu tinggi, dimana seharusnya intersep mendekati nilai 0.

Gambar. 6. Plot grafik pelatihan  $\alpha = 0.5$ 


Gambar 6, plot grafik hasil pelatihan TBS Inti Tabara menggunakan arsitektur terbaik pada pengujian variabel dengan menggunakan LR 0.5 didapatkan nilai MSE sebesar 0.0095.

Gambar. 7. Plot grafik pengujian  $\alpha = 0.5$ 

Gambar 7, plot grafik hasil Pengujian TBS Inti Tabara menggunakan arsitektur terbaik pada pengujian variabel dengan menggunakan LR sebesar 0.5 didapatkan nilai MSE sebesar 0,0124. Berdasarkan hasil uji coba menggunakan LR 0.7 dengan 5 inputan, 4 hidden layer dengan masing-masing neuron yaitu 10-11-12-13 dan 1 output, epoch maksimal sebesar 1.000 dan epoch berhenti pada iterasi ketiga dengan waktu eksekusi selama 3 detik.


Gambar. 8. Post-Training analisis jaringan BPNN  $\alpha = 0.7$

Gambar 8, analisis pasca pelatihan (Post-training analysis) dengan LR 0.7 menghasilkan koefisien kecocokan sebesar 1.1 dari nilai aktual dan nilai prediksi, sementara intersep kesesuaian dari nilai aktual dan nilai prediksi sebesar 0.027. Koefisien korelasi antara nilai aktual dan nilai prediksi sebesar 0.9797. Dapat dilihat target (garis putus-putus) dengan hasil prediksi (garis merah) hampir memiliki kecocokan. Dikarenakan koefisien kecocokan bernilai 1 dan koefisien korelasi hampir mendekati nilai 1 yang berarti bahwa data hampir dikenali dengan baik.



Gambar. 9. Plot grafik pelatihan  $\alpha = 0.7$

Gambar 9, plot grafik hasil pelatihan menggunakan arsitektur terbaik pada pengujian variabel dengan menggunakan LR 0.7 didapatkan nilai MSE sebesar 0.0035.



Gambar. 10. Plot grafik pengujian  $\alpha = 0.7$

Gambar 10, plot grafik hasil pengujian menggunakan arsitektur terbaik pada pengujian variabel dengan menggunakan LR 0.7 didapatkan nilai MSE sebesar 0.0069.

Tabel 4. Nilai MSE prediksi

Arsitektur	Fungsi Aktivasi	Learning Rate	MSE
5-10-11-12-13-1	trainlm	0.5	0.0124
5-10-11-12-13-1	trainlm	0.7	0.0069

Tabel 4, memperlihatkan arsitektur terbaik pada pengujian variabel, dengan menggunakan LR 0.5 didapatkan nilai MSE sebesar 0.0124 dan untuk LR 0.7 didapatkan nilai MSE 0.0069. Dalam percobaan ini, arsitektur terbaik untuk memprediksi produksi CPO tahun 2019 yaitu 5-10-11-12-13-1; trainlm; LR 0.7 dengan nilai MSE sebesar 0.0069.


Tabel 5. Perbandingan data aktual dan data prediksi

Bulan	Prediksi (JST BPNN)	Aktual	Selisih	Error
Januari	1274109.589	726199	-547910.5887	-0.163825
Februari	1213177.871	519724	-693453.8708	-0.2073424
Maret	1066036.396	28864	-1037172.396	-0.3101141



April	1055179.781	0	-1055179.781	-0.3154983
Mei	2316236.656	2641234	324997.3439	0.0971741
Juni	1055179.781	0	-1055179.781	-0.3154983
Juli	1055179.781	0	-1055179.781	-0.3154983
Agustus	1109782.878	156280	-953502.8783	-0.285097
September	1993801.814	1691221	-302580.8139	-0.0904715
Oktober	2083779.258	1777480	-306299.2576	-0.0915834
November	1055179.781	0	-1055179.781	-0.3154983
Desember	1055179.781	0	-1055179.781	-0.3154983
Total	16332823.37	7541002	-8791821.366	-2.6287509
Rata-Rata	1361068.614	628416.83	-732651.7805	-0.2190626

Tabel 5 menampilkan hasil prediksi produksi pada tahun 2019 kemudian dihitung berdasarkan data aktual. Dari hasil perbandingan data aktual diperoleh rata-rata selisih adalah 732651.7805 dan rata-rata error yang diperoleh adalah -0.2190626.



Gambar. 11. Hasil peramalan produksi CPO TBS Inti Tabara tahun 2019

Gambar 11, memperlihatkan hasil peramalan pada TBS Inti Tabara pada tahun 2019. Dapat dilihat bahwa pada bulan Februari hasil panen akan mengalami peningkatan hingga bulan April, pada bulan Maret dan April hasil panen. Namun, mengalami peningkatan yang sangat tinggi dibanding pada bulan Januari dan Februari. Pada bulan Mei dan Juni hasil panen mengalami penurunan yang drastis, tetapi pada bulan Juni hasil panen mulai meningkat secara perlahan hingga pada bulan Oktober dan pada bulan November dan Desember hasil panen kembali mengalami penurunan.

#### IV. Kesimpulan

Prediksi produksi minyak mentah kelapa sawit (CPO) dari kebun TBS Inti Tabara dengan menggunakan metode Backpropagation Neural Network (BPNN) telah dikerjakan. Berdasarkan hasil percobaan, metode BPNN dengan parameter arsitektur 5-10-11-12-13-1; fungsi pembelajaran adalah trainlm; fungsi aktivasi adalah logsig dan purelin; laju pembelajaran adalah 0.7 mampu menghasilkan tingkat kesalahan prediksi yang baik dengan nilai MSE sebesar 0.0069. Hal ini menunjukkan bahwa metode BPNN dapat menjadi alternative metode dalam memprediksi produksi CPO dengan data yang berjenis time series.

#### Daftar Pustaka

- Ahmad, S., & Latif, H. A. (2011). Forecasting on the Crude Palm Oil and Kernel Palm Production: Seasonal ARIMA Approach. *2011 IEEE Colloquium on Humanities, Science and Engineering Research (CHUSER 2011), Dec 5-6 2011, Penang*, 939–944.
- Asteriou, D., & Hall, S. G. (2011). ARIMA Models and the Box–Jenkins Methodology. *Applied Econometrics (Second Ed.)*. Palgrave MacMillan.
- Geurts, M., Box, G. E. P., & Jenkins, G. M. (2006). Time Series Analysis: Forecasting and Control. *Journal of Marketing Research*. <https://doi.org/10.2307/3150485>
- Gunawan, R., Khodra, M. L., & Harlili. (2013). Commodity price prediction using neural network case study: Crude palm oil price. *Proceeding - 2013 International Conference on Computer, Control, Informatics and Its Applications: "Recent Challenges in Computer, Control and Informatics", IC3INA*

2013. <https://doi.org/10.1109/IC3INA.2013.6819181>
- Haviluddin, & Dengen, N. (2017). Comparison of SARIMA, NARX and BPNN models in forecasting time series data of network traffic. *Proceeding - 2016 2nd International Conference on Science in Information Technology, ICSITech 2016: Information Science for Green Society and Environment*. <https://doi.org/10.1109/ICSITech.2016.7852645>
- Haviluddin, H., & Alfred, R. (2014). Daily Network Traffic Prediction Based on Backpropagation Neural Network. *Australian Journal of Basic and Applied Science*, 8(8(24) Special 2014), 164–169. Retrieved from <http://www.ajbasweb.com/old/index.html>
- Haviluddin, H., Alfred, R., Obit, J. H., Hijazi, M. H. A., & Ibrahim, A. A. A. (2015). A Performance Comparison of Statistical and Machine Learning Techniques in Learning Time Series Data. *Advanced Science Letters*, Vol. 21(Number 10, October 2015), 3037–3041. <https://doi.org/10.1166/asl.2015.6490>
- Haviluddin, H., & Jawahir, A. (2015). Comparing of ARIMA and RBFNN for short-term forecasting. *International Journal of Advances on Intelligent Informatics*, 1(1), 15–22. <https://doi.org/10.1292/ijain.v1i1.10.g8>
- Kanchymalay, K., Sallehuddin, R., Salim, N., & Hashim, U. R. (2017). Time series based forecasting for crude palm oil price utilizing neural network algorithms. *6th ICT International Student Project Conference: Elevating Community Through ICT, ICT-ISPC 2017*. <https://doi.org/10.1109/ICT-ISPC.2017.8075334>
- Kementan. (2018). Kementan: Industri Kelapa Sawit Berkontribusi Besar Terhadap Ekonomi. *KOMPAS.Com*. Retrieved from <https://ekonomi.kompas.com/read/2018/03/06/193500226/kementan--industri-kelapa-sawit-berkontribusi-besar-terhadap-ekonomi>
- Meryana, E. (2017). Minyak Kelapa Sawit Indonesia - Produksi & Ekspor CPO | Indonesia Investments. *Indonesia-Investments*.
- Mislan, Gaffar, A. F. O., Haviluddin, & Puspitasari, N. (2018). Water Level Prediction of Lake Cascade Mahakam Using Adaptive Neural Network Backpropagation (ANNBP). *1st International Conference on Tropical Studies and Its Application (ICTROPS)*.
- Norhidayu, A., Nur-Syazwani, M., Radzil, R., Amin, I., & Balu, N. (2017). The production of crude palm oil in Malaysia. *International Journal of Economics and Management*, 11(3 Special Issue), 591–606.
- Rojas, R., & Rojas, R. (2011). The Backpropagation Algorithm. In *Neural Networks*. [https://doi.org/10.1007/978-3-642-61068-4\\_7](https://doi.org/10.1007/978-3-642-61068-4_7)
- Statistik, B. P. (2018). Badan Pusat Statistik. Retrieved August 27, 2018, from <https://bps.go.id/subject/6/tenaga-kerja.html#subjekViewTab3>
- Wan Ahmad, W. K. A., & Ahmad, S. (2013). Arima model and exponential smoothing method: A comparison. *AIP Conference Proceedings*. <https://doi.org/10.1063/1.4801282>