

Jaringan Saraf Tiruan dalam Memprediksi Produksi Kelapa Sawit di PT. KRE Menggunakan Algoritma Levenberg Marquardt

Yuli Andriani¹, Anjar Wanto², Handrizal³

STIKOM Tunas Bangsa, Pematangsiantar

Jl. Jend Sudirman BLOK A No 1, 2 & 3 Pematangsiantar, 0622-22431

andrianiyuli66@gmail.com

Abstract- Predictions are used to determine how much the rate of increase or decrease in oil palm production at PT. Kerasaan Indonesia (KRE) in the future. This study uses Artificial Neural Networks (ANN) using the Levenberg Marquardt method. The research data is secondary data sourced from PT. Kerasaan Indonesia from 2002 to 2017. Data is divided into 2 parts, namely training data and testing data. There are 5 architectural models used in this study, 7-10-1, 7-20-1, 7-30-1, 7-40-1 and 7-50-1. Of the 5 architectural models used, the best architecture is 7-50-1 by producing an accuracy rate of 83%, MSE 1.1471332321 and a maximum iteration of 1000. So this model is good for predicting coconut production palm oil at PT. Indonesian feeling because of its accuracy between 80% and 90%.

Keywords: Oil Palm, Production, ANN, Prediction, Levenberg Maquardt

Abstrak- Prediksi digunakan untuk mengetahui seberapa besar tingkat kenaikan atau penurunan produksi kelapa sawit di PT. Kerasaan Indonesia (KRE) di masa yang akan datang. Penelitian ini menggunakan Jaringan Saraf Tiruan (JST) dengan metode Levenberg Marquardt. Data penelitian merupakan data sekunder yang bersumber dari PT. Kerasaan Indonesia dari tahun 2002 sampai tahun 2017. Data dibagi menjadi 2 bagian yakni data pelatihan (training) dan data pengujian (testing). Ada 5 model arsitektur yang digunakan pada penelitian ini , 7-10-1, 7-20-1, 7-30-1, 7-40-1 dan 7-50-1. Dari ke 5 model arsitektur yang digunakan, arsitektur yang terbaik adalah 7-50-1 dengan menghasilkan tingkat akurasi 83%, MSE 1,1471332321 dan iterasi maksimal 1000. Sehingga model ini bagus untuk memprediksi produksi kelapa sawit pada PT. Kerasaan Indonesia karena akurasinya antara 80% hingga 90%.

Kata Kunci : Kelapa sawit, Produksi, JST, Prediksi, Levenberg Maquardt

1. PENDAHULUAN

Kelapa sawit (*Elaeis guineensis* Jacq) merupakan tanaman tahunan golongan palma yang dapat tumbuh didaerah tropis. Tanaman kelapa sawit berasal dari Nigeria, Afrika Barat. Di Indonesia, Malaysia, Thailand, dan Papua Nugini tanaman kelapa sawit juga dapat tumbuh subur [1]. Saat ini perkebunan kelapa sawit menjadi bagian yang sangat penting dari rantai suplai minyak kelapa sawit global dan ada sekitar tiga juta petani perkebunan kelapa sawit rakyat di seluruh dunia yang memproduksi sekitar 4 juta ton minyak kelapa sawit [2]. Tanaman kelapa sawit merupakan salah satu penghasil minyak tertinggi per hektar. Untuk dapat memproduksi kelapa sawit secara ekonomis dibutuhkan kemampuan yang tinggi, manajemen yang rapi dan tenaga kerja yang disiplin dan terlatih. Kegiatan tersebut selain dapat menguntungkan bagi ekonomi daerah, juga mampu menyediakan lapangan kerja bagi ribuan keluarga yang masih bergantung pada hasil pertanian

[3]. Produktivitas minyak kelapa sawit lebih tinggi dibandingkan tanaman penghasil minyak lainnya seperti kedelai, bunga matahari dan rapak/lobak (*rapeseed*). Produktivitas minyak sawit 3,74 ton/ha/tahun dengan pengelolaan manajemen budidaya terbaik memiliki potensi sekitar 6 ton/ha/tahun. Minyak kedelai hanya 0,38 ton/ha/tahun, minyak bunga matahari 0,48 ton/ha/tahun dan minyak rapak sebesar 0,67 ton/ha/tahun [2].

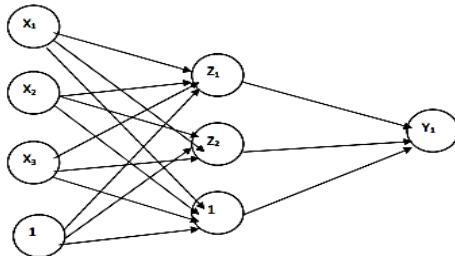
Menurut [3] "berdasarkan data dari Departemen Pertanian (2011) produksi CPO (*Crude Palm Oil*) di Indonesia sebesar 19 84 4 901 ton dengan luas areal sebesar 8 430 206 ha". Produktivitas kelapa sawit dapat diketahui dengan melihat faktor-faktor yang mempengaruhi pertumbuhan kelapa sawit sebagai upaya peningkatan hasil produksi kelapa sawit. Faktor-faktor yang mempengaruhi produktivitas kelapa sawit yaitu faktor lingkungan, faktor genetik, dan teknik budidaya [5]. PT. Kerasaan Indonesia (KRE) merupakan salah satu anggota SIPEF GROUP (Societe Internasional Plantation Estate De Finance) yang bergerak dibidang perkebunan kelapa sawit. Produksi kelapa sawit yang dihasilkan PT. Kerasaan Indonesia (KRE) berdasarkan hasil harian yang dipanen oleh para pekerja. Hasil harian dari PT. KRE akan dibawa ke Eastern Sumatera Indonesia - Bukit Maradja Oil Palm Mill yang akan diolah menjadi bahan setengah jadi. Hasil kelapa sawit yang diolah pada pabrik akan dilakukan penginputan data produksi untuk dijadikan laporan bulanan oleh perusahaan. Setiap hasil produksi tentunya tidak terus-menerus mengalami peningkatan, Pasti ada waktu dimana hasil produksi tersebut mengalami penurunan. Hasil produksi kelapa sawit yang tidak stabil, diperlukan metode untuk memprediksinya sehingga perusahaan dapat mengetahui tingkat perkembangan hasil produksi kelapa sawit dimasa yang akan datang. Banyak metode yang digunakan untuk memprediksi produksi kelapa sawit, salah satunya adalah menggunakan Jaringan Saraf Tiruan (JST) dengan metode *Levenberg Marquardt*.

2. METODOLOGI PENELITIAN

2.1. Jaringan Saraf Tiruan

Jaringan saraf tiruan mengasumsikan suatu proses yang mengikuti kerja biologis jaringan saraf pada otak dan menghasilkan keluaran yang paling sesuai atas dasar proses berulang di dalam jaringan saraf [3]–[5]. Proses yang berulang dalam jaringan saraf ini menghasilkan keluaran dengan bias yang paling kecil, sehingga proses ini dapat diulang kembali untuk memprediksi kejadian di masa mendatang. Penggunaan model JST, sudah banyak digunakan dalam memprediksi karena memiliki akurasi yang tinggi [6]–[12].

2.1.1. Konsep Dasar Jaringan Saraf Tiruan



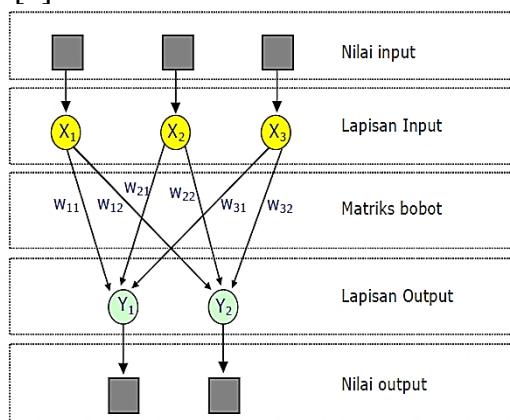
Gambar 1. Struktur Jaringan Saraf Tiruan

Berdasarkan gambar 1. dapat dijelaskan bahwa JST memiliki 3 (tiga) *layer*, yakni *input layer*, *hidden layer*, dan *output layer*. *Input layer* terdiri dari x_1 , x_2 , x_3 yang merupakan data yang diinputkan, angka 1 (satu) merupakan bias pada *input layer*. Pada *hidden layer* terdapat z_1 , z_2 yang merupakan penghubung antara sinyal *input* ke sinyal *output*. Angka 1 (satu) merupakan bias pada *hidden layer*. Pada *output layer* terdapat y_1 yang merupakan *output* dari JST itu sendiri.

2.1.2. Arsitektur Jaringan Saraf Tiruan

a. Jaringan Lapisan Tunggal

Jaringan dengan lapisan tunggal terdiri dari 1 *input layer* dan 1 *output layer*. Neuron atau unit yang terdapat didalam *input layer* selalu terhubung dengan setiap neuron yang terdapat pada *output layer*. Jaringan ini hanya menerima *input* kemudian secara langsung akan mengolahnya menjadi *output* tanpa harus melalui *hidden layer* [7].

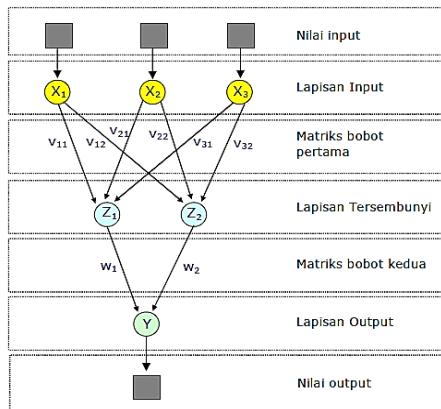


Gambar 2. Jaringan Lapisan Tunggal

Pada gambar 2. dapat dijelaskan bahwa lapisan input memiliki 3 neuron yaitu X_1 , X_2 dan X_3 , pada lapisan output memiliki 2 neuron yaitu Y_1 dan Y_2 . Neuron-neuron pada kedua lapisan saling berhubungan. Seberapa besar antara 2 neuron ditentukan oleh bobot yang besesuaian. Semua unit input akan dihubungkan dengan setiap unit ouput [9].

b. Jaringan Lapisan Jamak (*Multilayer Network*)

Jaringan *multilayer*, selain ada unit-unit *input* dan unit-unit *output*, juga terdapat unit-unit tersembunyi (*hidden*). Jumlah unit *hidden* tergantung pada kebutuhan. Jaringan yang semakin kompleks, unit *hidden* yang dibutuhkan akan semakin banyak, demikian pula dengan jumlah *layer* [7].



Gambar 3. Jaringan Lapisan Jamak

Pada gambar 3. dapat dijelaskan bahwa lapisan input memiliki 3 neuron yakni X₁, X₂ dan X₃ dengan 2 neuron lapisan tersembunyi yakni Z₁ dan Z₂ yang akan menghasilkan 1 neuron lapisan output yaitu Y.

2.2. Metode Levenberg Marquardt

Menurut [13] "Algoritma *Levenberg Marquardt* merupakan pengembangan dari algoritma *error backpropagation* yang dibangun untuk meminimalkan total *error*". Berikut beberapa struktur algoritma *Levenberg Marquardt*:

- Inisialisasi bobot dan bias dengan bilangan acak, *epoch* maksimum,minimal *goal* (*performance* yang dihitung dengan MSE)
- Menentukan parameter yang dibutuhkan, antara lain:
 - Parameter *Levenberg-Marquardt* yang nilainya harus lebih besar dari nol
 - Parameter faktor *input* dan bias yang digunakan sebagai parameter yang dikalikan atau dibagi dengan parameter *levenberg-Marquardt*
- Menghitung maju (*feedforward*) pada *hidden* dan *output layer* seperti langkah-langkah pada algortima *error backpropagation*.
- Menghitung nilai *Mean Square Error* (MSE)
- Menghitung *error* dan total *error* jaringan
 - Rumus untuk *error* : $e_r = t_r - y_r$
 r merupakan *input* ke- r
 - Rumus untuk menghitung total *error* :
$$e = [e_1 \ e_2 \ e_3 \dots \ e_N]$$
 e merupakan vektor kesalahan berukuran Nx1 yang terdiri dari e_r
 $r = 1,2,3\dots N$

f. Menghitung matriks *Jacobian* $J(x)$

x merupakan matriks yang berisi nilai bobot dan bias dari keseluruhan jaringan.

$$X = [v_{11}, v_{12}, \dots, v_{ij}; v_{01}, v_{02}, \dots; w_{11}, w_{12}, \dots, w_{jk}; w_{01}, w_{02}, \dots, w_{0k}]$$

Matriks *Jacobian* berisi turunan pertama *error* jaringan terhadap bobot dan bias jaringan.

Rumus untuk mencari *Jacobian* Matriks antara lain.

$$J = \left[\frac{\partial er}{\partial w} \right]$$

g. Setelah didapatkan nilai $J(x)$ maka dapat dihitung perubahan koreksi

Bobot dan biasnya dengan rumus berikut:

$$\Delta x = [J(x)^T J(x) + \mu I]^{-1} * \text{Gradient}$$

Gradient : $J(x)^T e$

h. Setelah didapatkan nilai Δx tahap selanjutnya adalah pengoreksian bobot dengan rumus yang sama seperti pada algortima *error backpropagation*. Pada langkah l

i. Menghitung maju (*feedforward*) dengan bobot dan bias yang baru. Pada langkah (a-d)

j. Menghitung MSE jaringan dengan bobot dan bias yang baru. Kemudian tes kondisi berhenti

k. Jika epoch atau iterasi masih berlanjut maka akan terdapat 2 kemungkinan: MSE naik atau MSE turun

l. Kemudian lakukan kembali langkah e sampai dengan h.

Dimana:

er = *error* ke- r

tr = target ke-r

yr = *output* ke-r

$J(x)$ = matriks *Jacobian*

r = *input* ke-r

3. HASIL DAN PEMBAHASAN

Pada pembahasan ini, penulis akan menjelaskan proses dalam melakukan prediksi produksi kelapa sawit dengan menggunakan *metode levenberg marquardt*.

3.1. Sumber Data

Pada penelitian ini menggunakan data produksi kelapa sawit yang diperoleh dari PT. KRE berupa data sekunder tahun 2002 hingga tahun 2017. Data produksi kelapa sawit dapat dilihat pada Tabel 1.

Tabel 1. Data Produksi Kelapa Sawit PT. KRE

Bulan	Produksi FFB (Kg)								
	Tahun								
	2002	2003	2004	2005	...	2014	2015	2016	2017
Januari	3.698.900	4.121.520	3.125.960	3.829.180	...	3.531.720	2.584.190	2.257.620	3.026.900
Februari	2.519.630	3.423.010	3.144.730	3.894.770	...	3.421.830	2.433.200	2.258.410	2.294.830
Maret	3.400.000	4.072.350	3.577.880	4.574.730	...	3.280.350	2.862.620	2.689.510	3.326.970
April	3.899.570	3.773.170	3.881.110	4.157.720	...	3.833.490	3.717.400	3.137.010	4.003.980
Mei	4.158.550	5.395.450	5.188.000	5.817.430	...	3.500.630	3.222.430	3.960.740	4.691.840

Bulan	Produksi FFB (Kg)								
	Tahun								
	2002	2003	2004	2005	...	2014	2015	2016	2017
Juni	4.537.740	5.642.940	4.999.730	5.372.310	...	3.558.890	3.885.860	4.386.000	3.986.410
Juli	5.405.770	4.697.370	5.702.680	5.440.610	...	3.316.980	4.238.820	4.626.680	5.958.260
Agustus	4.646.390	5.447.680	5.286.400	5.637.890	...	4.974.720	4.931.750	4.055.290	5.113.070
September	4.729.790	4.739.400	5.156.140	4.503.690	...	3.452.720	4.171.760	4.523.540	4.805.940
Oktober	4.281.220	4.109.590	5.229.840	4.765.290	...	3.297.690	3.871.910	3.696.120	4.760.910
November	4.094.820	2.904.560	4.689.550	3.878.250	...	2.698.970	3.049.200	3.165.860	4.259.560
Desember	3.245.990	4.669.780	4.496.780	3.817.990	...	3.101.320	2.664.970	3.329.470	3.796.210

3.2. Normalisasi Data

Data produksi selanjutnya akan dilakukan proses normalisasi data menggunakan rumus normalisasi yang akan menghasilkan nilai antara 0 hingga 1, hal ini disesuaikan dengan ketentuan pada persamaan (1) [14]-[27].

$$x' = \frac{0.8(x-a)}{b-a} + 0.1 \quad (1)$$

Data pada tabel 1 akan dibagi menjadi 2 bagian yakni data pelatihan (*training*) dan data pengujian (*testing*). Data pelatihan (*training*) yang akan digunakan adalah data dari tahun 2002-2008, target tahun 2009. Sedangkan untuk data pengujian (*testing*) dimulai dari tahun 2010-2016 dengan target tahun 2017.

Hasil normalisasi data *training* dapat dilihat pada tabel 2. Data ini telah dinormalisasi menggunakan rumus normalisasi sesuai pada persamaan (1).

Tabel 2. Normalisasi Data *Training* (Tahun 2002- 2008)/Target Tahun 2009

Bulan	Produksi FFB (Kg)							
	Tahun							
	2002	2003	2004	2005	2006	2007	2008	Target
Januari	0,38363	0,48528	0,24583	0,41497	0,28035	0,36269	0,33661	0,24436
Februari	0,10000	0,31728	0,25035	0,43074	0,33940	0,33303	0,35601	0,32859
Maret	0,31174	0,47345	0,35452	0,59428	0,51662	0,56194	0,37796	0,41655
April	0,43190	0,40149	0,42746	0,49398	0,57284	0,55021	0,44579	0,43478
Mei	0,49418	0,79168	0,74178	0,89317	0,76759	0,62333	0,47121	0,49625
Juni	0,58539	0,85120	0,69650	0,78611	0,75890	0,62360	0,56692	0,59693
Juli	0,79416	0,62378	0,86557	0,80254	0,86103	0,84123	0,54834	0,84171
Agustus	0,61152	0,80424	0,76545	0,84999	0,90000	0,71330	0,68910	0,73254
September	0,63158	0,63389	0,73412	0,57720	0,84032	0,56825	0,45527	0,45564
Oktober	0,52369	0,48241	0,75185	0,64011	0,41997	0,71100	0,63528	0,71631
November	0,47886	0,19258	0,62190	0,42677	0,68768	0,49293	0,53866	0,47348
Desember	0,27470	0,61714	0,57553	0,41227	0,50270	0,36310	0,48554	0,45170

Tabel 3. Normalisasi Data *Testing* (Tahun 2010- 2016)/Target Tahun 2017

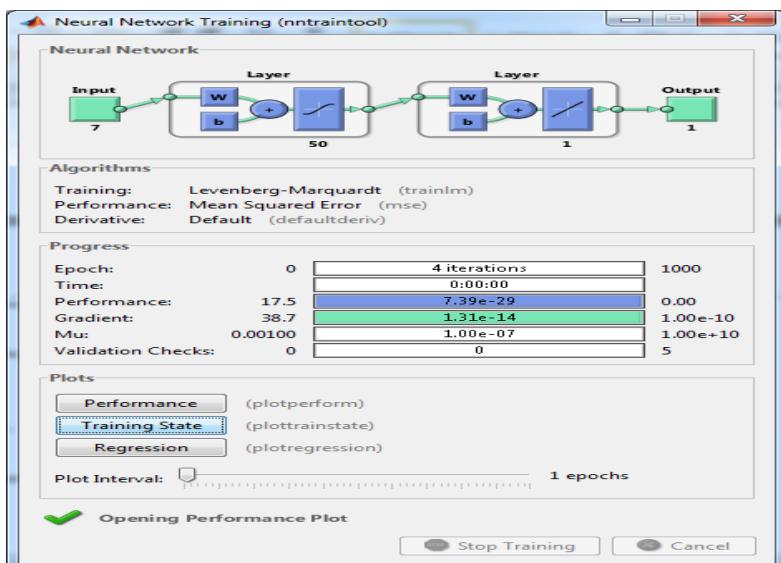
Bulan	Produksi FFB (Kg)							
	Tahun							
	2010	2011	2012	2013	2014	2015	2016	Target
Januari	0,46054	0,21468	0,30473	0,40068	0,37543	0,17060	0,10000	0,26630
Februari	0,30413	0,15660	0,23624	0,21760	0,35168	0,13796	0,10017	0,10804
Maret	0,44502	0,33808	0,22214	0,20632	0,32109	0,23079	0,19337	0,33117
April	0,47126	0,34575	0,20387	0,27457	0,44067	0,41557	0,29011	0,47753

Bulan	Produksi FFB (Kg)							
	Tahun							
	2010	2011	2012	2013	2014	2015	2016	Target
Mei	0,54209	0,53752	0,26973	0,38489	0,36871	0,30857	0,46818	0,62623
Juni	0,63485	0,54450	0,31797	0,19594	0,38131	0,45199	0,56011	0,47373
Juli	0,76784	0,61153	0,45567	0,50458	0,32901	0,52829	0,61214	0,90000
Agustus	0,46305	0,50135	0,42426	0,42589	0,68738	0,67809	0,48862	0,71729
September	0,55293	0,71603	0,47538	0,34362	0,35836	0,51380	0,58984	0,65089
Oktober	0,44840	0,59318	0,45504	0,52902	0,32484	0,44898	0,41097	0,64116
November	0,38420	0,52322	0,44960	0,40525	0,19541	0,27112	0,29634	0,53278
Desember	0,29366	0,43974	0,44040	0,36392	0,28239	0,18806	0,33171	0,43261

Hasil normalisasi data *testing* dapat dilihat pada Tabel 3. Data ini juga telah dinormalisasi menggunakan rumus normalisasi seperti yang dijelaskan pada Persamaan (1) berdasarkan pada Tabel 1., yakni tahun 2010-2016 dengan target tahun 2017.

3.3. Arsitektur Terbaik

Model arsitektur yang digunakan pada penelitian ini ada 5 arsitektur, antara lain 7-10-1, 7-20-1, 7-30-1, 7-40-1 dan 7-50-1. Berdasarkan model arsitektur 7-10-1 dapat dijelaskan bahwa 7 merupakan data input layer, 10 merupakan data hidden layer dan 1 merupakan data output layer. Begitu pula pada keterangan model arsitektur yang lain. Pelatihan ke 5 arsitektur menggunakan software MATLAB terdapat 1 arsitektur terbaik dengan model arsitektur 7-50-1 yang dapat dilihat pada Gambar 4.



Gambar 4. Hasil Data Training dengan Arsitektur 7-50-1

Tabel 4. merupakan komparasi dari masing-masing model arsitektur. Tingkat iterasi dan kecepatan waktu dari 5 model arsitektur dilihat dengan menggunakan aplikasi Matlab. Tingkat akurasi maupun nilai MSE (*Mean Squared Error*) dari ke 5 model arsitektur diperoleh menggunakan Microsoft Excel.

Tabel 4. Hasil Akurasi Algoritma *Levenberg Marquardt*

No	Arsitektur	Training		Testing	
		Epoch	Waktu	MSE	Akurasi
1	7 - 10 - 1	5	00:02	0,1037044964	50%
2	7 - 20 - 1	5	00:00	0,2345757769	33%
3	7 - 30 - 1	4	00:00	0,7697069038	33%
4	7 - 40 - 1	4	00:00	1,8913974523	42%
5	7 - 50 - 1	4	00:00	0,5735666160	83%

Berdasarkan Tabel 4. dapat disimpulkan bahwa tingkat akurasi tertinggi terdapat pada model arsitektur 7-50-1. Maka arsitektur terbaik pada algoritma *Levenberg Marquardt* dapat dilihat pada tabel 5.

Tabel 5. Arsitektur *Levenberg Marquardt* dengan Model 7-50-1

No	Pola	Target	Output	Error	SSE	Hasil
1	Pola 1	0,26630	0,53170	-0,26540	0,0704360745	1
2	Pola 2	0,10804	0,73240	-0,62436	0,3898203972	1
3	Pola 3	0,33117	0,65950	-0,32833	0,1078000475	1
4	Pola 4	0,47753	-0,65610	1,13363	1,2851080202	0
5	Pola 5	0,62623	0,24190	0,38433	0,1477071006	0
6	Pola 6	0,47373	0,85060	-0,37687	0,1420326645	1
7	Pola 7	0,90000	2,19740	-1,29740	1,6832467600	1
8	Pola 8	0,71729	0,53300	0,18429	0,0339620008	1
9	Pola 9	0,65089	2,09580	-1,44491	2,0877567630	1
10	Pola 10	0,64116	1,47850	-0,83734	0,7011411458	1
11	Pola 11	0,53278	0,97650	-0,44372	0,1968900713	1
12	Pola 12	0,43261	0,62470	-0,19209	0,0368983470	1
				Jumlah SSE	6,8827993924	
				MSE	0,5735666160	83 %

Tabel 5. merupakan hasil akurasi dan tingkat MSE dari model arsitektur terbaik, yakni 7-50-1. Perhitungan dan pembuatan tabel 5. menggunakan *Microsoft excel*. Berdasarkan tabel 5., *Target* diperoleh dari data tahun 2017 yang telah dinormalisasi, *Output* diperoleh menggunakan software Matlab dengan rumus $[a, Pf, Af, e, Perf] = sim(net, P, I, O, T)$, *error* diperoleh dari *Target-Output*, *Sum of Squared Errors (SSE)* diperoleh dari nilai *error*², total adalah jumlah SSE yang dihasilkan dari pola 1 ke pola 12, hasil adalah jika nilai kesalahan dalam pengujian data $\leq 0,3$ maka hasilnya benar (1), jika tidak maka salah (0). Akurasi diperoleh dari jumlah hasil yang benar pada $\frac{\text{pola}}{12} \times 100$, menghasilkan 83%, *margin error* diperoleh dari jumlah hasil yang salah $\frac{\text{pola}}{12} \times 100$ atau diperoleh dari jumlah akurasi maksimum 100% dikurangi akurasi yang dihasilkan, menghasilkan 17%. MSE diperoleh dari total $\frac{\text{SSE}}{12}$ (jumlah pola), 1 berarti benar dan 0 berarti salah.

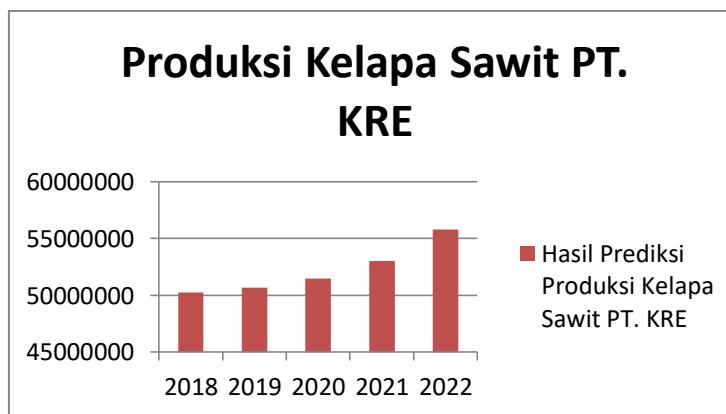
3.4. Hasil Estimasi Menggunakan Metode *Levenberg Marquardt*

Dalam melakukan proses estimasi untuk beberapa tahun berikutnya, penulis menggunakan *software MATLAB* R2011b dengan data yang diolah merupakan data pengujian (*testing*) dan menggunakan model arsitektur terbaik yakni 7-50-1.

Tabel 6. Hasil Estimasi Data Produksi Kelapa Sawit

Bulan	Produksi FFB (Kg)				
	Tahun				
	2018	2019	2020	2021	2022
Januari	3.056.366	3.114.399	3.226.811	3.438.400	3.813.986
Februari	2.331.464	2.404.000	2.544.393	2.808.968	3.278.213
Maret	3.353.561	3.405.449	3.506.265	3.696.147	4.033.255
April	4.023.511	4.061.899	4.136.702	4.277.784	4.528.088
Mei	4.704.451	4.729.683	4.778.246	4.869.663	5.031.975
Juni	4.006.110	4.045.125	4.120.708	4.263.275	4.515.884
Juli	5.958.260	5.958.260	5.958.260	5.958.260	5.958.260
Agustus	5.121.624	5.138.151	5.170.547	5.231.533	5.339.818
September	4.817.559	4.840.300	4.884.429	4.967.812	5.115.431
Oktober	4.773.140	4.796.779	4.842.667	4.928.979	5.082.363
November	4.276.746	4.310.335	4.375.726	4.498.405	4.715.864
Desember	3.817.901	3.860.612	3.943.439	4.099.410	4.376.528

Grafik hasil prediksi produksi kelapa sawit pada PT. KRE untuk 5 (lima) tahun berikutnya yakni tahun 2018 sampai tahun 2022 dapat dilihat pada gambar 5.



Gambar 5. Grafik Hasil Prediksi Produksi Kelapa Sawit PT.KRE

Berdasarkan gambar 5. diatas dapat dijelaskan bahwa jumlah produksi kelapa sawit setiap tahunnya mengalami peningkatan. Peningkatan yang cukup tinggi dapat dilihat pada tahun 2021 ke tahun 2022.

4. KESIMPULAN

Hasil prediksi produksi kelapa sawit tahun 2018 hingga tahun 2022 mengalami peningkatan yang cukup stabil dibanding hasil produksi 5 tahun sebelumnya yakni tahun 2013 hingga tahun 2017. Setelah dilakukan pelatihan dan pengujian menggunakan 5 model arsitektur yakni 7-10-1, 7-20-1, 7-30-1, 7-40-1 dan 7-50-1, maka didapat 1 arsitektur terbaik dengan model 7-50-1 yang memiliki tingkat akurasi tertinggi yaitu 83% dan dengan learning rate yaitu 0,3, jumlah

iterasi sebanyak 4 dengan waktu 1 detik dan nilai *Mean Squared Error* (MSE) terendah dibanding dengan model arsitektur lain sebesar 1,1471. Dengan menggunakan model arsitektur tersebut adapun hasil prediksi produksi kelapa sawit di PT.KRE pada tahun 2018 berjumlah 50.240.694 kg, tahun 2019 berjumlah 50.664.992 kg, tahun 2020 berjumlah 51.488.193 kg, tahun 2021 berjumlah 53.038.637 kg, dan tahun 2022 berjumlah 55.789.665 kg. Jika dibandingkan hasil produksi kelapa sawit tahun 2002 sampai 2017, hasil produksi tahun 2018 sampai tahun 2022 mengalami kenaikan yang cukup tinggi.

DAFTAR PUSTAKA

- [1] Masykur, "PENGEMBANGAN INDUSTRI KELAPA SAWIT SEBAGAI PENGHASIL ENERGI BAHAN BAKAR ALTERNATIF DANMENGURANGI PEMANASAN GLOBAL (Studi di Riau Sebagai Penghasil Kelapa Sawit Terbesar di Indonesia)," *Jurnal Reformasi*, vol. 3, no. 2, pp. 96–107, 2013.
- [2] D. K. Purba, "ANALISIS FAKTOR-FAKTOR YANG MEMPENGARUHI PRODUKSI CRUDE PALM OIL (CPO) UNIT ADOLINA PT . PERKEBUNAN NUSANTARA IV SUMATERA UTARA," *SKRIPSI*, 2013.
- [3] A. Wanto and A. P. Windarto, "Analisis Prediksi Indeks Harga Konsumen Berdasarkan Kelompok Kesehatan Dengan Menggunakan Metode Backpropagation," *Jurnal & Penelitian Teknik Informatika Sinkron*, vol. 2, no. 2, pp. 37–44, 2017.
- [4] A. Wanto, A. P. Windarto, D. Hartama, and I. Parlina, "Use of Binary Sigmoid Function And Linear Identity In Artificial Neural Networks For Forecasting Population Density," *International Journal Of Information System & Technology*, vol. 1, no. 1, pp. 43–54, 2017.
- [5] A. Wanto, M. Zarlis, Sawaluddin, and D. Hartama, "Analysis of Artificial Neural Network Backpropagation Using Conjugate Gradient Fletcher Reeves in the Predicting Process," *Journal of Physics: Conference Series*, vol. 930, no. 1, pp. 1–7, 2017.
- [6] S. P. Siregar and A. Wanto, "Analysis of Artificial Neural Network Accuracy Using Backpropagation Algorithm In Predicting Process (Forecasting)," *International Journal Of Information System & Technology*, vol. 1, no. 1, pp. 34–42, 2017.
- [7] J. R. Saragih, M. Billy, S. Saragih, and A. Wanto, "Analisis Algoritma Backpropagation Dalam Prediksi Nilai Ekspor (Juta USD)," *Jurnal Pendidikan Teknologi dan Kejuruan*, vol. 15, no. 2, pp. 254–264, 2018.
- [8] E. Hartato, D. Sitorus, and A. Wanto, "Analisis Jaringan Saraf Tiruan Untuk Prediksi Luas Panen Biofarmaka di Indonesia," *Jurnal semanTIK*, vol. 4, no. 1, pp. 49–56, 2018.
- [9] S. Setti and A. Wanto, "Analysis of Backpropagation Algorithm in Predicting the Most Number of Internet Users in the World," *JOIN (Jurnal Online Informatika)*, vol. 3, no. 2, pp. 110–115, 2018.
- [10] R. E. Pranata, S. P. Sinaga, and A. Wanto, "Estimasi Wisatawan Mancanegara Yang Datang ke Sumatera Utara Menggunakan Jaringan Saraf," *Jurnal semanTIK*, vol. 4, no. 1, pp. 97–102, 2018.
- [11] A. A. Fardhani, D. Insani, N. Simanjuntak, and A. Wanto, "Prediksi Harga Eceran Beras Di Pasar Tradisional Di 33 Kota Di Indonesia Menggunakan Algoritma Backpropagation," *Jurnal Infomedia*, vol. 3, no. 1, pp. 25–30, 2018.
- [12] J. Wahyuni, Y. W. Paranthy, and A. Wanto, "Analisis Jaringan Saraf Dalam Estimasi Tingkat Pengangguran Terbuka Penduduk Sumatera Utara," *Jurnal Infomedia*, vol. 3, no. 1, pp. 18–24, 2018.
- [13] I. Susanti, "SISTEM PERAMALAN KENAIKAN PERMUKAAN AIR DENGAN ARTIFICIAL NEURAL NETWORKS BACKPROPAGATION," *Skripsi*, 2014.
- [14] A. Wanto *et al.*, "Levenberg-Marquardt Algorithm Combined with Bipolar Sigmoid Function to Measure Open Unemployment Rate in Indonesia," in *Conference Paper*, 2018, pp. 1–7.
- [15] I. A. R. Simbolon, F. Yatussa'ada, and A. Wanto, "Penerapan Algoritma Backpropagation dalam Memprediksi Persentase Penduduk Buta Huruf di Indonesia," *Jurnal Informatika*

- Upgris*, vol. 4, no. 2, pp. 163–169, 2018.
- [16] S. P. Siregar, A. Wanto, and Z. M. Nasution, “Analisis Akurasi Arsitektur JST Berdasarkan Jumlah Penduduk Pada Kabupaten / Kota di Sumatera Utara,” in *Seminar Nasional Sains & Teknologi Informasi (SENSASI)*, 2018, pp. 526–536.
 - [17] A. Wanto, “Optimasi Prediksi Dengan Algoritma Backpropagation Dan Conjugate Gradient Beale-Powell Restarts,” *Jurnal Teknologi dan Sistem Informasi*, vol. 3, no. 3, pp. 370–380, Jan. 2018.
 - [18] B. K. Sihotang and A. Wanto, “Analisis Jaringan Syaraf Tiruan Dalam Memprediksi Jumlah Tamu Pada Hotel Non Bintang,” *Jurnal Teknologi Informasi Techno*, vol. 17, no. 4, pp. 333–346, 2018.
 - [19] M. A. P. Hutabarat, M. Julham, and A. Wanto, “Penerapan Algoritma Backpropagation Dalam Memprediksi Produksi Tanaman Padi Sawah Menurut Kabupaten/Kota di Sumatera Utara,” *Jurnal semantIK*, vol. 4, no. 1, pp. 77–86, 2018.
 - [20] Y. Andriani, H. Silitonga, and A. Wanto, “Analisis Jaringan Syaraf Tiruan untuk prediksi volume ekspor dan impor migas di Indonesia,” *Register - Jurnal Ilmiah Teknologi Sistem Informasi*, vol. 4, no. 1, pp. 30–40, 2018.
 - [21] A. Wanto, “Penerapan Jaringan Saraf Tiruan Dalam Memprediksi Jumlah Kemiskinan Pada Kabupaten/Kota Di Provinsi Riau,” *Kumpulan jurnal Ilmu Komputer (KLIK)*, vol. 5, no. 1, pp. 61–74, 2018.
 - [22] I. S. Purba and A. Wanto, “Prediksi Jumlah Nilai Impor Sumatera Utara Menurut Negara Asal Menggunakan Algoritma Backpropagation,” *Jurnal Teknologi Informasi Techno*, vol. 17, no. 3, pp. 302–311, 2018.
 - [23] A. Wanto, “Prediksi Angka Partisipasi Sekolah dengan Fungsi Pelatihan Gradient Descent With Momentum & Adaptive LR,” *Jurnal Ilmu Komputer dan Informatika (ALGORITMA)*, vol. 3, no. 1, pp. 9–20, 2019.
 - [24] N. Nasution, A. Zamsuri, L. Lisnawita, and A. Wanto, “Polak-Ribiere updates analysis with binary and linear function in determining coffee exports in Indonesia,” *IOP Conference Series: Materials Science and Engineering*, vol. 420, no. 12089, pp. 1–9, 2018.
 - [25] A. Wanto, “Prediksi Produktivitas Jagung Indonesia Tahun 2019-2020 Sebagai Upaya Antisipasi Impor Menggunakan Jaringan Saraf Tiruan Backpropagation,” *SINTECH (Science and Information Technology)*, vol. 1, no. 1, pp. 53–62, 2019.
 - [26] B. Febriadi, Z. Zamzami, Y. Yunefri, and A. Wanto, “Bipolar function in backpropagation algorithm in predicting Indonesia’s coal exports by major destination countries,” *IOP Conference Series: Materials Science and Engineering*, vol. 420, no. 12089, pp. 1–9, 2018.
 - [27] A. Wanto *et al.*, “Analysis of Standard Gradient Descent with GD Momentum And Adaptive LR for SPR Prediction,” 2018, pp. 1–9.