

PENGGUNAAN MODEL JARINGAN SARAF TIRUAN (*ARTIFICIAL NEURAL NETWORK*) UNTUK MEMPREDIKSI HASIL TANDAN BUAH SEGAR (TBS) KELAPA SAWIT BERDASAR CURAH HUJAN DAN HASIL TBS SEBELUMNYA

APPLICATION OF AN ARTIFICIAL NEURAL NETWORK (ANN) MODEL FOR PREDICTING OIL PALM FRESH FRUIT BUNCH (FFB) YIELD BASED ON RAINFALL AND THE PREVIOUS LEVEL OF YIELD

Iman Yani Harahap dan M. Edwin S. Lubis

Abstrak Untuk memprediksi hasil kelapa sawit 2018 di 4 kebun percobaan Pusat Penelitian Kelapa Sawit (Padang Mandarsah, Dalu-dalu, Bukit Sentang, dan Aek Pancur), maka disusun model Jaringan Saraf Tiruan (JST). Data yang digunakan untuk menyusun model ini adalah hasil tandan buah kelapa sawit segar dan curah hujan bulanan pada 2013-2017. Keluaran model diperoleh dari hubungan non-linear *Autoregressive* dengan memasukkan eksternal (*External/Exogenous input, NARX*) yaitu curah hujan bulanan. Proses pemodelan meliputi *training* model menggunakan data 2013-2015, validasi model menggunakan data 2016, dan pengujian model menggunakan data 2017. Dari hasil pengujian model diperoleh arsitektur model JST *n-d-h-o* (peubah input, *n*; *d-tapped delayed*, *d*, *node* tersembunyi, *h*; lapisan keluaran, *o*) yang sesuai untuk kebun Padang Mandarsah, Dalu-dalu, Bukit Sentang, dan Aek Pancur berturut-turut adalah 2-3-4-1, 2-24-5-1, 2-24-10-1, dan 2-3-5-1 dengan hubungan keeratan (*r*) antara keluaran model dengan data aktual berturut-turut 0,84; 0,74; 0,84; dan 0,86, yang berarti model tersebut cukup "fit". Sehingga model tersebut dinilai layak untuk memprediksi hasil tandan kelapa sawit beberapa bulan berikutnya.

Kata kunci: prediksi, masukan eksternal, training,

validasi, pengujian, arsitektur model

Abstract To predict oil palm yield in 2018 at 4 Indonesian Oil Palm Research Institute field Trial Plantation (Padang Mandarsah, Dalu-dalu, Bukit Sentang, and Aek Pancur), then it was built an Artificial Neural Network (ANN) model. The data used were monthly oil palm fresh fruit bunch (FFB) yield and rainfall during 2013-2017. The model output taking by the relation of non-linear *Autoregressive* to the rainfall external input (*NARX*). The modeling process includes including training using the data 2013-2015, validation using the data 2016, and testing models using the data 2017. From the testing models result, were taken a good fit model architecture *n-d-h-o* (variable input, *n*; *d-tapped delayed*, *d*, *node* hidden, *h*; output layer, *o*) and correlation coefficient (*r*) between output model and actual data for each plantation. Padang Mandarsah 2-3-4-1 with *r*= 0,84; Dalu-dalu 2-24-5-1 with *r* = 0,74; Bukit Sentang 2-24-10-1 with *r* = 0,84, and Aek Pancur 2-3-5-1 with *r* = 0,86. Which means the model is quite fit, so the model is considered feasible to predict the yield of oil palm bunches in the next few months.

Keywords: prediction, external input, training, validasi, testing, model architecture

PENDAHULUAN

Hasil kelapa sawit berfluktuasi menurut bulanan maupun tahunan. Fluktuasi hasil tersebut ditentukan faktor umur tanaman dan iklim terutama curah hujan (Paterson dan Lima, 2018), Woittiez *et al.* (2017) menyebutkan curah hujan dan interval waktu panen

Penulis yang tidak disertai dengan catatan kaki instansi adalah peneliti pada Pusat Penelitian Kelapa Sawit

Iman Yani Harahap (✉)
Pusat Penelitian Kelapa Sawit
Jl. Brigjen Katamso No. 51 Medan, Indonesia
Email: iyh_020464@yahoo.co.id

dapat menurunkan hasil hingga 20%, di samping faktor kultur teknis lainnya seperti *pruning*, populasi tanaman, pemupukan dan pemilihan bahan tanaman. Di samping faktor tersebut, Henson dan Dolmat (2004) menyebutkan bahwa aktivitas pembungaan mempengaruhi hasil tandan buah kelapa sawit pada masa berikutnya, dan membentuk pola hasil musiman.

Faktor curah hujan dan hasil sebelumnya diduga dapat menentukan fluktuasi hasil kelapa sawit, pengelolaan perusahaan kelapa sawit, dan pada akhirnya hasil prediksi tersebut dapat dimanfaatkan untuk merencanakan penggunaan sumber daya hasil, sehingga kegiatan bisnis kelapa sawit tersebut dapat lebih efisien.

Beberapa metode untuk mengestimasi hasil kelapa sawit telah dikembangkan, antara lain pendekatan model statistik-stokastik dan model tanaman-mekanistik. Secara umum, pendekatan model statistik-stokastik, yang paling banyak digunakan, karena dinilai lebih sederhana tetapi akurasi relatif rendah karena penumpukan bias pada setiap peubah pengestimasi yang digunakan dalam suatu perhitungan *time series*. Pendekatan model tanaman-mekanistik lebih dapat menjelaskan keterkaitan di antara peubah-peubah pengestimasi. Tetapi pendekatan model tanaman ini, memerlukan pemahaman yang rumit dan kompleks atas proses pertumbuhan dan hasil tanaman. Model Jaringan Saraf Tiruan (JST/*Artificial Neural Network*), adalah model yang mengkombinasikan pendekatan statistik-stokastik dan model matematis tanaman-mekanistik.

Model JST ini, mengasumsikan suatu proses dalam sistem mengikuti kerja biologis jaringan saraf pada otak, yang menghasilkan keluaran yang paling sesuai atas dasar proses berulang-ulang di dalam jaringan saraf (Demuth dan Beale, 2002). 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 data *time series*, karena pendekatannya yang sederhana dan memiliki akurasi yang tinggi (Karia *et al.*, 2013). Beberapa contoh penggunaan model JST ini, antara lain untuk prediksi ketersediaan komoditi pangan (Cynthia dan Ismanto, 2017), prediksi harga saham harian (Sari *et al.*, 2014), prediksi harga minyak sawit (Karia *et al.*, 2013), prediksi pengaruh

hidrometeorologi terhadap fluktuasi muka air tanah (Coulibaly *et al.*, 2001). Sedangkan Ismail dan Khamis (2011), model jaringan saraf ini dalam memodelkan hasil kelapa sawit di Malaysia dan Kartika *et al.*, 2016, juga menggunakan model JST untuk memprediksi hasil kelapa sawit dengan peubah masukannya adalah unsur cuaca. Paper ini bertujuan untuk mengaplikasikan model JST yang mempertimbangkan aspek hasil dan curah hujan sebelumnya untuk memprediksi hasil tandan buah kelapa sawit.

Landasan Teoritis

Secara umum, jaringan saraf (JS) bekerja dengan prinsip penyesuaian (*adjusted*) dan terlatih (*trained*), sehingga masukkan sistem mengarah ke berbagai elemen yg saling terhubung secara jejaring dan akhirnya menghasilkan suatu keluaran yang spesifik (Demuth dan Beale, 2002). Deskripsi JS tersebut disajikan pada Gambar 1.

Penyesuaian bobot (*adjusted*) dilakukan berulang pada model JST ini mengikuti pembandingan keluaran terhadap target, sedemikian rupa sehingga keluaran *matches* terhadap target, yang pada saat itu, kerja jaringan dihentikan (Gambar 1). Masukkan dan target adalah pasangan data yang harus ditentukan pada kerja model JF ini. Model sederhana jaringan, digambarkan dengan diagram pada gambar 2.

Model disamping, menunjukkan bahwa jaringan bekerja dengan meng-adjusted masing-masing elemen vektor masukkan ($P_1, P_2, P_3, \dots, P_R$) dengan $W_{1,1}; W_{1,2}; W_{1,3}; \dots, W_{1,R}$ di dalam jaringan tunggal melalui operasi penjumlahan W_p . Operasi tersebut menghasilkan nilai, n , dengan sisaan (bias), b . Nilai n ditransfer dengan fungsi f , untuk menghasilkan keluaran, a . Ekspresi matematis proses pada model jaringan tersebut, disajikan pada persamaan (1).

$$n = W_{1,1} P_1 + W_{1,2} P_2 + \dots + W_{1,R} P_R + b \quad (1a),$$

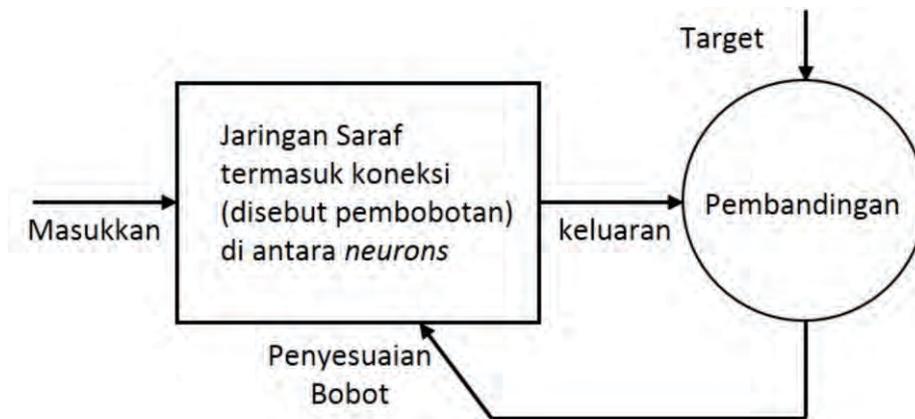
Persamaan (1a), dapat diringkas menjadi,

$$n = W^*p + b \quad (1b),$$

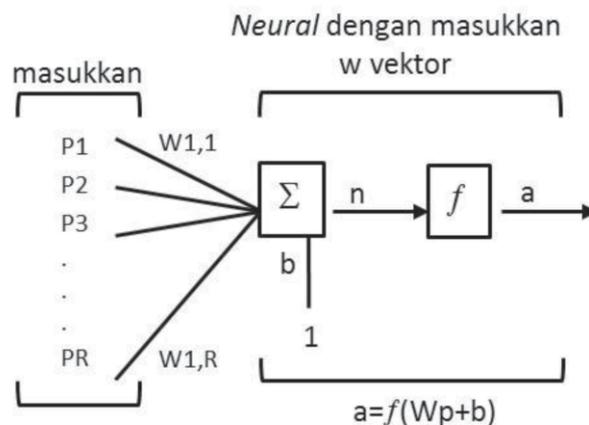
Sehingga,

$$a = f(Wp + b) \quad (1c),$$

$f(\)$: fungsi transfer linear ataupun log-sigmoid.



Gambar 1. Diagram sederhana proses penyesuaian, *trained*, pada model JST
 Figure 1. Simple diagram of adjusted process, *trained*, at JST model



Gambar 2. Model jaringan dengan masukan R elemen vektor tunggal (Beale, Hagan, dan Demuth, 2017)
 Figure 2. Neural model with R element single vector (Beale, Hagan and Demuth, 2017)

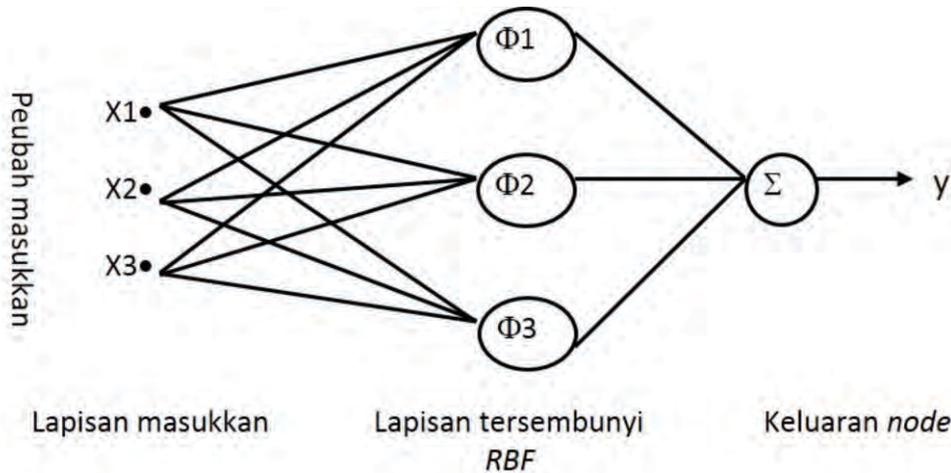
Arsitektur Jaringan Saraf Tiruan (JST)

Pola diagram JST dapat disusun dalam berbagai alternatif untuk mendapatkan tingkat akurasi keluaran yang tinggi. Obyek data yang dianalisis menggunakan model JST ini berpeluang mempengaruhi keakuratan model, sehingga sangat menentukan prediksi keluaran dari model ini. Hal ini yang menyebabkan arsitektur JST menentukan tingkat akurasi keluaran model JST itu sendiri. Arsitektur JST terdiri jumlah masukan, jumlah lapis neural, dan jumlah lapis keluaran. Penetapan arsitektur JST ini ditentukan oleh performa keluaran hasil uji model terhadap data target/data aktual (Coulibaly *et al.*, 2001 dan Cynthia dan Ismanto,

2017). Indikator yang umum digunakan dalam penetapan arsitektur ini adalah nilai kumulatif rerata sisaan (*Root Mean Square Error, RMSE*) dan koefisien keeratan antara keluaran model terhadap data aktual yang diuji (*r*). Coulibaly *et al.* (2001), menyebutkan ada 3 tipe utama arsitektur JST, yaitu jaringan saraf dengan masukan yang ditunda (*Input Delay Neural Network, IDDN*), jaringan saraf dengan pengulangan input (*Recurrent Neural Network, RNN*) dan jaringan saraf dengan fungsi basis radial (*Radial Basis Function, RBF*). Arsitektur IDDN dan RNN adalah pengembangan dari RBF. Arsitektur JST RBF ini adalah pola utama dalam menyusun arsitektur JST. Sebagai contoh, untuk memprediksi suatu data

berseri, dibuat arsitek JST tipe *RBF* dengan masukkan 3 peubah, dengan lapisan tersembunyi yang memiliki 3 neuron, serta 1 lapis keluaran. Arsitek JST tersebut,

dapat disingkat dengan *syntax RBF* (n:3-h:3-o:1) atau *TBF*(3-3-1). Diagram arsitektur JST tersebut disajikan pada Gambar 3 berikut.



Gambar 3. Arsitektur JST *Radial Basis Function* dengan pola (3-3-1)
 Figure 3. Architecture of ANN-*Radial Basis Function* with (3-3-1) pattern

Untuk memprediksi hasil kelapa sawit berdasarkan masukkan data curah hujan dan hasil kelapa sawit sebelumnya sebagai tujuan dari paper ini, maka arsitektur model JST nya mengikuti *RBF* dengan lapisan masukannya mengandung 2 peubah yaitu curah hujan dan hasil kelapa sawit sebelumnya, sehingga sesuai dengan model jaringan saraf dinamis (*Dynamic Neural Networks, DNN*) (Gambar 4) (Beale *et al.*, 2017). Keluaran model DNN ini diprediksi dari hubungan non-linear *Autoregressive* dengan masukkan eksternal (*External/Exogenous input, NARX*) yang representasikan persamaan (2), berikut.

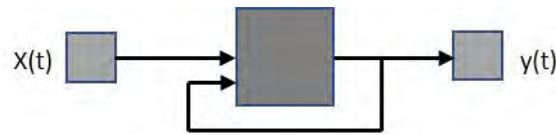
$$y(t) = f(x(t-1), \dots, x(t-d), y(t-1), \dots, y(t-d)) \quad (2)$$

dengan,

- $y(t)$: keluaran yang diprediksi pada saat t
- $x(t-1)$: peubah masukan pada saat $t-1$
- $x(t-d)$: peubah masukan pada saat $t-d$
- $y(t-1)$: peubah aktual pada saat $t-1$
- $y(t-d)$: peubah aktual pada saat $t-d$
- d : saat terjauh sebelum saat t

Metodologi

Prosedur aplikasi model JST mengikuti manual MATLAB program (Beale *et al.* 2017), yang urutan prosesnya sebagai berikut, (i) menyiapkan data seri masukkan dan target untuk diimpor ke dalam bahasa MATLAB, (ii) data masukkan dan target tersedia di *workspace*, (iii) memproses data masukkan dan target dalam tiga kegiatan berurutan yaitu *training*, yaitu proses *adjusted* parameter di setiap lapisan jaringan (lapisan tersembunyi neuron dan keluaran), (iv) melanjutkan proses *training*, dengan proses validasi, dan (v) menguji model JST yang terbentuk. Data untuk proses *training*, validasi dan pengujian harus terpisah, (vi) mengevaluasi arsitektur model JST, berdasarkan nilai *RMSE* (*Root Mean Square Error*) (Persamaan (4)) dan nilai koefesien keeratan, r , (Persamaan (5)) dari pasangan data keluaran model dan aktual, baik pada proses *training*, validasi, maupun pengujian serta jumlah *epoch* atau iterasi untuk mendapatkan nilai parameter yang optimal dan (vii), model JST dengan arsitektur terbaik, yang ditunjukkan dengan nilai *RMSE* yang paling rendah, nilai r yang paling mendekati 1, dan jumlah *epoch/iterasi* yang rendah digunakan untuk memprediksi keluaran untuk beberapa waktu kedepan. Proses pemodelan dan prediksi menggunakan *software* MATLAB_R2018a.



Gambar 4. Diagram autoregresi non linear dengan input eksternal (NARX)
 Figure 4. Diagram of nonlinear autoregressive with external input (NARX)

Arsitektur *default* model JST NARXT pada MATLAB_R2018a adalah satu lapis masukan dengan 1 node, 10 node pada layar tersembunyi, 2 *tapped delay* masukan, dan 1 lapis keluaran. Arsitektur tersebut dimodifikasi untuk memperoleh model JST yang paling optimal, sehingga dapat digunakan untuk memprediksi hasil beberapa waktu kedepan. Modifikasi tersebut mempertimbangkan fase-fase krisis perkembangan tandan bunga kelapa sawit dan penetapan model JST kelapa sawit

sebelumnya. Arsitektur model JST yang akan diuji tersebut disajikan pada Tabel 1.

Data yang digunakan adalah hasil tandan buah segar (TBS) kelapa sawit dan curah hujan bulanan selama 5 tahun (Januari 2013 sampai dengan Desember 2017). Data 2013 – 2015, digunakan untuk proses *training*. Data 2016, digunakan untuk proses *validasi*, dan data 2017 digunakan untuk menguji model. Data tersebut diperoleh dari 4 kebun percobaan Pusat Penelitian Kelapa Sawit (PPKS),

$$RMSE = \sqrt{\sum_{t=1}^T [Y(t) - y(t)]^2} \quad (3)$$

dengan,

- RMSE* : Root Mean Square Error
- $Y(t)$: peubah aktual (target) pada saat t
- $y(t)$: keluaran model pada saat t
- T : saat pada data T yang terakhir

$$r = \frac{T \sum Y(t) \cdot y(t) - (\sum Y(t)) \cdot (\sum y(t))}{\{T \sum Y(t)^2 - (\sum Y(t))^2\} \{T \sum y(t)^2 - (\sum y(t))^2\}} \quad (4)$$

yang meliputi (1), kebun Padang Mandarsah , Padang Lawas, Sumatera Utara, seluas 397 ha dengan umur tanaman 13 – 14 tahun, (2) kebun Dalu Dalu , Rokan, Riau, seluas 235 ha, dengan umur tanaman 24 – 26 tahun, (3) kebun Bukit Sentang, Langkat, Sumatera Utara, seluas 394 ha, dengan umur tanaman 12 – 24 tahun, dan (4) kebun Aek Pancur, Deli Serdang, Sumatera Utara, seluas 248 ha, dengan umur tanaman 6 - 32 tahun. Hasil pemodelan digunakan

untuk memprediksi hasil tandan 1 tahun kedepan (2018) di 4 kebun percobaan tersebut.

Hasil dan Pembahasan

Hasil kelapa sawit dan curah hujan

Fluktuasi hasil tandan buah segar (TBS) dan curah hujan pada 2013 – 2017, untuk masing-masing kebun

disajikan pada Gambar 5. Pola hasil dan curah hujan tersebut terlihat berfluktuasi dalam suatu tahun, dimana terdapat satu puncak dan satu lembah hasil. Demikian juga dengan curah hujan, terdapat satu puncak dan lembah jumlah hujan dalam satu tahun. Puncak dan lembah hasil dan curah hujan tersebut berulang setiap tahun, selama 5 tahun pengamatan, dan terjadi relatif pada bulan-bulan yang sama. Keeratan hubungan curah hujan dan hasil kelapa sawit

telah dilaporkan beberapa peneliti antara lain, Caliman dan Southworth (1998), Adam *et al.* (2011) dan Corley dan Tinker (2016). Keeratan hubungan hasil kelapa sawit dan curah hujan tersebut menjadi dasar penyusunan model JST NARXT dalam paper ini. Walaupun demikian, kultur teknis, terutama pemupukan, sangat menentukan hasil kelapa sawit (Ashari *et al.*, 2017).

Tabel 1. Arsitektur model JST NARXT yang diuji untuk memprediksi hasil kelapa sawit
 Table 1. NARXT-ANN architecture model were tested for oil palm yield prediction

No	Arsitektur model				Jumlah parameter*)
	node masukan		node tersembunyi (h)	Lapisan keluaran (o)	
	Peubah (n)	<i>d-tapped delayed (d)</i>			
1	2	3	5	1	35
2	2	3	10	1	70
3	2	3	15	1	105
4	2	3	20	1	140
5	2	6	5	1	65
6	2	6	10	1	130
7	2	6	15	1	195
8	2	6	20	1	260
9	2	12	5	1	125
10	2	12	10	1	250
11	2	12	15	1	375
12	2	12	20	1	500
13	2	24	5	1	245
14	2	24	10	1	490
15	2	24	15	1	735
16	2	24	20	1	980

Keterangan: *) jumlah *adjusted* pada seluruh proses ;
 Note: *) *sum of adjusted at the whole process*



Gambar 5. Fluktuasi hasil dan curah hujan 2013 – 2017 di kebun Padang Mandarsah (A), Dalu-dalu (B), Aek Pancur (C), dan Bukit Sentang (D)

Figure 5. Yield and rainfall fluctuation 2013-2017 in Padang Mandarsah (A), Dalu-dalu (B), Aek Pancur (C), and Bukit Sentang (D) plantations

Arsitektur model JST NARXT terpilih

Pemilihan arsitektur model JST, yang terbaik dilakukan dengan menguji seluruh alternatif arsitektur model, yang disajikan pada Tabel 1. Hasil pemilihan arsitektur tersebut disajikan pada Tabel 2.

Arsitektur model JST yang terbaik untuk setiap kebun berbeda, terutama untuk nilai *d-delayed*, yang menunjukkan pengaruh kumulatif curah hujan dan tingkat hasil pada waktu sebelumnya. Pada kebun Dalu-dalu dan Aek Pancur, hasil suatu bulan dipengaruhi oleh kejadian curah hujan dan hasil sampai 24 sebelumnya. Sedangkan hasil di kebun Padang Mandarsah dan Bukit Sentang lebih dipengaruhi kejadian curah hujan dan hasil 3 bulan sebelumnya. Kelapa sawit merespon fisiologi lingkungan pada setiap fase umur tanaman. Tanaman tua, merespon fisiologi lingkungannya dalam jangka waktu yang relatif lama, sehingga hasilnya pun dipengaruhi kondisi lingkungan sampai 24 bulan sebelumnya. Pertanaman kelapa sawit di kebun Dalu-dalu dan Aek Pancur didominasi tanaman berumur tua, sehingga respon hasil terhadap fisiologi lingkungan berlangsung dengan relatif yang panjang. Fase-fase perkembangan pembungaan selama 24 bulan sebelum panen meliputi pemisahan jenis kelamin, absorsi bunga, penyerbukan bunga, dan pertumbuhan dan perkembangan tandan buah (Adam *et al.*, 2011; Keong dan Keng, 2012; dan Combers *et al.*, 2012). Sedangkan pada tanaman relatif lebih muda, yang terdapat di sebagian besar kebun Padang Mandarsah dan Bukit Sentang, hasil kelapa sawitnya merespon fisiologi lingkungan yang relatif lebih pendek. Fase perkembangan tandan buah pada 3 bulan sebelum panen adalah pembentukan minyak, dimana pada fase ini kebutuhan energi sangat besar, sehingga kebutuhan fotosintat juga besar. Di samping itu, kompetisi kebutuhan energi di antara tandan buah yang sedang berkembang dalam satu individu tanaman mempengaruhi perkembangan masing-masing tandan pada individu tanaman tersebut. Kondisi kompetisi tersebut merupakan salah satu faktor penyebab terjadinya fluktuasi hasil kelapa sawit (DeSoto *et al.*, 2016). *Hidden node*, yang optimal untuk model JST hasil kelapa sawit adalah 5, seperti model

yang disusun berdasar data kebun Padang Mandarsah, Dalu-dalu, dan Bukit Sentang. Sedangkan model JST yang disusun berdasar data kebun Aek Pancur adalah 10. *Hidden node* ini adalah parameter model yang menjadi ciri model JST, dimana proses intensitas *adjusted* model untuk menghasilkan bias yang kecil antara keluaran model dan target (data aktual) terlihat dari jumlah hidden node ini. Kartika *et al.* (2016), juga menyatakan bahwa jumlah *hidden node* yang paling optimal untuk memprediksi hasil kelapa sawit menggunakan JST model adalah 5.

Pengujian model JST

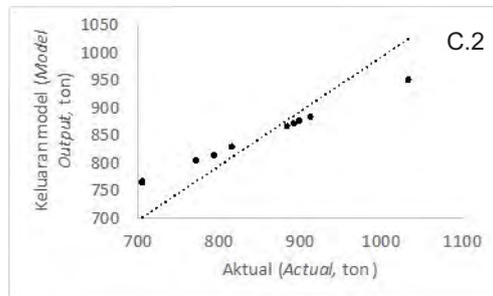
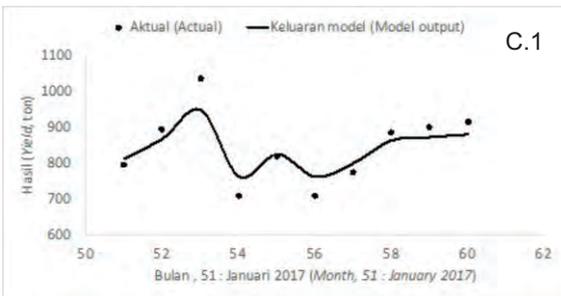
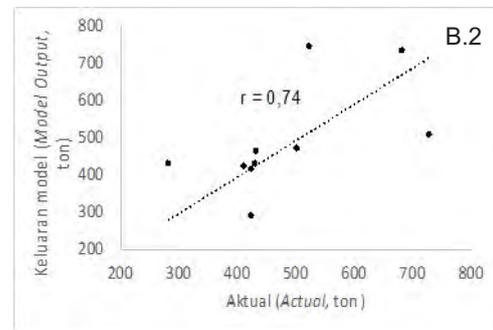
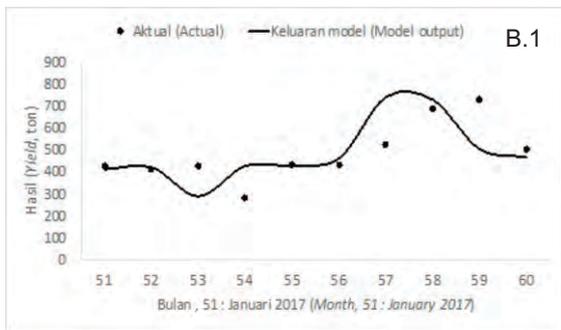
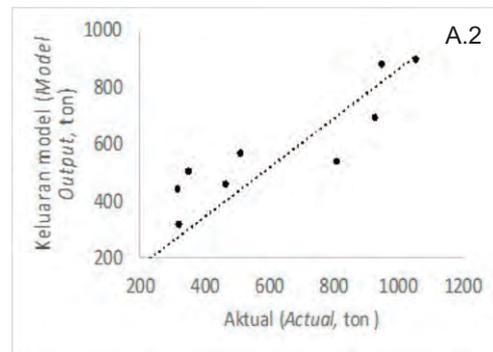
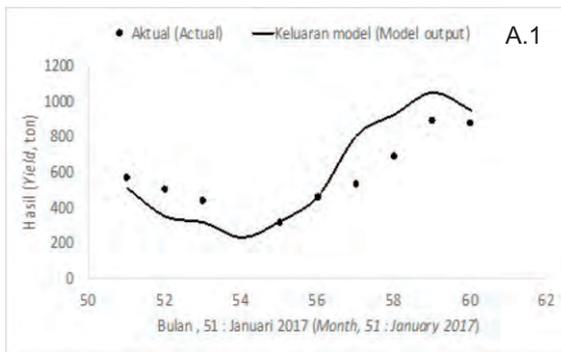
Pengujian model ini diperlukan untuk memperoleh gambaran keakuratan model tersebut dalam memprediksi hasil kelapa sawit. Hasil pengujian model JST tersebut disajikan pada Gambar 6.

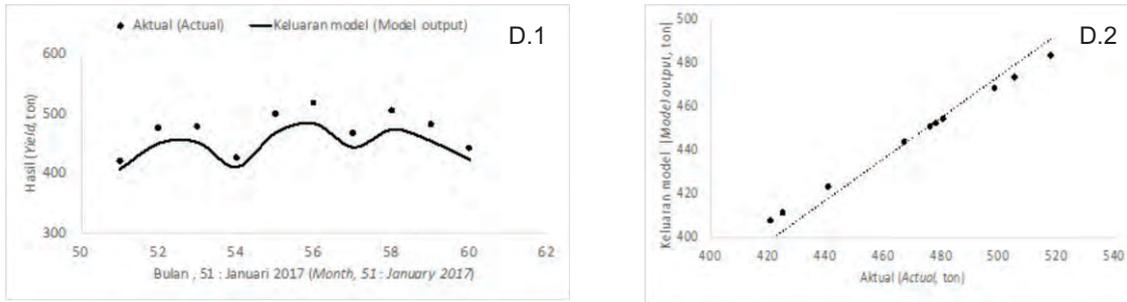
Keluaran model JST NARXT, dibandingkan terhadap hasil aktual Januari – Desember 2017. Keluaran model dinilai cukup akurat dengan koefisien keerratan (*r*), umumnya di atas 80%, kecuali untuk model JST NARXT kebun Dalu-dalu. Sarwono (2006), menyatakan bahwa koefisien keerratan antara 0,75 – 0,99 dinilai memiliki keerratan yang kuat. Sehingga model dinilai akurat untuk memprediksi hasil. Moghaddam *et al.* (2016), juga menggunakan nilai koefisien keerratan (*r*) di atas 80% dalam memilih model JST untuk memprediksi hasil. Jumlah data yang diuji juga mempengaruhi nilai koefisien keerratan (*r*) (Lee *et al.*, 2016).

Model jaringan saraf tiruan (JST), dengan masukkan peubah eksternal (*External/Exogenous input, NARX*) curah hujan dinilai efektif dalam memprediksi hasil kelapa sawit bulanan dalam satu tahun ke depan. Arsitektur model JST yang digunakan untuk memprediksi setiap kebun bersifat spesifik, yang diduga berhubungan dengan umur tanaman, dan kondisi lahan dan agroklimat. Penetapan arsitektur model JST bersifat *trial and error*, sehingga penggunaannya untuk memprediksi harus dilakukan simultan dengan penetapan arsitektur model JST tersebut. Keluaran model JST dihasilkan dengan proses yang berkarakter "*black box*", sehingga hanya efektif dalam memprediksi. Model JST ini memiliki

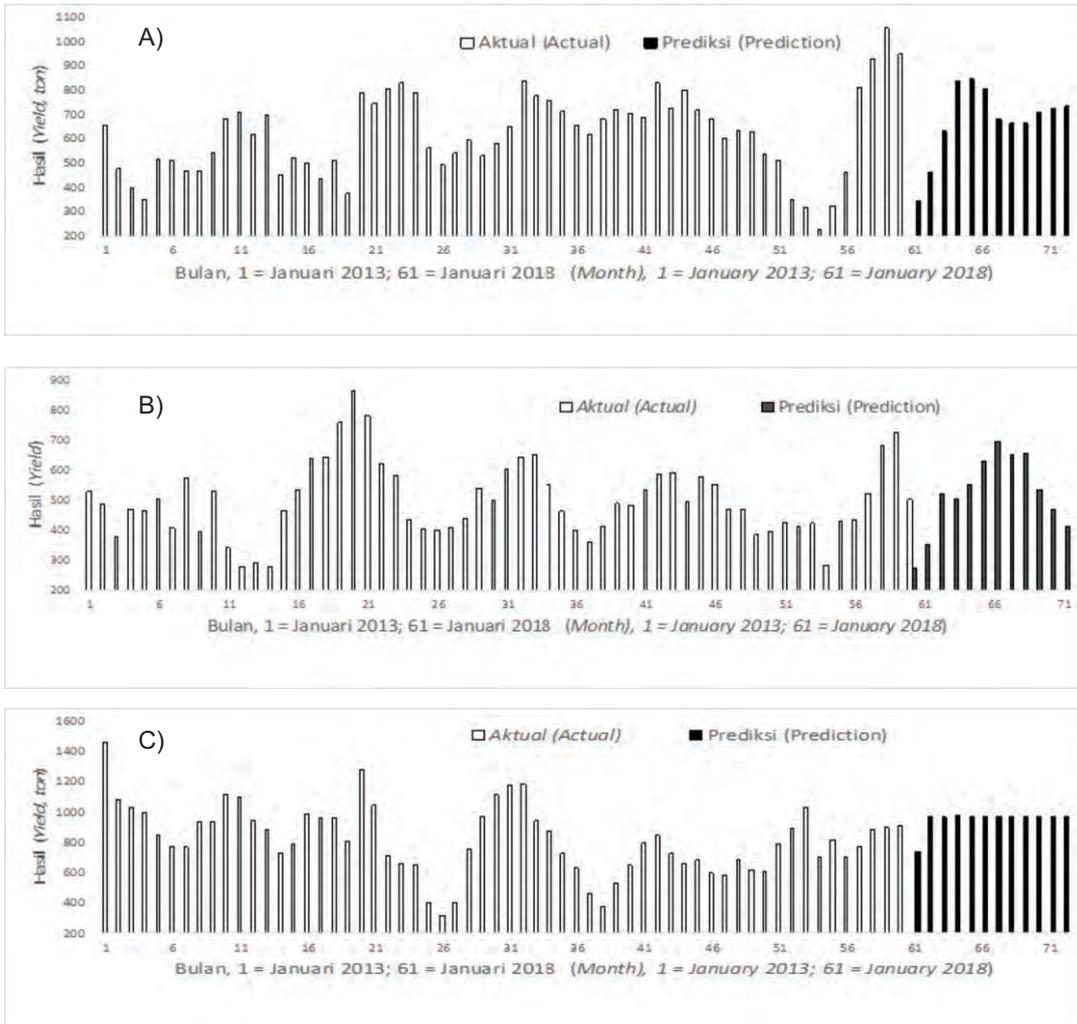
Tabel 2. Model JST NARXT dengan arsitektur terbaik untuk masing-masing kebun
 Table 2. ANN-NARXT model with the best architecture for each plantations

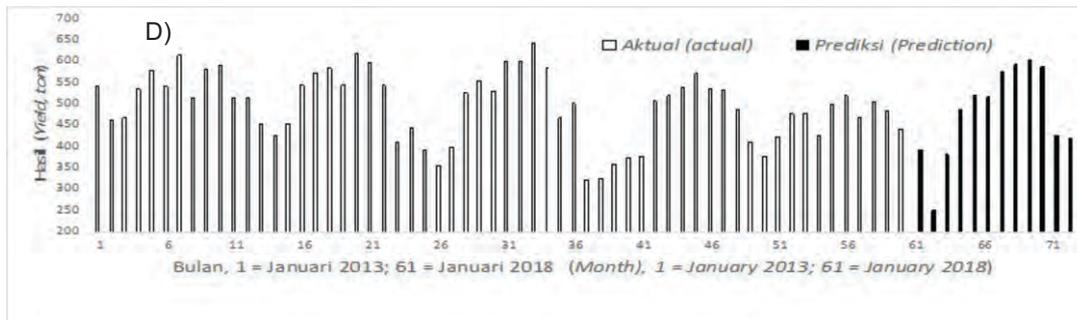
Kebun	Arsitektur (n-d-h-o)	RMSE	r	Jumlah iterasi/epoch
Padang Mandarsah	2-3-5-1	117	0,84	4
Dalu-dalu	2-24-5-1	38	0,74	4
Aek Pancur	2-24-10-1	29	0,84	3
Bukit Sentang	2-3-5-1	118	0,86	6





Gambar 6. Keragaan hasil uji model JST NARXT terhadap hasil TBS Januari-Desember 2017 di kebun Padang Mandarsah (A.1 dan A.2), Dalu-dalu (B.1 dan B.2), Bukit Sentang (C.1 dan C.2), dan Aek Pancur (D1 dan D2) *Figure 6. Performance of ANN NARXT model test result for FFB yield in January – December 2017 at Padang Mandarsah (A.1 and A.2), Dalu-dalu (B.1 and B.2), Bukit Sentang (C.1 and C.2), and Aek Pancur (D.1 and D.2)*





Gambar 7. Hasil aktual (Januari 2013 – Desember 2017) dan prediksi (Januari 2018– Desember 2018)
Figure 7. Actual yield (January 2013 – December 2017) and prediction (January 2018 – December 2018)

keterbatasan dalam menjelaskan proses di dalam sistem, sehingga tidak dapat digunakan untuk menganalisis proses sebab akibat yang terjadi pada sistem produksi tanaman kelapa sawit (Lee *et al.*, 2016).

Prediksi hasil

Prediksi hasil ditujukan untuk melihat gambaran capaian hasil pada beberapa bulan ke depan setelah model JST dibangun. Hasil prediksi hasil bulanan masing-masing kebun disajikan pada Gambar 7.

Berdasar keluaran model JST, terlihat setiap kebun pada tahun 2018, akan memperoleh hasil TBS dengan satu puncak dan satu lembah, kecuali kebun Bukit Sentang, sejak triwulan pertama hingga akhir tahun hasilnya relatif tidak berfluktuasi. Prediksi hasil di kebun Bukit Sentang ini lebih menggambarkan hasil pada satu tahun sebelumnya (2017) dibanding hasil-hasil tahun sebelumnya (2013 – 2016), yang relatif lebih berfluktuasi. Pada awal 2018, hasil pada setiap kebun relatif rendah dan pada pertengahan tahun sampai triwulan ke-3, hasil meningkat sehingga terjadi puncak-puncak hasil pada periode tersebut. Pada triwulan ke-4 hasil menunjukkan penurunan kembali hingga akhir tahun 2018. Model JST, sangat membantu dalam memprediksi suatu serial data yang berkelanjutan tanpa memerlukan masukan data eksternal pada tahun yang akan diprediksi. Sedang model stokastik dan deterministik lainnya memerlukan masukan data eksternal pada tahun yang akan diprediksi dan tahun-tahun sebelumnya. Prediksi dengan model JST, akan lebih akurat apabila

menggunakan serial data yang panjang (banyak), untuk proses training, validasi, dan pengujian. Sedangkan model statistik ARIMA, berprinsip pada perhitungan auto korelasi pada suatu data serial, tanpa memasukkan peubah eksternal lainnya, yang dapat diduga bahwa sebenarnya faktor tersebut mempengaruhi terbentuknya serial data tersebut.

KESIMPULAN

Model jaringan saraf tiruan (JST) efektif dalam memprediksi hasil kelapa sawit bulanan dalam satu tahun ke depan. Arsitektur model JST yang digunakan untuk memprediksi setiap kebun bersifat spesifik. Model JST ini memiliki keterbatasan dalam menjelaskan proses di dalam sistem, sehingga tidak dapat digunakan untuk menganalisis proses sebab akibat yang terjadi pada sistem produksi tanaman kelapa sawit. Model JST efektif bekerja untuk serial data, sehingga disarankan penggunaan model ini lebih sesuai pada data serial yang panjang.

DAFTAR PUSTAKA

- Adam, H., M. Collin, F. Richaud, T. Beule, D. Cros, A. Omore, L. Nodichao, B. Nouy, and J.W. Tregear. 2011. Environmental Regulation of Sex Determination in Oil Palm: Current Knowledge and Insight from Other Species. *Annals of Botany* 108: 1529-1573.
- Ashari, D.S., Sudradjat, dan Sugiyanta. 2017. The

- Roles of Bio Organic and NPK Compound Fertilizer to Growth and Production of Four Year Old Oil Palm. *Asian Journal of Applied Sciences*. 5(5): 937-943.
- Beale, M.H., M.T. Hagan, and H.B. Demuth. 2017. *Matlab: Neural Network Toolbox, User's Guide*. MathWorks. 512 pp.
- Caliman, J.P. and A. Southworth. 1998. Effect of Drought and Haze on the Performance of Oil Palm. In: *International Oil Palm Conferences: Commodity of the Past, Today, and the Future-Indonesia*. IOPRI. 30 p.
- Combers, J.C., B. Pallas, L. Roun, I. Mialet-Serra, J.P. Caliman, S. Braconnier, J.C. Soulie, and M. Dingkuhn. 2012. Simulation of Inflorescence Dynamics in Oil Palm and Estimation of Environment-Sensitive Phenological Phases: A Model based Analysis. *Functional Plant Biology*. 40(3): 263-279.
- Corley, R.H.V. and P.B.H. Tinker. 2016. *The Oil Palm*. Fifth Edition. Wiley Blackwell. 627 p.
- Coulibaly, P., F. Ancil, R. Aravena, and B. Bobee. 2001. Artificial Neural Network Modeling of Table Depth Fluctuation. *Water Resources Research*. 37(4): 885-896.
- Cynthia E.P. dan E. Ismanto. 2017. Jaringan Syaraf Tiruan Algoritma Backpropagation Dalam Memprediksi Ketersediaan Komoditi Pangan Provinsi Riau. Dalam: *Seminar Nasional Teknologi Informasi, Komunikasi dan Industri*. UIN Syarif Kasim Riau. Pekanbaru 18-19 Mei 2017.
- Demuth, H. and M. Beale. 2002. *Neural Network Toolbox for Use With Matlab, User's Guide version 4*. The MathWork. 840 pp.
- DeSoto, L., J.M. Olano, and V. Rozas. 2016. Secondary Growth and Carbohydrate Storage Patterns Differ between Sexes in *Juniperus thurifera*. *Frontiers in Plant Science*. 7: 723.
- Henson, I.E. and T. Dolmat. 2004. Seasonal Variation in Yield and Developmental Processes in An Oil Palm Density Trial on Peat Soil: 1. Yield and Bunch Number Components. *Journal of Oil Palm Research*. 16(2): 88-105.
- Ismail, Z. and A. Khamis. 2011. Neural Network in Modeling Malaysian Oil Palm Yield. *American Journal of Applied Sciences*. 8(8): 796-803.
- Karia, A.A., I. Bujang, and I. Ahmad. 2013. Forecasting on Crude Palm Oil Prices Using Artificial Intelligence Approaches. *American Journal of Operation Research*. 3: 259-267.
- Kartika, N.D., I.W. Astika and E. Santosa. 2016. Oil Palm Yield Forecasting Based on Weather Variables Using Artificial Neural Network. *Indonesian Journal of Electrical Engineering and Computer Science*. 3(3): 626-633.
- Keong, Y.K. and W.M. Keng. 2012. Statistical Modeling of Weather-based Yield Forecasting for Young Mature Oil Palm. *APCBEE Procedia*. 4: 58 – 65.
- Lee, K.Y., N. Chung, and S. Hwang. 2016. Application of an Artificial Neural Network (ANN) Model for Predicting Mosquito Abundance in Urban Areas. *Ecological Informatics*. 36: 172-180.
- Moghaddam, A.H., M.H. Moghaddam, and M. Esfandyari. 2016. Stock Market Index Prediction Using Artificial Neural Network. *Journal of Economics, Finance, and Administrative Science*. 21(41): 89-93.
- Paterson, R.R.M. and N. Lima. 2018. Climate Change Affecting Oil Palm Agronomy, and Oil Palm Cultivation Increasing Climate Change, Require Amelioration. *Ecology and Evolution*. 8(1): 452-461.
- Sari, I.P., T. Wuryandari dan H. Yasin. 2014. Prediksi Data Harga Saham Harian Menggunakan Feed Forward Neural Networks (FFNN) dengan Pelatihan Algoritma Genetika (Studi Kasus pada Harga Saham Harian PT. XL Axiata Tbk). *Jurnal Gaussian*. 3(3): 441-450.
- Sarwono, J. 2006. *Metode Penelitian Kuantitatif dan Kualitatif*. Graha Ilmu, Yogyakarta.
- Woittiez, L.S., M.T. van Wijk, M. Slingerland, and M. van Noordwijk. 2017. Yield Gaps in Oil Palm: A Quantitative Review of Contributing Factors. *European J. Agronomy*. 83: 57-77.