

Penerapan Jaringan Syaraf Tiruan Backpropagation Dalam Prediksi Produksi Bahan Pangan Pokok di Indonesia

Nurfia Oktaviani Syamsiah¹, Romi Satria Wahono²

Abstract — *Foods prediction is one of the ways applicable to know condition of food stockpiling. Even have available research about food material condition, but that research object just confines to one food and data material that is utilized is gross production data only. This research started by processing netto's production data their material food to get time series data of food. Method that is utilized is artificial neural network backpropagation with data input is previous year datas. Severally experimental being done to get optimal architecture and resulting predicts that accurate. Result observationaling to point out optimal architecture is network with one input layer with 9 neuron, one hidden layer with 9 neuron and one output layer (9 - 6 - 1). Best activation function that is utilized is tansig, training's function best is trainrp with epochs 138 with RMSE's 0,0100.*

Intisari — *Prediksi bahan pangan pokok merupakan salah satu cara yang dapat digunakan untuk mengetahui kondisi persediaan pangan. Meskipun sudah ada penelitian tentang kondisi bahan pangan, tetapi objek penelitian tersebut hanya terbatas pada satu bahan pangan serta data yang digunakan adalah data produksi bruto saja. Penelitian ini diawali dengan mengolah data produksi netto masing-masing bahan pangan untuk mendapatkan nilai runtun waktu data produksi bahan pangan pokok. Metode yang digunakan adalah jaringan syaraf tiruan dengan input data adalah data-data tahun sebelumnya. Beberapa percobaan dilakukan untuk mendapatkan arsitektur yang optimal dan menghasilkan prediksi yang akurat. Hasil penelitian menunjukkan arsitektur yang optimal adalah jaringan dengan satu lapisan masukan dengan 9 neuron, satu lapisan tersembunyi dengan 6 neuron dan satu lapisan keluaran (9-6-1). Fungsi aktivasi terbaik yang digunakan adalah tansig, fungsi training terbaik adalah trainrp dengan epochs 138 yang menunjukkan RMSE 0,0100.*

Keyword: *Backpropagation, Neural Network, Prediction, Food*

I. PENDAHULUAN

Sebagai salah satu kebutuhan dasar manusia, pemenuhan kebutuhan pangan menjadi salah satu hak asasi yang harus dipenuhi secara bersama-sama oleh negara dan masyarakatnya.

Hak atas pangan telah diakui secara formal oleh banyak negara di dunia, termasuk Indonesia yang menjadikan pangan sebagai komponen strategis dalam pembangunan

nasional. Komitmen ini terdapat dalam Undang-undang No. 7 Tahun 1996 tentang pangan, yang mengamanatkan agar pemerintah bersama masyarakat mewujudkan ketahanan pangan bagi seluruh rakyat Indonesia.

Makna dari pangan pada penelitian ini mengacu pada Peta Ketahanan Pangan dan Kerentanan Pangan Indonesia yakni karbohidrat yang bersumber dari produksi pangan pokok, yaitu padi, jagung dan umbi-umbian (ubi kayu dan ubi jalar). Dengan alasan karena porsi utama dari kebutuhan kalori harian berasal dari sumber pangan karbohidrat, yaitu sekitar separuh dari kebutuhan energi per orang per hari [10].

Sebagai salah satu hak dasar manusia, yang pemenuhannya menjadi suatu keharusan, maka prediksi jumlah produksi bahan pangan yang merupakan komponen utama indikator ketersediaan pangan merupakan suatu keniscayaan. Agar ke depannya tidak akan terjadi kerentanan pangan, karena terjadinya kerentanan pangan akan berefek pula pada masalah sosial lainnya.

Sampai saat ini prediksi produksi bahan pangan pokok di Indonesia belum pernah dilakukan. Prediksi-prediksi yang telah dilakukan sebelumnya hanya terbatas pada satu atau dua bahan pangan saja. Seperti penelitian tentang prediksi produksi padi jagung menggunakan estimasi M [23]. Ataupun penelitian tentang pemanfaatan *Global Circulation Model (GCM)* untuk prediksi produksi padi [21]. Sedangkan penelitian-penelitian yang dilakukan di luar Indonesia pun, hampir sama dengan penelitian di dalam negeri, yakni hanya terbatas pada satu atau dua bahan pangan saja. Selain itu, dari penelitian-penelitian yang telah ada tersebut, hampir semua objek penelitian masih dalam bentuk data produksi bruto. Padahal sebenarnya, data produksi bruto saja tidak bisa menjamin ketersediaan pangan, karena jumlah produksi netto bahan pangan merupakan hasil pengurangan produksi bruto dengan data benih, data pakan dan data tercecet. Selain itu, prediksi-prediksi yang telah dilakukan tersebut masih kurang akurat.

TABEL 1
NILAI KESALAHAN PENELITIAN SEBELUMNYA

No	Judul Penelitian	Error
1	Forecasting of the Rice Yields Time Series Forecasting using Artificial Neural Network and Statistical Model (Shabri, Samsudin, & Ismail, 2009)	0,06
2	Wheat Grain Yield Forecasting Models for Food Security in Morocco (Balaghi, 2006)	1,44

¹ AMIK BSI Jakarta, Jln. RS. Fatmawati No. 24 Jakarta Selatan (telp: 021-75760914; fax:021-7513790; e-mail: nurfia.nos@bsi.ac.id)

² Fakultas Ilmu Komputer, Universitas Dian Nuswantoro; e-mail: romi@brainmatics.com

3	Rice Yield Prediction Using Apparent Electrical Conductivity of Paddy Soils (Ezrin, Amin, Anuar, & Aimrun, 2009; Ezrin, Amin, Anuar, & Aimrun, 2009)	0,18
4	Box-Jenkins vs. Artificial Neural Networks in Predicting Commodity Prices Forecasting the Export Prices of Thai Rice(Boosarawoongse, Henry, & Feng, 2007)	0,09
5	The Research on the BP Neural Network in the Food Security Risk Early Warning Applied Under Supply Chain Environment(Xiao, Ma, & Zhang, 2009)	0,66
6	Forecasting Iran's Rice Imports Trend During 2009-2013(Pakravan, Kelasemi, & Alipour, 2010)	0,085
7	Studi Sistem Deteksi Dini Untuk Manajemen Krisis Pangan dengan Simulasi Model Dinamis dan Komputasi Cerdas(Kudang, Marimin, AndarWulan, Belawati, Herdiyenny, & Solahudin, 2009)	0,11

Sumber: Hasil Penelitian (2011)

Berdasarkan kenyataan-kenyataan yang telah dipaparkan di atas, dalam penelitian ini berusaha melakukan prediksi tidak hanya terbatas pada satu atau beberapa bahan pangan saja. Namun penelitian ini berupaya untuk menghasilkan suatu model prediksi yang akurat tentang produksi netto bahan pangan pokok berbasis Jaringan Syaraf Tiruan.

II. KAJIAN LITERATUR

Berikut ini adalah beberapa penelitian terdahulu yang terkait dengan penelitian ini:

- 1). Penelitian yang dilakukan oleh Kudang, et.al, didapatkan hasil bahwa dinamisnya faktor penentu krisis pangan memerlukan suatu perumusan kebijakan penghindaran dan penanggulangan krisis. Penelitian ini menggunakan jaringan syaraf tiruan (JST) dengan 167 data pelatihan. Akurasi sistem dalam mendeteksi level krisis pangan adalah 96,9 % dengan tingkat *error* (MSE) sebesar 0,1 [11].
- 2). Penelitian yang dilakukan oleh Pakravan, et.al, mengangkat masalah tentang nilai impor beras di Iran yang meningkat hampir 30 % pada tahun 2008, hal ini menjadikan Iran sebagai salah satu negara pengimpor beras terbesar. Kebijakan yang tepat adalah meningkatkan produksi beras dalam negeri, untuk itu salah satu hal yang diperlukan adalah prediksi status impor pada tahun-tahun berikutnya. Metode yang digunakan adalah jaringan syaraf dan ARIMA, dengan hasil yang ditunjukkan oleh jaringan syaraf tiruan lebih

baik dibandingkan dengan ARIMA, yakni dengan *error* sebesar 0,0085. Peramalan pada tahun-tahun mendatang menunjukkan tingkat impor beras yang semakin tinggi selama tahun 2009 hingga 2013 [15].

- 3). Penelitian yang dilakukan oleh Xiao, et.al, mengangkat masalah perkembangan internasionalisasi industri makanan dan lemahnya kontrol terhadap kuantitas dan kualitas bahan pangan yang menjadikan pendeteksian dini kerentanan pangan menjadi tujuan global bagi setiap pelaku industri makanan. Untuk itu dilakukan penelitian menggunakan jaringan syaraf tiruan dengan minyak kedelai sebagai objek penelitian dengan tingkat *error* 0,66. Hasilnya adalah sebuah sistem peringatan dini dalam proses oksidasi minyak kedelai, sehingga kualitas minyak kedelai yang buruk dapat dihindarkan [25].
- 4). Penelitian yang dilakukan oleh Ezrin, et.al, membahas masalah hubungan antara hasil panen dengan sifat tanah seperti konduktivitas elektrik (ECA) sangat diperlukan dalam penentuan presisi lahan pertanian yang berdampak pada hasil panen. Tiga buah metode digunakan dalam prediksi hasil panen berdasarkan ECA, yakni *Stepwise Linear Regression* (SLR), *Boundary Line Analysis* (BLA) dan Jaringan Syaraf Tiruan (JST). Hasilnya prediksi dengan jaringan syaraf tiruan lebih baik daripada dua metode lainnya, yakni dengan *error* 0,18 [5].
- 5). Penelitian yang dilakukan oleh Saad, et al, membahas masalah beras sebagai tanaman pangan yang paling penting di dunia dan merupakan sumber utama makanan bagi lebih dari setengah populasi dunia. Hampir 90% beras yang diproduksi dan dikonsumsi di Asia, dan 96% di negara berkembang. Di Malaysia hampir 30 % pemenuhan kebutuhan beras berasal dari beras impor. Padahal swasembada beras nasional sudah menjadi wacana strategis pemerintah. Untuk mensukseskan wacana tersebut, diperlukan suatu sistem prediksi hasil panen, dalam hal ini menggunakan jaringan syaraf tiruan dengan metode *backpropagation* dan *radial basis network*. Hasilnya performa dari *radial basis network* lebih baik dari *backpropagation* dalam hal waktu pelatihan, akurasi dan jumlah *neuron* lapisan tersembunyi [17].

Pengertian Ketahanan Pangan berdasarkan Undang-undang no. 7 tahun 1996 dan PP No. 68 Tahun 2002 Tentang Ketahanan Pangan adalah Kondisi terpenuhinya kebutuhan pangan rumah tangga yang tercermin dari tersedianya pangan yang cukup, baik jumlah maupun mutunya, aman, merata dan terjangkau [10]. Pangan meliputi produk sereal, kacang-kacangan, minyak nabati, sayur-sayuran, buah-buahan, rempah, gula dan produk hewani. Karena porsi utama dari kebutuhan kalori harian berasal dari sumber pangan karbohidrat, yaitu sekitar separuh dari kebutuhan energi per orang per hari, maka yang digunakan dalam penelitian ini yaitu karbohidrat yang bersumber dari produksi bahan pangan pokok, yaitu padi, jagung dan umbi-umbian (ubi kayu dan ubi

jalar) yang digunakan untuk memahami tingkat kecukupan pangan [10].

Beberapa formula yang digunakan dalam menentukan jumlah produksi netto bahan pangan pokok (P_{food}), adalah:

1). Padi

Produksi netto padi (R_{net}) adalah produksi bruto padi (P) dikurangi dengan data benih (s), pakan ternak (f) dan tercecer (w).

$$Benih (s) = P * 0,9 \%$$

$$Pakan ternak (f) = P * 0,44\%$$

$$Tercecer (w) = P * 5,4\%$$

$$R_{net} = 63,2\% * (P - (s + f + w))$$

2). Jagung

Produksi netto jagung (M_{net}) adalah produksi bruto jagung (M) dikurangi dengan data benih (s), pakan ternak (f) dan tercecer (w).

$$Benih (s) = M * 0,9 \%$$

$$Pakan ternak (f) = M * 6\%$$

$$Tercecer (w) = M * 5\%$$

$$M_{net} = M - (s + f + w)$$

3). Umbi-umbian

(1). Ubi Kayu

Produksi netto Ubi Kayu (C_{net}) adalah produksi bruto Ubi Kayu (C) dikurangi dengan pakan ternak (f) dan tercecer (w).

$$Pakan ternak (f) = C * 2\%$$

$$Tercecer (w) = C * 2,13 \%$$

$$C_{net} = C - (f + w)$$

(2). Ubi Jalar

Produksi netto Ubi Jalar (SP_{net}) adalah produksi bruto Ubi Jalar (SP) dikurangi dengan pakan ternak (f) dan tercecer (w).

$$Pakan ternak (f) = SP * 2\%$$

$$Tercecer (w) = SP * 10 \%$$

$$SP_{net} = SP - (f + w)$$

Untuk produksi bersih rata-rata ubi kayu dan ubi jalar (T_{net}) agar setara dengan beras, maka harus dikalikan dengan 1/3 (1 kg beras atau jagung ekuivalen dengan 3 kg ubi kayu dan ubi jalar dalam hal nilai kalori).

$$T_{net} = \frac{1}{3} * (C_{net} + SP_{net})$$

4). Produksi Netto Bahan Pangan Pokok

$$P_{food} = R_{net} + M_{net} + T_{net}$$

Jaringan syaraf tiruan adalah sebuah arsitektur paralel terdistribusi dengan banyak *node* dan *connection*. Tiap *connection* (hubungan) menghubungkan sebuah *node* ke *node* lainnya, dan tiap *connection* mempunyai nilai bobot (F_u , 1994).

Backpropagation merupakan sebuah metode sistematis untuk pelatihan *multilayer* jaringan syaraf tiruan. Metode ini memiliki dasar matematis yang kuat, obyektif, selain itu algoritma ini memiliki bentuk persamaan dan nilai koefisien dengan cara meminimalisasi jumlah kuadrat galat *error* melalui *training set* [6]. Langkah-langkah dari algoritma ini adalah:

- 1). Dimulai dengan lapisan masukan, hitung keluaran dari setiap elemen pemroses melalui lapisan luar
- 2). Hitung kesalahan pada lapisan luar yang merupakan selisih antara data aktual dan target
- 3). Transformasikan kesalahan tersebut pada kesalahan yang sesuai di sisi masukan elemen pemroses
- 4). Propagasi balik kesalahan-kesalahan ini pada keluaran setiap elemen pemroses ke kesalahan yang terdapat pada masukan. Ulangi proses ini sampai masukan tercapai.
- 5). Ubah seluruh bobot dengan menggunakan kesalahan pada sisi masukan elemen dan elemen pemroses yang terhubung.

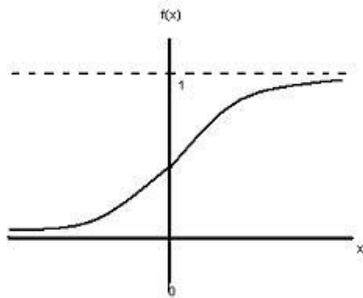
Fungsi aktivasi yang digunakan dalam jaringan *backpropagation* harus memiliki beberapa karakteristik penting seperti: fungsi harus bersifat kontinyu, terdefersial dan tidak menurun secara monoton. Selain itu agar perhitungannya lebih efisien, turunan dari fungsi aktivasi ini harus mudah dihitung. Fungsi aktivasi yang memenuhi kriteria tersebut dan sering digunakan adalah fungsi *binary sigmoid* dan fungsi *bipolar sigmoid*.

Fungsi *binary sigmoid* atau biasa disebut dengan *logsig* mempunyai nilai jangkauan antara nol dan satu atau (0,1) serta dapat didefinisikan dengan rumus berikut:

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

Dengan fungsi turunannya adalah:

$$f'(x) = f(x)(1 - f(x))$$



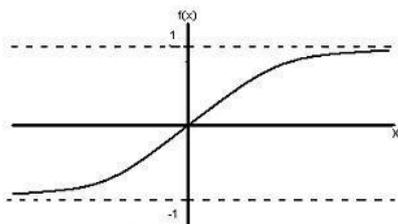
Gambar 1.
Fungsi Binary Sigmoid

Fungsi aktivasi lainnya yang sering digunakan dalam jaringan *backpropagation* adalah fungsi *bipolar sigmoid* atau biasa disebut sebagai fungsi tansig, yang mempunyai jangkauan nilai antara -1 dan 1 atau (-1, 1). Rumus fungsi ini adalah:

$$f(x) = \frac{2}{1 + e^{-x}} - 1$$

Dengan fungsi turunannya:

$$f'(x) = \frac{1}{2} [1 + f(x)][1 - f(x)]$$



Gambar 2.
Fungsi Bipolar Sigmoid

Pada dasarnya, algoritma pelatihan *backpropagation* akan menggerakkan bobot dengan arah gradien negatif, yakni memperbaiki bobot-bobot jaringan dengan arah yang membuat fungsi kinerja menjadi turun dengan cepat (*gradient descent*) [13]. Fungsi pembelajaran yang digunakan pada penelitian ini adalah: *traingd* (*gradient descent*), *traingdm* (*gradient descent* dengan momentum) dan *trainrp* (*resilient backpropagation*).

Time series adalah himpunan nilai-nilai hasil pengamatan berdasarkan periode waktu dan disusun untuk melihat pengaruh perubahan dalam rentang waktu tertentu. Sedangkan data *time series* merupakan data yang dikumpulkan, dicatat atau diobservasi secara berurutan. Periode observasi dapat berupa tahun, bulan, minggu dan untuk beberapa kasus ada pula periode dalam hari ataupun jam[4].

Perhitungan kesalahan merupakan pengukuran bagaimana jaringan dapat belajar dengan baik sehingga jika dibandingkan dengan pola yang baru akan mudah dikenali.

Kesalahan pada keluaran jaringan merupakan selisih antara keluaran sebenarnya dan target.

A. *Root Mean Square Error* (RMSE)

Perhitungannya adalah:

a. Hitung SSE

$$SSE = \sum_{i=1}^N (D_{ij} - f_j(X_i))^2$$

b. Hasilnya dibagi dengan perkalian antara banyaknya data pada pelatihan dan banyaknya keluaran, kemudian diakarkan.

$$RMSE = \sqrt{\frac{SSE}{N * K}}$$

N = Banyaknya data pada pelatihan

K = Banyaknya Keluaran

Jaringan yang telah optimal akan digunakan untuk simulasi terhadap data yang telah disiapkan untuk pengujian. Kinerja dari suatu jaringan syaraf tiruan setelah dilakukan suatu pelatihan dapat diukur dengan melihat *error* hasil pelatihan, validasi dan *testing* terhadap sekumpulan data *input* baru. Salah satu cara yang dapat digunakan untuk evaluasi ini adalah menggunakan analisis regresi terhadap respon jaringan dan target yang diharapkan. Matlab menyediakan fungsi *postreg* untuk melakukan evaluasi ini.

$$[m, b, r] = \text{postreg}(a, t)$$

a : *output* jaringan

t : target

m : hasil dari fungsi ini adalah gradien garis hasil regresi linier. Apabila *output* jaringan tepat sama dengan targetnya, maka gradien ini akan bernilai 1.

b : titik perpotongan dengan sumbu y. Apabila *output* jaringan tepat sama dengan targetnya, maka perpotongan dengan sumbu y ini akan bernilai 0.

R : koefisien korelasi antara *output* jaringan dan target. Apabila *output* jaringan tepat sama dengan targetnya, maka koefisien korelasi ini akan bernilai 1.

III. METODE PENELITIAN

Penelitian ini merupakan penelitian eksperimen, yakni penelitian yang berfokus pada penyelidikan beberapa variabel dan cara variabel-variabel tersebut dapat terpengaruh oleh suatu kondisi tertentu. Biasanya penelitian eksperimen digunakan untuk memverifikasi hipotesis yang sudah dirumuskan sebelumnya [2]. Dalam penelitian ini dilakukan penerapan Jaringan Syaraf Tiruan untuk prediksi produksi netto bahan pangan pokok.

Data sekunder yang digunakan dalam penelitian ini yaitu data produksi bruto padi, jagung, ubi jalar dan ubi kayu sejak tahun 1970 hingga 2010 yang diolah dengan formula tertentu untuk menghasilkan data produksi netto bahan pangan pokok. Data ini diperoleh dari Pusat Data dan Informasi (PUSDATIN) Kementerian Pertanian. Sedangkan data primer yang digunakan adalah data hasil pengolahan dengan Matlab yang akan dibandingkan dengan data aktual.

HASIL DAN PEMBAHASAN

Penelitian ini dilakukan melalui lima tahap, yaitu pengumpulan data, pengolahan data, pemodelan, validasi dan evaluasi.

1). Pengumpulan Data

Tahap ini dilakukan untuk mendapatkan data serta formulasi yang sudah tersedia.

TABEL 2.
DATA PRODUKSI NETTO PANGAN SERELIA

Tahun	PADI	JAGUNG	UMBI- UMBIAN	PFOOD
1970	11.018.096,54	2.489.014,42	4.130.862,32	17.637.973,28
1971	12.073.150,67	2.296.321,21	4.211.895,93	18.581.367,81
1972	11.430.846,17	1.986.110,54	4.067.773,84	17.484.730,55
1973	12.666.615,44	3.250.715,56	4.428.648,11	20.345.979,11
1974	13.247.469,35	2.652.498,06	5.067.859,01	20.967.826,42

Seperti yang tampak pada tabel di atas, jumlah produksi netto bahan pangan pokok (Pfood) merupakan hasil penjumlahan dari data jumlah netto padi, jagung dan umbi-umbian. Data produksi netto bahan pangan pokok tersebut merupakan data runtun waktu tahunan.

2). Pengolahan Data

Merupakan tindak lanjut dari pengumpulan data, tahap ini terdiri dari:

a. Penentuan data *input* dan *output*

Data *input* dan *output* yang digunakan dalam penelitian ini adalah data *time series* (runtun waktu), yakni data jumlah produksi netto bahan pangan pokok mulai tahun 1970 hingga 2010. Data *input* merupakan data 9 tahun sebelumnya dan data *output* adalah data satu tahun berikutnya.

b. Normalisasi data

Normalisasi data dilakukan sesuai fungsi aktivasi yang digunakan, dalam penelitian ini digunakan dua fungsi aktivasi yakni *binary sigmoid* (logsig) dan *bipolar sigmoid* (tansig). Jika menggunakan fungsi *binary sigmoid* (logsig), maka data harus dinormalisasi sehingga berada dalam *range* 0 sampai 1. Sedangkan jika fungsi aktivasi yang digunakan adalah fungsi *bipolar sigmoid*, maka data harus dinormalisasi agar data berada dalam *range* -1 sampai 1.

3). Tahap Pemodelan

Dilakukan untuk menghasilkan arsitektur jaringan syaraf yang optimal. Tahap ini terdiri dari:

(1). Menentukan Parameter Pembelajaran, yaitu Maksimum *Epoch*, Besar Galat, fungsi *training* dan *Learning Rate*

Parameter-parameter ini akan berpengaruh terhadap kinerja sistem dalam proses pembelajaran terhadap proses prediksi. Untuk maksimum *epoch* dilakukan pengujian *epoch* sampai mendapatkan nilai *epoch* terbaik dan untuk galat digunakan nilai 0,0001 sebagai kriteria pemberhentian. Fungsi *training* yang digunakan terdiri dari 3 jenis, yakni fungsi *default* Matlab (traingd), traingdm dan trainrp. Sedangkan *learning rate* diberikan nilai awal 0,1.

(2). Menentukan Fungsi Bobot yang Akan Digunakan Berdasarkan Fungsi Aktivasi

Penentuan nilai bobot minimum dan maksimum ditentukan atas dasar nilai jangkauan fungsi, yakni fungsi *sigmoid biner* dan fungsi *sigmoid bipolar*. Karena dalam penelitian ini menggunakan *software* Matlab, maka bobot akan ditentukan otomatis secara acak oleh Matlab.

4). Simulasi

Pada tahap ini dilakukan simulasi menggunakan *software* Matlab untuk semua jaringan yang dirancang.

5). Tahap Validasi

Pada tahap ini dilakukan pengujian akurasi atas model prediksi yang dianggap paling optimal.

6). Tahap Evaluasi

Menelaah secara keseluruhan atas apa yang sudah dilakukan pada penelitian ini, selanjutnya membuat kesimpulan. Kesimpulan dibuat secara terukur dan didasari oleh hasil studi pustaka, perancangan, serta simulasi dan validasi hasil. Kesimpulan berdasarkan pada permasalahan dan tujuan yang ditetapkan.

Proses *training* pada Jaringan Syaraf Tiruan dipengaruhi oleh beberapa hal, diantaranya adalah arsitektur jaringan yang digunakan serta nilai parameter yang diberikan [19]. Pada penelitian ini, dilakukan uji coba dengan arsitektur jaringan yang dicari dengan mengkombinasikan beberapa *neuron* pada *hidden layer*, 1 lapisan dengan 9 *neuron* pada *input layer* dan 1 lapisan dengan 1 *neuron* pada *output layer*.

Selain itu, dicari beberapa nilai parameter yang telah disesuaikan sehingga dapat ditentukan nilai parameter terbaik untuk menghasilkan prediksi data yang optimal. Parameter yang digunakan dalam eksperimen antara lain jumlah *epoch*, jumlah *neuron hidden layer*, fungsi aktivasi, fungsi pembelajaran serta lama *training (time)*.

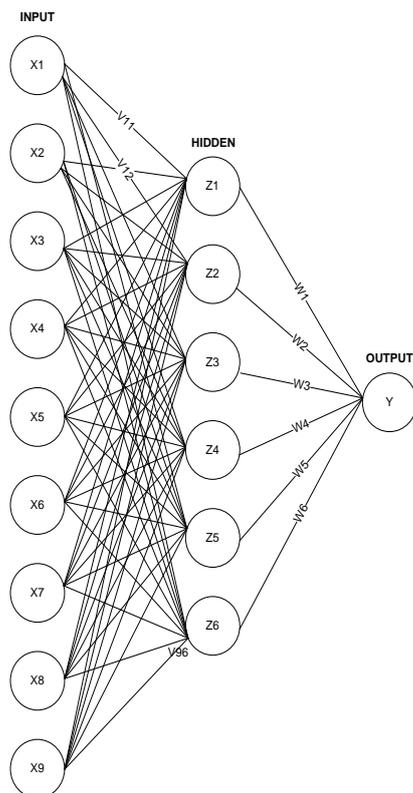
Suatu jaringan dengan jumlah *neuron* pada *hidden layer* yang terlalu banyak, maka akan cenderung tidak mampu menggeneralisasi. Yang artinya model hanya berfungsi baik pada ruang sampelnya saja, sedangkan jika

menggunakan data di luar sampel maka akan tidak dapat memprediksi dengan baik. Sebaliknya, jika jumlah *neuron* terlalu sedikit, maka yang terjadi adalah model tidak akan mampu memprediksi dengan baik walaupun dengan data yang ada di ruang sampelnya [6].

Sesuai dengan tujuan penelitian ini, yakni mencari model prediksi yang tidak hanya akurat, namun juga optimal. Maka model jaringan dengan *error* kecil tetapi memiliki nilai parameter lainnya yang cukup besar, tidak akan terpilih sebagai jaringan yang optimal.

Penilaian performa prediksi atau pengukuran keakuratan dan keoptimalan suatu arsitektur jaringan yang digunakan dalam penelitian ini menggunakan faktor kesalahan RMSE dan fungsi penilaian kinerja yang ada pada Matlab, yaitu *postreg*.

Berdasarkan beberapa eksperimen yang telah dilakukan, arsitektur jaringan syaraf tiruan teroptimal untuk prediksi produksi netto bahan pangan pokok adalah arsitektur 9-6-1. Arsitektur ini terdiri dari 1 lapisan input dengan 9 neuron, 1 lapisan *hidden* dengan 6 neuron dan 1 lapisan *output* dengan 1 neuron. Parameter terbaiknya adalah menggunakan fungsi aktivasi tansig dan fungsi pelatihan *trainrp* (*resilient backpropagation*), dengan waktu hanya 2 detik untuk 138 *epochs*. Nilai MSE yang dihasilkan adalah 0,0100. Gambar dari arsitektur jaringan tersebut dapat dilihat di bawah ini:



Gambar 1.
Model Prediksi Jumlah Produksi Bahan Pangan Pokok

Sumber: Hasil Penelitian (2011)

Keterangan :

X1 sampai X9 : data netto bahan pangan pokok tahun sebelumnya, selengkapnya dapat dilihat di lampiran

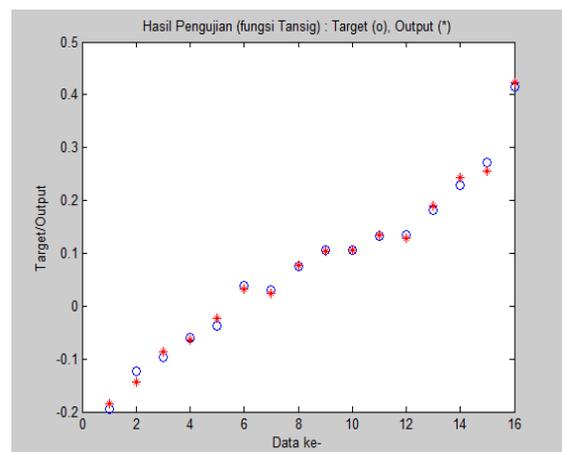
Z1 sampai Z6 : *hidden layer*

Y : Output yang diinginkan

TABEL 4.
PERBANDINGAN TARGET DENGAN OUTPUT

Data ke-	Target	Output
1	-0,1950	-0,1837
2	-0,1227	-0,1429
3	-0,0961	-0,0859
4	-0,0608	-0,0647
5	-0,0380	-0,0228
6	0,0374	0,0323
7	0,0308	0,0242
8	0,0747	0,0774
9	0,1057	0,1032
10	0,1065	0,1057
11	0,1333	0,1348
12	0,1351	0,1279
13	0,1824	0,1890
14	0,2288	0,2441
15	0,2724	0,2564
16	0,4161	0,4223

Sumber: Hasil Penelitian (2011)



Gambar 2.
Grafik Perbandingan Target dan Output Jaringan

Sumber: Hasil Penelitian (2011)

KESIMPULAN

Berdasarkan hasil eksperimen, mulai tahap awal hingga evaluasi, dapat ditarik kesimpulan bahwa model prediksi jumlah produksi netto bahan pangan pokok yang optimal dan cukup akurat adalah dengan arsitektur 9-6-1, yakni 1 lapisan *input* dengan 9 *neuron*, 1 lapisan *hidden* dengan 6 *neuron* dan 1 lapisan *output* dengan 1 *neuron*. Parameter terbaiknya adalah menggunakan fungsi aktivasi *tansig* dan fungsi pelatihan *trainrp*, yang hanya memerlukan waktu 2 detik untuk 138 epochs. Nilai RMSE yang dihasilkan adalah 0,0100.

SARAN

Penelitian ini telah menghasilkan suatu model prediksi yang optimal dan akurat, namun untuk penelitian selanjutnya masih memerlukan pengembangan dalam beberapa hal, yakni:

- 1). Melakukan simulasi prediksi dengan jumlah data yang lebih banyak, seperti mengganti data tahunan menjadi data bulanan ataupun data nasional menjadi data per provinsi, sehingga analisa akan bertambah optimal dan akurat
- 2). Menggunakan parameter yang lebih bervariasi, sehingga akan menghasilkan hasil prediksi yang lebih baik.
- 3). Membangun sebuah sistem/aplikasi dengan menerapkan metode jaringan syaraf tiruan untuk prediksi produksi netto bahan pangan pokok.

REFERENSI

- [1] Balaghi, R. (2006). *Wheat Grain Yield Forecasting Models for Food Security in Morocco*. Morocco.
- [2] Berndtsson, M. (2008). *Thesis Project, A Guide for Students in Computer Science and Information System*. London: Springer.
- [3] Boosarawongse, R., Henry, & Feng, P. (2007). Box-Jenkins vs. Artificial Neural Networks in Predicting Commodity Prices Forecasting the Export Prices of Thai Rice. *International DSI*.
- [4] Box, G. E., & Jenkins, G. (1976). *Time Series Analysis: Forecasting and Control*. San Francisco: Holden-Day.
- [5] Ezrin, M. H., Amin, M. S., Anuar, A. R., & Aimrun, W. (2009). Rice Yields Prediction Using Apparent Electrical Conductivity of Paddy Soils. *European Journal of Scientific Research*, 575-590.
- [6] Fausett, L. (1994). *Fundamentals of Neural Networks, Architectures, Algorithms and applications*. New Jersey: Prentice-Hall.
- [7] Fu, L. M. (1994). *Neural Networks in Computer Intelligence*. McGraw-Hill International.
- [8] Hasibuan, Z. A. (2007). *Metodologi Penelitian pada Bidang Ilmu Komputer dan Teknologi Informasi*. Depok: Universitas Indonesia.
- [9] Jha, G. K. (2007). Artificial Neural Networks. *Indian Agricultural Research*, 1.
- [10] Kementrian Pertanian RI. (2009). *Peta Ketahanan Pangan dan Kerentanan Pangan Indonesia*. Jakarta: Kementrian Pertanian.
- [11] Kudang, B. S., Marimin, AndarWulan, N., Belawati, Y. F., Herdiyenny, Y., & Solahudin, M. (2009). Studi Sistem Deteksi Dni Untuk Manajemen Krisis Pangan Dengan Simulasi Model Dinamis dan Komputasi Cerdas. *Hasil-hasil Penelitian IPB*.
- [12] Kusumadewi, S. (2003). *Artificial Intelligence (Teknik dan Aplikasinya)*. Yogyakarta: Graha Ilmu.
- [13] Kusumadewi, S. (2004). *Membangun Jaringan Syaraf Tiruan dengan Matlab dan Excel Link*. Yogyakarta: Graha Ilmu.
- [14] Makridakis, S., Wheelwright, S. C., & Hyndmand, R. J. (1998). *Forecasting Methods and Applications.3Rd Ed*. New York: John Wiley & Sons.
- [15] Pakravan, M. R., Kelasemi, M. K., & Alipour, H. R. (2010). "Forecasting Iran's Rice Imports Trend During 2009-2013".
- [16] Reich, Y. (1994). Layer Models of Research Methodologies. *AI EDAM*, 263-274.
- [17] Saad, P., Yaakob, S. N., Rahaman, N. A., Daud, S., Bakri, A., Kamarudin, S. S., et al. (2004). Artificial Neural Network Modelling of Rice Yield Prediction in Precision Farming.
- [18] Shabri, A., Samsudin, R., & Ismail, Z. (2009). Forecasting of the Rice Yields Time Series Forecasting using ANN and Statistical Model. *Asian Network for Scientific Iformation*, 4168-4173.
- [19] Shukla, A., Tiwari, R., & Kala, R. (2010). *Real Life Applications of Soft Computing*. New York: CRC Press.
- [20] Siang, J. J. (2009). *Jaringan Syaraf Tiruan & Pemrogramannya*. Yogyakarta: Andi.
- [21] Sipayung, S. B., & Sutikno. (2009). Pemanfaatan Global Circulation Model (GCM) untuk Prediksi Produksi Padi. *Sains Dirgantara*, 82-94.
- [22] Suryana, A. (2004). Arah dan Strategi Perwujudan Ketahanan Pangan. *Evaluasi Kebijakan Pangan dan Kemiskinan* (hal. 307-318). Bogor: Institut Pertanian Bogor.
- [23] Susanti, Y., & Pratiwi, H. (2007). Prediksi produksi padi jagung menggunakan estimasi M. *Math-M*.
- [24] UNDP. (2010, Januari). *Human Development Report*. UNDP.
- [25] Xiao, J., Ma, Z., & Zhang, D. (2009). The Research on the BP Neural Network in the Food Security Risk Early Warning Applied Under Supply Chain Environment.



Nurfia Oktaviani Syamsiah, M.Kom. Tangerang Oktober 1985. Tahun 2008 lulus dari Program Strata Satu (S1) Jurusan Sistem Informasi STMIK Nusa Mandiri Jakarta. Tahun 2011 lulus dari Program Strata Dua (S2) Jurusan Magister Ilmu Komputer STMIK Nusa Mandiri Jakarta. Tahun 2012 sudah memiliki Jabatan Fungsional Akademik Asisten Ahli di AMIK BSI Jakarta. Aktif dalam pengembangan Program Studi melalui Konsorsium Program Studi dan menulis paper di beberapa jurnal.



Romi Satria Wahono. Memperoleh gelar B.Eng dan M.Eng masing-masing di Ilmu Komputer dari Saitama University, Jepang, dan Ph.D dalam Rekayasa Perangkat Lunak dari Universiti Teknikal Malaysia Melaka. Pengajar di Pascasarjana Ilmu Komputer, Universitas Dian Nuswantoro, Indonesia. Juga pendiri dan CEO PT Brainmatics, sebuah perusahaan pengembangan perangkat lunak di Indonesia. Minat penelitiannya saat ini meliputi rekayasa perangkat lunak dan machine learning. Anggota profesional dari asosiasi ilmiah ACM, PMI dan IEEE Computer Society.