

PERAMALAN PRODUKSI GULA NASIONAL MELALUI PENDEKATAN ARTIFICIAL NEURAL NETWORK

Oleh :

Bambang Suhada, S.E., M.Si.
Dosen PNS Dpk FE - UM Metro

Abstrak

Pada awalnya ide jaringan syaraf tiruan (JST) berkembang dari komputer analog yang meniru otak manusia. Suatu JST terdiri atas banyak unit tunggal dan unit pengolahan sederhana yang berinteraksi melalui suatu jaringan pada antar koneksi. Melalui struktur jaringan inilah JST mampu belajar dan mengingat pola kompleks (Wilppu, 1999). JST belajar melalui dua paradigma utama yaitu pembelajaran tersedia (supervised learning) dan pembelajaran tak tersedia (unsupervised learning) (Fu, 1994)

Otak manusia terdiri atas sel-sel syaraf yang disebut neuron, yang berjumlah sekitar 10^9 neuron. Neuron-neuron tersebut terbagi atas kelompok-kelompok yang disebut dengan jaringan, yang dibedakan berdasarkan fungsinya; setiap group mengandung ribuan neuron yang saling berhubungan. Setiap neuron mempunyai kemampuan untuk menerima, memproses, dan menghantarkan sinyal elektro kimiawi melalui jalur-jalur syaraf. Neuron buatan dirancang untuk menirukan karakteristik neuron biologis. Jaringan syaraf, dengan kemampuan luar biasanya dapat mengartikan data yang rumit, dapat juga digunakan untuk mengubah pola yang terlalu kompleks (banyak). Sebuah jaringan syaraf yang terlatih dapat disebut sebagai “pakar” untuk menganalisa di bidang informasi

Sistem JST merupakan suatu upaya untuk mensimulasikan hardware tertentu atau software yang rumit dengan elemen-elemen pemroses, disebut neuron, yang berlapis-lapis. Tiap neuron dihubungkan dengan tetangga terdekatnya dengan tingkat koefisien keterhubungan yang berbeda-beda, yang merepresentasikan kekuatan keterhubungan

Peramalan dengan menggunakan pendekatan ANN ternyata memberikan nilai MSE yang sangat kecil mendekati 0. Hal ini berarti pendekatan Artificial Neural Network memiliki akurasi yang sangat tinggi dalam melakukan prediksi terhadap suatu model sistem. Keakuratan ANN dalam memprediksi suatu model karena proses peramalan mempertimbangkan faktor-faktor lain yang berpengaruh

Pada dekade terakhir, khususnya periode 1994-2004, industri gula Indonesia menghadapi berbagai masalah yang signifikan. Salah satu indikator masalah industri gula Indonesia adalah kecenderungan volume impor yang terus meningkat,

dari 194,700 ton pada tahun 1986 menjadi 1.348 juta ton pada tahun 2004, atau meningkat dengan laju 11.4 % per tahun. Pada periode 1994- 2004, impor gula meningkat dengan laju 7.8 % per tahun. Hal ini terjadi karena ketika konsumsi terus meningkat dengan 1.2

% per tahun produksi gula dalam negeri menurun dengan laju -1.8 per tahun (DGI, 2006)

Dalam tiga tahun terakhir, konsumsi gula domestik meningkat dengan laju $3,3$ persen per tahun. Perpaduan antara peningkatan konsumsi dan penurunan produksi gula tebu telah menyebabkan akselerasi defisit yang harus ditutupi oleh impor dalam jumlah yang makin besar. Peningkatan ketergantungan terhadap impor gula dipandang sebagai ancaman terhadap ketahanan pangan (*food security*) dan kehilangan kesempatan pasar bagi industri gula domestik. Akselerasi peningkatan import, tidak dapat diterima baik secara politik maupun secara ekonomi, sehingga harus diredam melalui peningkatan produksi gula domestik (Simatupang, 2004).



Gambar 1. Perkembangan produksi Gula Nasional

Membiarkan impor terus meningkat berarti membiarkan industri gula terus mengalami kemunduran yang akan menimbulkan masalah bagi Indonesia. *Pertama*, industri gula melibatkan sekitar 1.4 juta petani dan tenaga kerja (Bakrie dan Susmiadi, 1999). *Kedua*, kebangkrutan industri gula juga berkaitan dengan aset yang sangat besar dengan nilai sekitar Rp 50 triliun. *Ketiga*, gula merupakan kebutuhan pokok yang mempunyai

pengaruh langsung terhadap inflasi, sesuatu yang mengkhawatirkan pelaku bisnis, masyarakat umum, dan pemerintah. Lebih jauh, membiarkan ketergantungan kebutuhan pokok yang harganya sangat fluktuatif dengan koefisien keragaman harga tahunan sekitar 48% akan berpengaruh negatif terhadap upaya pencapaian ketahanan pangan (Pakpahan, 2000; Simatupang et al. 2000). Selanjutnya, beban devisa untuk mengimpor akan terus meningkat yang pada lima tahun terakhir rata-rata devisa yang dikeluarkan sudah mencapai US\$ 200 juta (Direktorat Jenderal Perkebunan, 2000).

Ketika produksi terus mengalami penurunan, konsumsi domestik baik oleh rumah tangga maupun industri terus mengalami peningkatan. Pada tahun 1984, konsumsi gula domestik baru mencapai 1.866 juta ton. Pada tahun 2004, konsumsi melonjak menjadi 3.4 juta ton atau mengalami peningkatan sekitar 0.5% per tahun. Peningkatan konsumsi terutama berkaitan dengan dua faktor yaitu pertambahan penduduk dan peningkatan pendapatan atau pertumbuhan ekonomi (Susila, 2005).

Tujuan yang ingin dicapai dalam penelitian tentang adalah melakukan proyeksi terhadap jumlah produksi gula nasional untuk Tahun 2007.

Manfaat Penelitian Menjadi masukan bagi pemerintah (Kementerian BUMN atau Departemen Terkait) dalam merencanakan kebutuhan produksi gula nasional; Membantu merumuskan strategi dalam perencanaan produksi gula nasional.

II. METODOLOGI PENELITIAN

Pada awalnya ide jaringan syaraf tiruan (JST) berkembang dari komputer analog yang meniru otak manusia. Suatu JST terdiri atas banyak unit tunggal dan unit pengolahan sederhana yang berinteraksi melalui suatu jaringan pada antar koneksi. Melalui struktur jaringan inilah JST mampu belajar dan mengingat pola kompleks (Wilppu, 1999). JST belajar melalui dua paradigma utama yaitu pembelajaran tersedia (*supervised learning*) dan pembelajaran tak tersedia (*unsupervised learning*) (Fu, 1994)

Otak manusia terdiri atas sel-sel syaraf yang disebut neuron, yang berjumlah sekitar 10^9 neuron. Neuron-neuron tersebut terbagi atas kelompok-kelompok yang disebut dengan jaringan, yang dibedakan berdasarkan fungsinya; setiap group mengandung ribuan neuron yang saling berhubungan. Setiap neuron mempunyai kemampuan untuk menerima, memproses, dan menghantarkan sinyal elektro kimiawi melalui jalur-jalur syaraf. Neuron buatan dirancang untuk menirukan karakteristik neuron biologis. Jaringan syaraf, dengan kemampuan luar biasanya dapat mengartikan data yang rumit, dapat juga digunakan untuk mengubah pola yang terlalu kompleks (banyak). Sebuah jaringan syaraf yang terlatih dapat disebut sebagai “pakar” untuk menganalisa di bidang informasi. Keuntungan lainnya meliputi :

1. *Adaptive Learning*, yaitu kemampuan untuk belajar bagaimana melakukan tugas berdasarkan data yang telah diberikan untuk latihan atau pengalaman pertama.

2. *Self-organization*, yaitu sebuah jaringan syaraf buatan dapat membuat organisasi sendiri atau merepresentasi informasi yang diterimanya pada waktu belajar.
3. *Real time operation*, artinya input, proses dan output (hasil) diperoleh pada saat itu juga.

Sistem JST merupakan suatu upaya untuk mensimulasikan hardware tertentu atau *software* yang rumit dengan elemen-elemen pemroses, disebut neuron, yang berlapis-lapis. Tiap neuron dihubungkan dengan tetangga terdekatnya dengan tingkat koefisien keterhubungan yang berbeda-beda, yang merepresentasikan kekuatan keterhubungan. Pembelajaran dilaksanakan dengan mengatur kekuatan tersebut agar keseluruhan jaringan memberikan hasil keluaran sebagaimana yang dikehendaki (Kleifors 1998). Model JST merupakan model matematis neural yang menggambarkan fungsi neuron, seperti pada Gambar 3. Secara matematis, neural dapat digambarkan sebagai operasi pemetaan vektor input ke output scalar. Operasi pemetaan ini dinyatakan dalam persamaan berikut :


$$Y(t) = f[u(t)] = f[\sum X_i(t) w_i(t)]$$

Dengan :

$W_i(t)$ adalah faktor bobot

$X_i(t)$ adalah input neural

$U(t)$ adalah fungsi aktivasi




Gambar 2. Model Jaringan Syaraf Tiruan (Kleifor 1998)

a. Fungsi Aktivasi


Fungsi aktivasi adalah fungsi yang mengubah nilai penjumlahan input dengan bobotnya menjadi output pada unit di lapisan tersembunyi dan lapisan output. Beberapa fungsi aktivasi yang banyak digunakan dalam pemakaian JST (Kusumadewi 2004) adalah sebagai berikut:

1. Fungsi Undak Biner (*Step Function*). Fungsi ini umumnya digunakan pada jaringan dengan lapisan tunggal untuk mengkonversikan input dari suatu variabel kontinu ke suatu output biner (0 atau 1). Persamaan dan fungsi dapat dilihat pada Gambar 3.




Gambar 3. Persamaan dan fungsi undak Biner

2. Fungsi Bipolar. Fungsi ini hampir sama dengan fungsi undak biner, hanya saja output yang dihasilkan berupa 1 atau -1 (Gambar 4),




Gambar 4. Persamaan dan fungsi Bipolar

3. Fungsi Linier. Fungsi ini memiliki nilai output yang sama dengan nilai inputnya (Gambar 5).




4. Fungsi Saturating Linier. Fungsi ini akan bernilai 0 jika inputnya kurang dari -0.5 dan akan bernilai 1 bila inputnya lebih dari 0.5. Jika inputnya terletak antara -0.5 dan 0.5, maka outputnya bernilai sama dengan nilai input ditambah 0.5. Persamaan dan fungsi saturating linier dapat dilihat pada Gambar 6.




Gambar 6. Persamaan dan fungsi Saturating Linier

5. Fungsi Symetric Saturating Linier. Fungsi ini akan bernilai -1 jika inputnya kurang dari -1 dan akan bernilai 1 bila inputnya lebih dari 1. Jika inputnya terletak antara -1 dan 1, maka outputnya bernilai sama dengan nilai inputnya. Persamaan dan fungsi saturating linier dapat dilihat Gambar 7.




Gambar 7. Persamaan dan fungsi Symetric Saturating Linier

6. Fungsi Sigmoid Biner. Fungsi ini digunakan untuk jaringan syaraf yang dilatih dengan menggunakan metode propagasi balik. Fungsi sigmoid biner memiliki nilai pada range 0 samapi 1. oleh karena itu fungsi ini sering digunakan untuk jaringan syaraf yuang membutuhkan nilai output yang terletak pada interval 0 sampai 1.
7. Namun fungsi ini dapat juga digunakan oleh jaringan syaraf yang nilai outputnya 0 atau 1. Persamaan dan fungsi sigmoid biner dapat dilihat pada Gambar 8.




Gambar 8. Persamaan dan fungsi Sigmoid Biner (Kusumadewi 2004)



Gambar 9. Persamaan dan fungsi Dignmoid Bipolar (Kusumadewi, 2004)

b. Struktur Jaringan Syaraf Tiruan

Struktur atau arsitektur dari JST adalah arsitektur lapis banyak dengan n buah neuron pada satu lapisan input (*input layer*), p buah nuron pada satu atau lebih lapisan tersembunyi dan m buah neuron pada satu lapisan output (*output layer*). Lapisan input berfungsi untuk meneruskan masukan dan tidak melakukan perhitungan, sedangkan lapisan tersembunyi dan lapisan output melakukan perhitungan. Bentuk struktur dari jaringan syaraf tiruan dapat dillihat pada Gambar 11.



Gambar 10. Struktur Jaringan Syaraf Tiruan (Plummer 2000)

Suatu JST dapat memiliki beberapa lapisan (*layer*), unit per *layer*, *network input*, dan *network output*. Layer A dan B pada Gambar 11 merupakan *hidden layer* (layer tersembunyi), dan layer C merupakan layer output. Layer input berfungsi untuk menerima data, layer tersembunyi melakukan proses internal, dan layer output mengeluarkan hasil berupa suatu dugaan. Terdapat dua struktur JST, yaitu *feed forward* dan *feedback (recurrent)*. Pada JST berstruktur *feed forward*, neuron di suatu lapisan mengirimkan keluaran ke neuron di lapisan selanjutnya tetapi tidak berfungsi sebaliknya, sehingga hanya merespon masukan yang diberikan dan tidak mempunyai elemen dinamis di dalamnya (statis). Sedangkan pada JST berstruktur *feedback*, neuron di lapisan keluaran mengirimkan hasilnya lagi ke neuron di lapisan input, sehingga tidak hanya merespon input, tetapi juga merespon output, yang di umpanbalik ke input (dinamis).

c. Algoritma Pelatihan

Pembelajaran (*learning*) dan pelatihan (*training*) adalah proses untuk mengubah nilai faktor pembobot sehingga JST mampu menghasilkan keluaran seperti yang diinginkan selama proses pembelajaran. Secara umum pelatihan ini dibedakan menjadi dua, yaitu pelatihan dengan terawasi (*supervised training*) dan pelatihan tanpa terawasi (*unsupervised training*). Dalam pelatihan dengan terawasi, faktor bobot diperbaharui dengan menggunakan referensi. Mula-mula JST diberikan faktor bobot awal secara acak.

Ketika diberikan pasangan data input-output, JST akan memproses data input sehingga menghasilkan keluaran. Keluaran ini selanjutnya dibandingkan dengan referensi (data output), sehingga diperoleh error. Berdasarkan error ini, faktor bobot diperbaharui melalui kaidah pelatihan tertentu, misalnya dengan menggunakan *Least Means Square (LMS)* dan *back propagation* (propagasi balik).

Pelatihan tanpa terawasi, tidak membutuhkan referensi pada proses pembelajarannya. Tidak ada faktor eksternal yang dapat mengubah bobot JST tanpa terawasi adalah mengoreksi nilai bobot sedemikian rupa, sehingga output yang dihasilkannya memberikan representatif yang berguna berdasarkan statistik lingkungannya (Gustavo dan Obradovic 1996).

d. Jaringan Syaraf Tiruan dengan *Back Propagation*

JST dengan *back propagation* (propagasi balik) merupakan JST yang memiliki arsitektur, pelatihan dan fungsi aktivasi sendiri (Fausett, 1994). Pelatihan pada JST propagasi balik melibatkan tiga tahap di bawah ini :

1. *Feed forward* dari pola pelatihan input. Pada tahap ini lapisan input menerima input dan mengirimkannya ke lapisan tersembunyi guna pelatihan.
2. Propagasi balik dari error
3. Penyesuaian bobot.

Setiap unit tersembunyi menghitung fungsi aktivitas dan mengirim (z_i) ke unit keluaran (Y_k). Setiap unit keluaran memberikan respon untuk setiap pola input yang diterima. Algoritma

pelatihan pada jaringan syaraf propagasi balik (Fausett 1994), sebagai berikut :

Langkah 0. Tentukan bobot awal {nilai acak yang kecil}

Langkah 1. Bila error jaringan lebih besar dari toleransi error maka lakukan langkah 2 – 9 {tahap *feed forward*}

Langkah 2. Untuk setiap pasangan pelatihan lakukan langkah 3 – 8

Langkah 3. Masing-masing unit input ($X_1, X_2, \dots, X_n$) menerima sinyal input x_i , dan mengirimkan sinyal ini ke seluruh unit pada lapisan tersembunyi

Langkah 4. Untuk setiap lapisan tersembunyi ($Z_1, Z_2, \dots, Z_p$) dilakukan penjumlahan sinyal input beserta bobotnya sesuai dengan rumus di bawah ini :

Sinyal keluarannya dihitung dengan :

$$Z_j = f(z_{in_j})$$

Lapisan tersembunyi mengirim sinyal ini ke semua unit pada unit-unit keluaran

Langkah 5. Setiap unit output ($Y_1, Y_2, \dots, Y_m$) menjumlahkan sinyal output beserta bobotnya :

Menghitung fungsi aktivitas sebagai output jaringan :

$$Y_k = f(y_{in_k}) \text{ {Progasi balik error}}$$

Langkah 6. Setiap unit output menerima pola target

yang diperoleh dari training input, dan error dihitung dengan menggunakan rumus berikut :

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

Menghitung koreksi bobot digunakan untuk memperbaharui nilai W_{jk}

$$\Delta W_{ok} = \alpha \delta_j X_j$$

Dan kirim δ_k ke lapisan sebelumnya.

Langkah 7. Untuk lapisan tersembunyi dilakukan penghitungan jumlah error dari neuron sebagai berikut:

Menghitung nilai aktivitas koreksi error:

$$\delta_j = \delta_{in_j} f'(z_{in_j})$$

Menghitung koreksi bobot neuron lapisan tersembunyi :

$$\Delta v_{jk} = \alpha \delta_j W_{jk}$$

Menghitung koreksi error bias lapisan tersembunyi :

$$\Delta v_{oj} = \alpha \delta_j \text{ {Perbaharui bobot dan bias}}$$

Langkah 8. Setiap unit output memperbaharui bias dan bobotnya ($j=0, \dots, P$)

$$W_{jk}(\text{new}) = W_{jk}(\text{old}) + \Delta W_{jk}$$

Setiap neuron pada lapisan tersembunyi

memperbaharui bias dan bobotnya ($i=0, \dots, n$)

$$v_{ij}(\text{new}) = v_{jk}(\text{old}) + \Delta v_{jk}$$

langkah 9. Uji nilai error.

Jika lebih besar dari toleransi error, kembali ke langkah 1

Keterangan :

- X : Vektor data masukan untuk pelatihan
 t : Vektor target keluaran
 δ_k : Koreksi error penentuan bobot wjk
 δ_j : Koreksi error penentuan bobot vij
 α : Kecepatan pembelajaran
 X_1 : Unit masukan ke-1
 v_{oi} : Bias pada lapis tersembunyi ke-j
 Z_j : Lapis tersembunyi ke-j Masukan Z_j , dilambangkan dengan z_{in_j} Sinyal keluaran dari Z_j dilambangkan dengan z_j .
 W_{ok} : Bias pada lapis keluaran ke k.
 Y_k : Lapis Keluar ke k. Masukan Y_k dilambangkan dengan y_{in_k} . Sinyal keluaran dari Y_k dilambangkan dengan y_k .

2.1. Kriteria Kinerja Peramalan

Mean Square Error (MSE) adalah salah satu kriteria yang sering digunakan dalam membandingkan akurasi beberapa metode peramalan. Rumus yang digunakan adalah sebagai berikut :

dimana:

dt = data aktual pada periode t


Dt' = nilai ramalan pada periode t

n = banyaknya periode

2.2. Kerangka Pemikiran

Melalui scatter diagram ditunjukkan bahwa pola data produksi gula nasional menunjukkan kecenderungan peningkatan (*trend*) dari tahun ke tahun. Namun demikian, gambaran sebenarnya menunjukkan kondisi adalah fluktuatif, dengan volume produksi gula nasional berkisar antara 1.500.000 ton sampai 2.500.000 ton.

Berikut digambarkan kerangka pemikiran dari peramalan produksi gula nasional dengan menggunakan pendekatan ANN.



III. HASIL DAN PEMBAHASAN

3.1. Peramalan

Peramalan produksi gula nasional menggunakan metode ANN dilakukan dengan menggunakan data input dan output sebagaimana disajikan pada Tabel 1. Sebagai output adalah jumlah produksi gula, sementara sebagai input yaitu produksi gula t-1, t-2, t-3, t-4, t-5 dan t-6. Hal ini diasumsikan bahwa kebutuhan produksi gula dipengaruhi oleh produksi gula dari 6 (tahun) sebelumnya.

Tabel 1. Data input dan output pada peramalan produksi gula nasional

Tahun	x1	x2	x3	x4	x5	x6	output
1	1,621,620	1,871,139	1,909,950	2,090,579	1,784,264	1,907,592	1,942,051
2	1,871,139	1,909,950	2,090,579	1,784,264	1,907,592	1,942,051	1,943,700
3	1,909,950	2,090,579	1,784,264	1,907,592	1,942,051	1,943,700	2,235,160
4	2,090,579	1,784,264	1,907,592	1,942,051	1,943,700	2,235,160	2,080,341
5	1,784,264	1,907,592	1,942,051	1,943,700	2,235,160	2,080,341	2,194,200
6	1,907,592	1,942,051	1,943,700	2,235,160	2,080,341	2,194,200	2,142,550
7	1,942,051	1,943,700	2,235,160	2,080,341	2,194,200	2,142,550	2,272,568
8	1,943,700	2,235,160	2,080,341	2,194,200	2,142,550	2,272,568	2,317,869
9	2,235,160	2,080,341	2,194,200	2,142,550	2,272,568	2,317,869	2,212,278
10	2,080,341	2,194,200	2,142,550	2,272,568	2,317,869	2,212,278	2,051,710
11	2,194,200	2,142,550	2,272,568	2,317,869	2,212,278	2,051,710	2,234,902
12	2,142,550	2,272,568	2,317,869	2,212,278	2,051,710	2,234,902	2,146,994
13	2,272,568	2,317,869	2,212,278	2,051,710	2,234,902	2,146,994	2,142,587
14	2,317,869	2,212,278	2,051,710	2,234,902	2,146,994	2,142,587	1,708,307
15	2,212,278	2,051,710	2,234,902	2,146,994	2,142,587	1,708,307	1,815,172
16	2,051,710	2,234,902	2,146,994	2,142,587	1,708,307	1,815,172	1,934,076
17	2,234,902	2,146,994	2,142,587	1,708,307	1,815,172	1,934,076	1,755,434
18	2,146,994	2,142,587	1,708,307	1,815,172	1,934,076	1,755,434	1,948,683
19	2,142,587	1,708,307	1,815,172	1,934,076	1,755,434	1,948,683	2,049,300
20	1,708,307	1,815,172	1,934,076	1,755,434	1,948,683	2,049,300	2,114,168
21	1,815,172	1,934,076	1,755,434	1,948,683	2,049,300	2,114,168	2,265,692

Data produksi gula nasional yang diperoleh (Sumber : BPS, Deptan dan Dewan Gula Indonesia) adalah dari tahun 1980 sampai 2006, yaitu selama 26 tahun. Kedua puluh enam data ini kemudian dibagi menjadi dua, yaitu data *training* dan data *testing*. Untuk data *training* diambil sebanyak 50% yaitu 11 data dari tahun genap dan untuk data *testing* sebanyak 50%, yaitu 10 data dari tahun genap. Dari hasil excel diperoleh nilai minimum sebesar 1,621,620, nilai maksimum 2,317,869 dan nilai rata-rata sebesar 2,045,741.

Tabel 2. Normalisasi Data Produksi Gula Nasional

t	x1	x2	x3	x4	x5	x6	Output
1	0.1000	0.3509	0.3899	0.5715	0.2635	0.3875	0.4222
2	0.3509	0.3899	0.5715	0.2635	0.3875	0.4222	0.4238
3	0.3899	0.5715	0.2635	0.3875	0.4222	0.4238	0.7168
4	0.5715	0.2635	0.3875	0.4222	0.4238	0.7168	0.5612
5	0.2635	0.3875	0.4222	0.4238	0.7168	0.5612	0.6757
6	0.3875	0.4222	0.4238	0.7168	0.5612	0.6757	0.6237
7	0.4222	0.4238	0.7168	0.5612	0.6757	0.6237	0.7545
8	0.4238	0.7168	0.5612	0.6757	0.6237	0.7545	0.8000
9	0.7168	0.5612	0.6757	0.6237	0.7545	0.8000	0.6938
10	0.5612	0.6757	0.6237	0.7545	0.8000	0.6938	0.5324
11	0.6757	0.6237	0.7545	0.8000	0.6938	0.5324	0.7166
12	0.6237	0.7545	0.8000	0.6938	0.5324	0.7166	0.6282
13	0.7545	0.8000	0.6938	0.5324	0.7166	0.6282	0.6238
14	0.8000	0.6938	0.5324	0.7166	0.6282	0.6238	0.1872
15	0.6938	0.5324	0.7166	0.6282	0.6238	0.1872	0.2946
16	0.5324	0.7166	0.6282	0.6238	0.1872	0.2946	0.4141
17	0.7166	0.6282	0.6238	0.1872	0.2946	0.4141	0.2345
18	0.6282	0.6238	0.1872	0.2946	0.4141	0.2345	0.4288
19	0.6238	0.1872	0.2946	0.4141	0.2345	0.4288	0.5300
20	0.1872	0.2946	0.4141	0.2345	0.4288	0.5300	0.5952
21	0.2946	0.4141	0.2345	0.4288	0.5300	0.5952	0.7475

Pengolahan data dilakukan dengan menggunakan Excell dan Matlab 7.0. Pemodelan ANN dilakukan dengan menggunakan 6 Input (X_t), 1 Hidden layer., dan 1 output. Percobaan dilakukan dengan mengubah-ubah nilai epochs, yaitu 10, 12, 25, 50, 75 dan 100.


t	x1	x2	x3	x4	x5	x6	Output
1	0.1000	0.3509	0.3899	0.5715	0.2635	0.3875	0.4222
3	0.3899	0.5715	0.2635	0.3875	0.4222	0.4238	0.7168
5	0.2635	0.3875	0.4222	0.4238	0.7168	0.5612	0.6757
7	0.4222	0.4238	0.7168	0.5612	0.6757	0.6237	0.7545
9	0.7168	0.5612	0.6757	0.6237	0.7545	0.8000	0.6938
11	0.6757	0.6237	0.7545	0.8000	0.6938	0.5324	0.7166
13	0.7545	0.8000	0.6938	0.5324	0.7166	0.6282	0.6238
15	0.6938	0.5324	0.7166	0.6282	0.6238	0.1872	0.2946
17	0.7166	0.6282	0.6238	0.1872	0.2946	0.4141	0.2345
19	0.6238	0.1872	0.2946	0.4141	0.2345	0.4288	0.5300
21	0.2946	0.4141	0.2345	0.4288	0.5300	0.5952	0.7475

Tabel 4. Data Testing (data Tahun Genap)

t	x1	x2	x3	x4	x5	x6	Output
2	0.3509	0.3899	0.5715	0.2635	0.3875	0.4222	0.4238
4	0.5715	0.2635	0.3875	0.4222	0.4238	0.7168	0.5612
6	0.3875	0.4222	0.4238	0.7168	0.5612	0.6757	0.6237
8	0.4238	0.7168	0.5612	0.6757	0.6237	0.7545	0.8000
10	0.5612	0.6757	0.6237	0.7545	0.8000	0.6938	0.5324
12	0.6237	0.7545	0.8000	0.6938	0.5324	0.7166	0.6282
14	0.8000	0.6938	0.5324	0.7166	0.6282	0.6238	0.1872
16	0.5324	0.7166	0.6282	0.6238	0.1872	0.2946	0.4141
18	0.6282	0.6238	0.1872	0.2946	0.4141	0.2345	0.4288
20	0.1872	0.2946	0.4141	0.2345	0.4288	0.5300	0.5952

(1). Run Matlab dengan “dm”.

```
for n=1:30 net = newff(p,t,9,{'traingdm'});
net.trainParam.lr = 0.05;
net.trainParam.mc = 0.9;
net = train(net,p,t);
y = sim(net,p);
end
```




Gambar 12. Hasil Training Dengan Epoch 39

```

(1). Run Matlab dengan "lm".
for n=1:30 net = newff(p,t,5,{},'trainlm');
net.trainParam.lr = 0.05; net.trainParam.goal = 0.00001;
net.trainParam.mc = 0.9;
net = train(net,p,t);
y = sim(net,dat)
end

```



Gambar 12. Hasil Training Dengan Epoch 100


Hasil training data untuk ketiga epochs tersebut disajikan pada Gambar 11 dan 12 diatas Kedua data hasil training memberikan nilai MSE berbeda, yaitu untuk epochs 39 nilai MSEnya adalah 0.0545203, untuk epochs 100 nilai MSEnya adalah 0.245965.

Tabel 5. Hasil Prediksi ANN

t	Prediksi
1	0.761303949
2	0.774287118
3	0.503069836
4	0.759582665
5	0.451600777
6	0.626756348
7	0.39007081
8	0.545521961
9	0.693340308
10	0.663334465
11	0.268161411
12	0.653191445
13	0.576963714
14	0.776242619
15	0.713970289
16	0.722442868
17	0.701440217
18	0.755683739
19	0.787630399
20	0.732635883
21	0.739234783
Rata-Rata	0.63015901
"Denomalisasi"	2,248,402

Setelah proses training, selanjutnya dilakukan tahapan simulasi. Pada tahapan simulasi ini akan diprediksi produksi gula untuk tahun 2007. Grafik hasil peramalan produksi gula gandum nasional menggunakan metode ANN disajikan pada Gambar 13.

Setelah dilakukan "denormalisasi", maka hasil peramalan dengan menggunakan matlab 7.0 diperoleh hasil produksi gula nasional untuk tahun 2007 diperkirakan mencapai 2,248,402 ton .



Gambar 13. Perbandingan Produksi dan peramalan produksi Gula Nasional

3.2. Kinerja Peramalan

Performansi masing-masing metode dinilai dengan membandingkan nilai Mean Square Error masing-masing metode tersebut. Hasil peramalan ketiga metode peramalan memberikan hasil performansi Mean Square Error (MSE) seperti terlihat pada Tabel 5.

Tabel 5. Nilai MSE untuk Peramalan Produksi Gula

Parameter	Pendekatan Artificial Neural Network
MSE	0.245965/1e-005
Gradient	0.497568/1e-010

Memperhatikan hasil perhitungan MSE pada Tabel 5 diatas, dengan menggunakan pendekatan ANN berdasarkan input dengan nilai epoch 100, memberikan nilai MSE yang sangat kecil mendekati 0. Hal ini menunjukkan bahwa pendekatan *Artificial Neural Network* memiliki akurasi yang sangat tinggi dalam melakukan prediksi terhadap suatu model sistem.

IV. KESIMPULAN DAN SARAN

KESIMPULAN

Peramalan dengan menggunakan pendekatan ANN ternyata memberikan nilai MSE yang sangat kecil mendekati 0. Hal ini berarti pendekatan Artificial Neural Network memiliki akurasi yang sangat tinggi dalam melakukan prediksi terhadap suatu model sistem. Keakuratan ANN dalam memprediksi suatu model karena proses peramalan mempertimbangkan faktor-faktor lain yang berpengaruh.

SARAN

Untuk lebih membuktikan keakuratan ANN dalam melakukan peramalan produksi gula nasional, sebaiknya data input untuk menggunakan data tahun sebelumnya saja (t-1), dengan memasukkan variabel pengaruh lainnya seperti luas lahan, kebijakan harga gula, harga gula domestik, konsumsi dan sebagainya.

DAFTAR PUSTAKA

- Anmi, L. 2004. Peramalan Impor Komoditas Pertanian Indonesia dari Negara ASEAN. Skripsi. Departemen Ilmu-ilmu Sosial Ekonomi Pertanian. Faperta IPB, Bogor.
- Badan Pusat Statistik. 1983-2003. Neraca Bahan Pangan. Badan Pusat Statistik, Jakarta
- Anonimous (1983-2003). Statistik Perdagangan Luar Negeri (Impor). Badan Pusat Statistik, Jakarta.
- Fausett, L. 1994. Fundamental of neural Network : Architecture. Algorithms and Applications. Prentice Hall Inc., New Jersey.

- Fu, L. 1994. Neural Network in Intelligent Computer Application. John Wiley & Sons, New York.
- Gustavo, D dan P. Obradovic. 1996. An Information – Theoretic Approach to Neural Computing, Springer, New York.
- Harfa, A. 1996. Analisis Faktor-faktor yang Mempengaruhi Perkembangan Permintaan Tepung Terigu di Indonesia. Skripsi. Jurusan Ilmu-ilmu Ekonomi Pertanian. Faperta IPB, Bogor.
- Klefors, D 1998. Aptfical neural network.
www.hjise/~deg6klda/Neural/network.htm (5 April 2005).
- Kusumadewi, R. 2004. Membangun Jaringan Syaraf Tiruan. Penerbit Fraha Ilmu, Yogyakarta.
- Makridakis, S., S.C. Wheelwright dan R.J. Hyndman. 1998. Forecasting : Method and Applications. John Wiley & Sons, New York.
- Mahardhika, P.Y. 2003. Analisis Faktor-faktor yang Mempengaruhi Perkembangan Permintaan Tepung Terigu di Indonesia. Skripsi. Jurusan Ilmu-ilmu Ekonomi Pertanian. Faperta IPB, Bogor.
- Nursusanto, A. 2003. Analisis Peluang Ekspor-Impor Jagung Indonesia : Pendekatan Permintaan. Skripsi. Departemen Ilmu-ilmu Sosial Ekonomi Pertanian. Faperta IPB, Bogor.
- Plummer, E.A. 2000. Time Series Forecating With Feed-Forward Neuron Network : Guidelines and Limitations [Thesis]. Department of Computer Sciene and The Braduate School of The University of Wyoming.
- Savitri, H. 2004. Analisis Peramalan Ekspor Komoditi Pertanian Indonesia ke Singapura, Malaysia dan Thailand. Skripsi. Departemen Ilmu-ilmu Sosial Ekonomi Pertanian. Faperta IPB, Bogor.
- Wei, W.W.S. 1990. Time Series Analysis : Univariate and Multivariate Methods. Addison-Wesley Publishing Company, California.
- Wilppu, E. 1999. Profitability Analysis in Distribution : A Neural Network Application Turku Center for Computer Selence. TUCS Technical Report No. 312. Turku School of Economics and Business Administration. <http://ueseer.com/cs>. Coty 2005]
- Dewan Gula Indonesia. 1999. Restrukturisasi Gula Indonesia April 1999. Bahan Diskusi Reformasi Gula Indonesia. Dewan Gula Indonesia, Jakarta
- Sudana W dkk. 2000. Dampak Deregulasi Industri Gula Terhadap Realokasi Sumberdaya, Produksi Pangan dan pendapatan petani. Laporan penelitian, Pusat penelitian sosial Ekonomi Pertanian , Bogor
- Susila W.R. dan A. Susmiadi. 2000. Analisa Dampak pembebasan Tarif Impor dan Perdagangan Bebas Terhadap Industri Gula. Laporan Penelitian, Asosiasi Penelitian Perkebunan Indonesia, Bogor
- Susila W.R. 2005. Pengembangan Industri Gula Indonesia ; Analisis Kebijakan Dan Keterpaduan Sistem Produksi . Disertasi S3 Institut pertanian Bogor.