

Penerapan *Bootstrap* pada *Neural Network* untuk Peramalan Produksi Minyak Mentah di Indonesia

Ida Bagus Oka Ari Adnyana, Dwiatmono A. W., Brodjol Sutijo S. U.

¹Mahasiswa, ²Dosen Pembimbing

Jurusan Statistika, Fakultas MIPA, Institut Teknologi Sepuluh Nopember (ITS)

Jalan Arief Rahman Hakim, Surabaya 60111

E-mail: dwiatmono@statistika.its.ac.id, sutijo_b@gmail.com

Abstrak—Sumberdaya alam yang tidak dapat diperbaharui adalah minyak bumi. Saat jumlah konsumsi mengalami peningkatan, tetapi tidak sejalan dengan peningkatan jumlah produksinya, maka terjadi kesenjangan antara konsumsi minyak mentah dan produksi minyak mentah. Produksi minyak mentah dapat diramalkan dengan menggunakan *time series forecasting* atau dengan metode ARIMA dimana model diasumsikan sebagai fungsi linier. Ketika model linier menghasilkan akurasi peramalan yang kecil, kemungkinan model nonlinier mampu menjelaskan. Salah satu model nonlinier untuk *time series forecasting* adalah *artificial neural network*. Pada penelitian ini dilakukan *resampling* terhadap unit input untuk melihat signifikan bobot *neural network* dengan melihat selang kepercayaan dari *bootstrap*. Perbandingan model antara model ARIMA, *neural network* dan *neural network* dengan *bootstrap* dalam peramalan produksi minyak mentah di Indonesia didapat bahwa model yang paling baik menggambarkan data adalah model *neural network*. Tetapi untuk jumlah input *neural network* paling sedikit dengan menggunakan hasil dari *bootstrap* yang sudah di hilangkan input yang tidak signifikan, yaitu hanya memasukkan dua unit input layer.

Kata Kunci—minyak mentah, *neural network*, *bootstrap*.

I. PENDAHULUAN

Sumberdaya alam yang tidak dapat diperbaharui salah satunya adalah minyak bumi. Permintaan masyarakat terhadap minyak sangat tinggi karena minyak sangat dibutuhkan oleh masyarakat dalam melakukan segala aktivitas (Yuza, 2010). Hal tersebut membuat kapasitas minyak mentah semakin lama semakin berkurang dari tahun ke tahun. Wakil Direktur Reform Miner Institute, Komaidi Notonegoro menyampaikan bahwa tahun 2012, cadangan minyak Indonesia terhitung hanya tersisa 4,3 miliar barel. Dalam 10-12 tahun lagi cadangan minyak Indonesia akan habis (Daniel, 2012). Kondisi dimana jumlah konsumsi terhadap minyak mentah dari tahun ketahun mengalami peningkatan, tetapi tidak diiringi dengan peningkatan jumlah produksinya. Sehingga terjadi kesenjangan antara konsumsi minyak mentah dan produksi minyak mentah yang cenderung semakin menurun.

Produksi minyak mentah dilakukan peramalan dengan menggunakan *time series forecasting*. Model yang digunakan untuk menjelaskan produksi minyak mentah di Indonesia pada tahun 1965 sampai 2011 yaitu menyederhanakan sistem

yang kompleks yang kemudian dijelaskan dengan persamaan matematika dan parameter yang sesuai dengan pengamatan dan ketidakpastian (Bates & Townley, 1988).

Metode yang sering digunakan dalam *time series forecasting* adalah *Autoregressive Integrated Moving Average* (ARIMA) dimana pada ARIMA, *Future Value* atau model persamaan matematisnya diasumsikan sebagai fungsi linier dari beberapa pengamatan di masa lalu dan *random error*. Beberapa studi menunjukkan bahwa ketika model linier menghasilkan tingkat akurasi peramalan yang relatif kecil dan kesalahan dalam prediksi yang besar, kemungkinan model nonlinier mampu menjelaskan dan meramalkan *time series* dengan lebih baik dibandingkan dengan model linier (Zhang, 2003). Salah satu metode yang dapat memodelkan model nonlinier untuk *time series forecasting* adalah *Artificial Neural Network* (ANN). *Artificial Neural Network* (ANN) atau disebut *Neural Networks* (NN) merupakan salah satu contoh metode nonlinier yang mempunyai bentuk fungsional fleksibel dan mengandung beberapa parameter yang tidak dapat diinterpretasikan seperti pada model parametrik (Suhartono, 2007).

Pengujian signifikansi dari bobot *neural network*, dilakukan dengan pendekatan yang didasari pada teknik *resampling* yaitu dengan menggunakan selang kepercayaan pada prosedur *bootstrap*. Metode *bootstrap* adalah prosedur komputasi yang menggunakan *resampling* intensif dengan mengambil sampel dari sampel yang ada. Hal ini dilakukan untuk mengurangi ketidakpastian dari parameter (Efron & Tibshirani, 1993). Selain itu, pendekatan yang dilakukan tidak memerlukan perhitungan yang kompleks, sehingga metode *bootstrap* memungkinkan diterapkan pada model *neural network* (Dybowski & Roberts, 2000).

Pada penelitian kali ini akan dilakukan *resampling* terhadap unit input kemudian dilihat signifikan bobot *neural network* dari unit input ke unit hidden dan dari unit hidden ke unit output dengan melihat selang kepercayaan dari *bootstrap* dalam kasus peramalan produksi minyak mentah di Indonesia. Ketika suatu bobot tidak signifikan pada suatu jalur maka jalur dari suatu unit ke unit lain tersebut dapat dihilangkan, sehingga dapat mengefisienkan perhitungan *neural network*. Pemodelan *neural network* yang digunakan dalam penelitian ini menggunakan jumlah hidden layer sesuai dengan yang dilakukan oleh peneliti sebelumnya yaitu sebanyak 9 neuron.

II. TINJAUAN PUSTAKA

Tinjauan yang digunakan terdiri atas kajian pustaka serta kajian teori terkait kasus dalam penelitian, yang ber-

tujuan agar dapat menyelesaikan masalah yang ada dalam penelitian.

A. Model ARIMA Box Jenkins

Suatu proses dikatakan non-stasioner jika proses tersebut mempunyai rata-rata dan ragam yang tidak konstan untuk sembarang waktu pengamatan. Model deret waktu yang nonstasioner dapat dikatakan sebagai proses *Auto Regressive Integrated Moving Average* ordo (p,d,q) atau disingkat ARIMA (p,d,q), dimana: p adalah order dari parameter autoregresif, d adalah besaran yang menyatakan berapa kali dilakukan differencing pada proses sehingga menjadi proses yang stasioner, dan q adalah order dari parameter moving average. Pada kenyataannya, tidak semua observasi deret waktu membentuk proses yang stasioner.

B. Backpropagation Neural Network

Backpropagation merupakan algoritma pembelajaran *neural network* dan biasanya digunakan oleh perceptron dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan neuron-neuron pada lapisan tersembunyinya (Kusumadewi, 2004). Pembelajaran dari jaringan backpropagation terdiri dari tiga tahapan yaitu menghitung arah maju dari pola input pembelajaran, menghitung eror backpropagation dan menentukan peubah bobot (Fausett, 1994).

Arsitektur dalam backpropagation disebut juga dengan multilayer *neural network*. Pada gambar berikut akan ditunjukkan *multilayer neural network* dengan satu layer dari hidden unit (Z unit), unit output (Y unit) dan juga memiliki unit bias.

Gambar 1 menunjukkan arsitektur backpropagation dengan 3 input, ditambah sebuah bias, dan sebuah layer tersembunyi yang terdiri dari p unit, ditambah sebuah bias, serta 1 buah unit keluaran. Dimana :

- $Y_{t-1}, Y_{t-2}, Y_{t-3}$: Unit input
- Y_t : Unit output
- Z_i : Unit hidden
- v_{ij} : bobot dari unit input menuju unit hidden
- w_i : bobot dari unit hidden menuju unit output


Fungsi aktivasi merupakan suatu fungsi yang digunakan untuk membandingkan antara hasil penjumlahan nilai-nilai semua bobot yang datang dengan suatu nilai ambang (*threshold*) tertentu pada setiap neuron (Kusumadewi, 2004). Dalam backpropagation, fungsi aktivasi yang dipakai harus memenuhi beberapa syarat yaitu :

1. Kontinu.
2. Terdiferensial dengan mudah.
3. Merupakan fungsi yang tidak turun.

Salah satu fungsi yang memenuhi ketiga syarat tersebut adalah fungsi sigmoid biner yang memiliki *range* (0,1).

$$f_1(x) = \frac{1}{1 + \exp(-x)}$$

dengan turunan $f_1'(x) = f(x)[1 - f(x)]$



Gambar 1 Arsitektur Backpropagation

Algoritma pembelajaran backpropagation dalam jaringan dengan satu layer tersembunyi dan dengan fungsi aktivasi logistik biner adalah sebagai berikut.

- Langkah 0* : Inisialisasi bobot dengan bilangan acak kecil.
- Langkah 1* : Dilakukan langkah 2-9, jika kondisi penghentian belum terpenuhi.
- Langkah 2* : Setiap pasang data pelatihan, dilakukan langkah 3-8.
- Fase I : Propagansi maju (*Feedforward*)
- Langkah 3* : Tiap unit input menerima sinyal dan meneruskannya ke unit tersembunyi di atasnya (unit hidden).
- Langkah 4* : Hitung semua sinyal input terboboti di unit hidden ($z_j, j=1,2,\dots,p$).

$$z_in_j = v_{j0} + \sum_{i=1}^3 x_i v_{ji}$$

gunakan fungsi aktivasi untuk menghitung sinyal output yang selanjutnya akan diteruskan menuju output unit.

$$z_j = f(z_in_j)$$

- Langkah 5* : Hitung semua sinyal input terboboti pada unit output y.

$$y_in = w_o + \sum_{j=1}^p z_j w_j$$

gunakan fungsi aktivasi untuk menghitung sinyal output.

$$y = f(y_in)$$

- Fase II : Propagansi mundur (*Backpropagation*)
- Langkah 6* : Hitung faktor δ unit output berdasarkan kesalahan setiap unit keluaran y.

$$\delta = (t - y) f'(y_in)$$

Hitung suku perubahan bobot w_{kj} dengan laju percepatan α .

$$\Delta w_j = \alpha \delta z_j$$

- Langkah 7* : Hitung faktor δ unit hidden berdasarkan kesalahan pada setiap unit z_j .

$$\delta_in_j = \sum_{k=1}^m \delta w_j$$

kalikan dengan turunan dari fungsi aktivasi untuk menghitung errornya

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

Hitung suku perubahan bobot v_{ji} .

$$\Delta v_{ji} = \alpha \delta_j x_i$$

Fase III : Perubahan bobot (*Update*)

Langkah 8 : Hitung semua perubahan bobot. Perubahan bobot garis yang menuju ke unit output :

$$w_{kj} \text{ baru} = w_{kj} \text{ lama} + \Delta w_{kj}$$

Perubahan bobot yang menuju unit hidden

$$v_{ji} \text{ baru} = v_{ji} \text{ lama} + \Delta v_{ji}$$

Langkah 9 : Test berhenti pada kondisi tertentu.

Dalam pengenalan pola, hanya langkah pada fase propagasi maju saja yang bisa dipakai untuk menentukan keluaran jaringan.

C. Selang Kepercayaan Bootstrap

Pada metode *resampling bootstrap* salah satu bentuk aplikasinya adalah mengestimasi selang kepercayaan dari parameter sampel. Pada kasus selang kepercayaan dan pengujian hipotesis pengambilan sampel bootstrap paling sedikit sebanyak 1000 replikasi *bootstrap*. (Chernick, 2007). Selang kepercayaan *bootstrap* disebut juga dengan metode persentil selang kepercayaan (Efron, 1982). menunjukkan untuk median, metode persentil memperlihatkan mendekati selang kepercayaan yang berdasarkan nonparametrik interval pada distribusi binomial.

Misalkan φ_0 merupakan parameter yang tidak diketahui dari fungsi distribusi F_0 . Maka $\varphi_0 = \varphi(F_0)$. Teori dari α - level persentil selang kepercayaan untuk φ_0 adalah interval $I_1 = (-\infty, \Psi + t_0)$, dimana t_0 didefinisikan sebagai berikut.

$$P(\varphi_0 \leq \Psi + t_0) = \alpha$$

atau dapat di definisikan sebagai berikut

$$f_1(F_0, F_1) = I\{\varphi(F_0) \leq \varphi(F_1) + t\} - \alpha$$

Maka t_0 merupakan nilai dari t sehingga $f_1(F_0, F_1) = 0$.

Dengan menganalogikan *bootstrap* persentil interval satu sisi untuk φ_0 sehingga didapatkan penyelesaian.

$$f_t(F_1, F_2) = 0$$

F_2 menggantikan F_1 . Jika \hat{t}_0 merupakan solusi dari persamaan, selang kepercayaan $(-\infty, \varphi(F_2) + \hat{t}_0)$ merupakan selang kepercayaan persentil *bootstrap* satu arah untuk φ .

Misalkan terdapat parameter θ dan sebuah estimasi θ_h untuk θ . Kemudian θ^* merupakan estimasi *bootstrap* nonparametric untuk θ berdasarkan pada sampel *bootstrap* dan S^* merupakan estimasi dari standar deviasi untuk θ_h berdasarkan pada sampel *bootstrap*. Sehingga didefinisikan

$$T^* = (\theta^* - \theta_h) / S^*$$

untuk setiap banyaknya sampel *bootstrap* misalkan B, estimasi *bootstrap* θ^* , sehingga dapat hubungan dengan T^* . Dapat dicari percentil dari T^* . Kemudian untuk aproksimasi dua sisi $100(1 - \alpha)\%$ selang kepercayaan untuk θ , didapat

interval $[\theta_h - t_{(1-\alpha)}^* S, \theta_h - t_{(\alpha)}^* S]$, dimana $t_{(1-\alpha)}^*$ merupakan $100(1 - \alpha)$ persentil dari T^* dan $t_{(\alpha)}^*$ merupakan 100α persentil dari T^* dan S adalah estimasi standar deviasi dari θ_h .

D. Pemilihan Model Terbaik

Kriteria pemilihan model terbaik, dapat dibagi menjadi dua yakni kriteria untuk *in sample* dan *out sample*. Untuk kriteria *in sample*, menggunakan AIC (*Akaike's Information Criterion*), sedangkan untuk *out sample* menggunakan RMSE (*Root of Mean Square Error*). RMSE digunakan untuk mendapatkan informasi dari keseluruhan standar deviasi yang muncul saat menunjukkan perbedaan hubungan atau model yang dimiliki. Adapun rumus perhitungan RMSE adalah sebagai berikut (Wei, 2006).

$$RMSE = \sqrt{\left(\frac{1}{n} \times \sum_{t=1}^n e_t^2\right)}$$

III. METODOLOGI PENELITIAN

Data yang digunakan dalam penelitian ini adalah data tahunan produksi minyak mentah selama periode tahun 1965 sampai tahun 2011. Data ini merupakan data sekunder yang diperoleh dari perusahaan British Petroleum (BP) yaitu perusahaan minyak Internasional. Produksi minyak mentah di Indonesia per tahun dalam satuan ribuan barel.


Berikut ini adalah langkah-langkah analisis yang dilakukan untuk mencapai tujuan dari penelitian.

1. Melihat time series plot dari data untuk melihat pola dari data.
2. Melihat plot ACF untuk mengetahui lag yang signifikan.
3. Melakukan pengujian non-linieritas pada data sampel.
4. Menentukan unit input layer *neural network*, kemudian banyak unit dalam hidden layer yang nanti akan disimulasikan.
5. Menentukan bobot pada arsitektur *neural network* dengan pendekatan *backpropagation*.
6. Mendapatkan arsitektur *neural network* (hidden layer dan iterasi) yang optimum.
7. Melihat stasioneritas dari sampel, sehingga dapat dilakukan prosedur *bootstrap* pada sampel, yaitu dengan mengambil sampel dari sampel yang ada dengan pengembalian.
8. Melakukan prosedur *bootstrap* terhadap unit input kemudian dilakukan pemodelan dengan *neural network*. hal ini dilakukan sebanyak 1000 kali sehingga didapat bobot sebanyak 1000 di tiap jalur.
9. Mencari selang kepercayaan dari masing-masing bobot dari input ke hidden layer dan dari hidden layer ke output.
10. Menentukan bobot yang signifikan dan yang tidak signifikan dengan melihat selang kepercayaan *bootstrap*, jika selang kepercayaan mengandung nilai 0, maka dapat diartikan tidak signifikan.
11. Melakukan pemodelan kembali dengan menggunakan *neural network* dengan menghilangkan bobot yang tidak signifikan.

IV. ANALISIS DAN PEMBAHASAN

A. Statistika Deskriptif

Rata-rata atau *mean* dari produksi minyak mentah dari tahun 1965 sampai 2011 di Indonesia adalah sebesar 1265,5 ribu barel pertahun. Standar deviasi dari data produksi minyak mentah di Indonesia yaitu sebesar 342,4 ini berarti penyebaran data dari tahun 1965 sampai 2011 sangar besar. Sehingga produksi minyak mentah di Indonesia memiliki variansi yang cukup besar. Produksi minyak mentah di Indonesia dari tahun 1965 sampai 2011 yang paling minimum adalah sebesar 474 ribu barel, yaitu pada tahun 1966. Kemudian untuk produksi minyak mentah paling maksimum yaitu sebesar 1685 ribu barel pada tahun 1977.



Gambar 2 Plot Time Series Produksi Minyak Mentah

B. Identifikasi Model

Model *neural network* yang akan dibangun terdiri dari unit input dan unit output.

Berdasarkan Gambar 2 dapat dilihat bahwa secara visual data produksi minyak mentah di Indonesia dari tahun 1965 sampai tahun 2011 menunjukkan fungsi nonlinier. Hal ini disebabkan karena jika ditarik garis lurus atau garis linier dari data, maka banyak pengamatan yang jauh dari garis linier, sehingga fungsi linier tidak terlalu baik dalam menjelaskan data produksi minyak mentah di Indonesia dari tahun 1965 sampai 2011. Secara visual terlihat bahwa data tidak stationer dalam mean, sehingga perlu dilakukan proses *differencing* orde 1. Kemudian setelah data sudah stationer maka model ARIMA yang didapat adalah ARIMA ([3],1,0).

Secara teori model ARIMA dari data produksi minyak mentah di Indonesia dari tahun 1965 sampai 2011 adalah

$$y_t = y_{t-1} + \varphi_3 y_{t-3} - \varphi_3 y_{t-4} + a_t$$

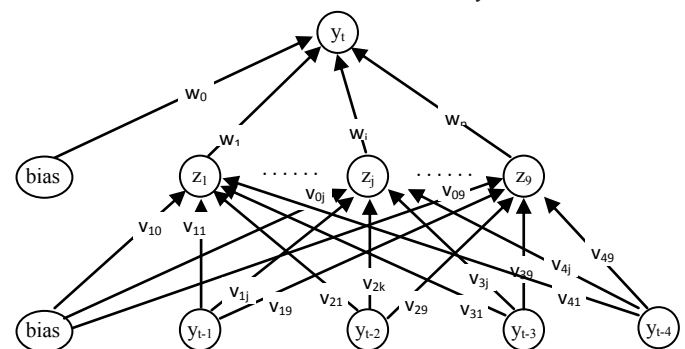
Ini berarti secara teori unit input model *neural network* pada data produksi minyak mentah di Indonesia adalah y_{t-1} , y_{t-3} , dan y_{t-4} . Sehingga pada simulasi *bootstrap neural network* digunakan unit input yaitu y_{t-1} , y_{t-2} , y_{t-3} , dan y_{t-4} .

C. Model Neural Network

Unit input dari model *neural network* telah didapat dari identifikasi model dengan melihat plot ACF dan PACF nya, kemudian telah ditentukan jumlah hidden layernya yaitu 9 layer dan maksimum iterasi dari model *neural network* yaitu sebanyak 10000 iterasi. Bobot awal dari tiap jalur sebanyak 55 jalur bobot pada model *neural network* ditentukan sebesar 0,5 serentak semua. Sehingga tidak terdapat faktor random dalam proses pembentukan model *neural network* yang diinginkan.

Arsitektur model *neural network* yang terbentuk dari proses pembelajaran *backpropagation* dalam pembentukan modelnya dengan iterasi yang memberikan residual yang konvergen dapat dilihat pada Gambar 4.2.

Bootstrap pada *neural network* dilakukan dengan meresampling unit input dan out pada data produksi minyak mentah di Indonesia. Resampling dilakukan dengan mengambil sampel dari sampel data berpasangan sebanyak jumlah pengamatan (n) dengan pengembalian lalu dilakukan pemodelan dengan *neural network* dengan input model



Gambar 3 Arsitektur Model Neural Network

Tabel 1
Selang Kepercayaan Bobot tidak Signifikan

Dari	Ke	Batas Bawah	Batas Atas
yt-2	z1	-1.56	1.37
yt-3	z1	-0.03	3.28
yt-2	z2	-1.68	1.42
yt-3	z2	-0.04	3.12
yt-2	z3	-2.33	1.27
yt-3	z3	-0.09	3.01
yt-2	z4	-1.69	1.31
yt-3	z4	-0.03	3.41
yt-2	z5	-1.75	1.49
yt-3	z5	-0.03	3.09
yt-2	z6	-1.76	1.5
yt-3	z6	-0.03	3.09
yt-2	z7	-2.18	1.3
yt-3	z7	-0.07	2.93
yt-2	z8	-1.82	1.29
yt-3	z8	-0.03	3.28
yt-2	z9	-2.01	1.63
yt-3	z9	-0.09	3.48

neural network yang sudah ditetapkan diawal yaitu unit input sebanyak 4 layer, unit hidden sebanyak 9 layer, maksimum iterasi sebanyak 10000 iterasi dan bobot awal dari tiap jalur adalah 0,5.

Pengujian terhadap bobot *neural network* pada penelitian ini dilakukan dengan melihat selang kepercayaan dari bobot *neural network*. Pada penelitian kali ini digunakan

tingkat kesalahan (α) dalam membangun selang kepercayaan *bootstrap* sebesar 10%. Bobot yang tidak signifikan dapat dilihat dari selang kepercayaan sebagai berikut.

Bobot yang tidak signifikan ini akan dihilangkan dari model. Kemudian digunakan bobot yang signifikan untuk mencari nilai prediksi dari data produksi minyak mentah di Indonesia dari tahun 1965 sampai 2011. Bentuk model *neural network* pada data produksi minyak mentah di Indonesia setelah dilakukan eliminasi terhadap bobot yang tidak signifikan adalah sebagai berikut.

Berdasarkan hasil selang kepercayaan *bootstrap* dengan tingkat kesalahan (α) sebesar 10% didapat hasil yaitu 26 bobot *neural network* tidak signifikan secara statistik, yang artinya selang kepercayaan *bootstrap* dari 26 bobot yang tidak signifikan melewati nilai 0. Sehingga ada kemungkinan kalau didalam proses membangun model, nilai 0 akan muncul sehingga menyebabkan model *neural network* tidak signifikan pada jalur tertentu.

Neuron yang tidak memiliki pengaruh sama sekali dengan neuron lain adalah neuron input bias yang tidak signifikan terhadap hidden layer manapun, kemudian neuron pada unit input y_{t-2} dan neuron pada unit input y_{t-3} yang tidak signifikan terhadap hidden layer manapun, sehingga dihilangkan.

D. Perbandingan Model Bootstrap Neural Network

Perbandingan model *bootstrap neural network* yang sudah didapat selanjutnya dibandingkan dengan model *neural network* yang biasa dan model ARIMA dengan melakukan perbandingan terhadap nilai RMSE dan nilai P pada uji normal dengan metode Kolmogorov-smirnov.


Berdasarkan Tabel 2 dapat dilihat bahwa secara statistik, nilai RMSE dari *artificial neural network* lebih kecil dibandingkan nilai RMSE dari *bootstrap neural network* yang telah dihilangkan bobot yang tidak signifikan secara statistik serta lebih baik dibandingkan model ARIMA ([3],1,0). Tetapi untuk jumlah input pada saat pemodelan paling sedikit adalah dengan menggunakan *neural network* yang telah didapatkan input yang signifikan dari *bootstrap*. Kemudian dari nilai P Kolmogorov-smirnov uji normal memperlihatkan bahwa ketiga residual metode ARIMA, *artificial neural network* dan *bootstrap neural network* sama-sama tidak normal.

. KESIMPULAN DAN SARAN

A. Kesimpulan

Berdasarkan hasil analisis dan pembahasan pada bab sebelum, maka diperoleh kesimpulan dari penelitian ini adalah sebagai berikut.

1. Model *neural network* dalam peramalan produksi minyak mentah di Indonesia dari tahun 1965 sampai tahun 2011 dengan unit input yaitu y_{t-1} , y_{t-2} , y_{t-3} , dan y_{t-4} , hidden layer sebanyak 9 neuron. Memiliki bobot dari tiap jalur pada unit input ke hidden dan dari hidden ke output sebanyak 55 bobot. Menghasilkan nilai MSE sebesar 0.231698 lebih kecil dibandingkan dengan model ARIMA ([3],1,0) dengan MSE sebesar 0.277834. Residual dari model *neural network* yang dihasilkan tidak mengikuti distribusi normal, hal ini berdasarkan



Gambar 4 Arsitektur Model *Neural Network* yang telah di Eliminasi
Tabel 2

Perbandingan Residual Model

Metode	RMSE	Nilai P Kolmogorov-Smirnov
ARIMA ([3],1,0)	95,1144	0.0003893
Artificial Neural Network	79,112	0.0001365
Bootstrap Neural Network	200,069	0.001157

2. Perbandingan model antara model ARIMA, *neural network* dan *neural network* dengan *bootstrap* dalam peramalan produksi minyak mentah di Indonesia didapat bahwa model yang paling baik menggambarkan data berdasarkan nilai MSE adalah model *neural network* sederhana, karena nilai model ini menghasilkan MSE paling kecil. Tetapi untuk jumlah input *neural network* paling sedikit dengan menggunakan hasil dari *bootstrap* yang sudah di hilangkan input dengan bobot yang tidak signifikan, yaitu hanya memasukkan dua unit input, y_{t-1} dan y_{t-4} . Sedangkan untuk model ARIMA menghasilkan nilai MSE yang tidak lebih bagus dari nilai MSE dari model *neural network* sederhana.

B. Saran

Pada penelitian ini, masih terdapat kekurangan dan permasalahan. Sehingga terdapat beberapa saran yang direkomendasikan untuk penelitian selanjutnya. Pada bagian analisis, diperlukan sumber pendukung dari penelitian sebelumnya untuk mendukung hasil dalam penelitian, serta para peneliti tidak selalu berpikir bahwa model yang rumit selalu menghasilkan hasil peramalan yang lebih baik dibandingkan dengan model yang sederhana.

DAFTAR PUSTAKA

- [1] Abrahart, R.J., 2003. Neural network rainfall-runoff forecasting based on continuous resampling. *Journal of Hydroinformatics* 5 (1), 51-61.
- [2] Bates, B.C. & Townley, L.R., 1988. Nonlinear, discrete flood event models: 3. Analysis of prediction uncertainty. *Journal of Hydrology* 99, 91-101.
- [3] Box, G.E.P. & Jenkins, G.M. 1976. *Time series Analysis Forecasting and Control Revised Edition*. Oakland: Holden-Day, Inc

- [4] Cryer, J.D. 1986. Time Series Analysis. PWS-KENT Publishing Company, Boston.
- [5] Daniel, Wahyu. 2012. Detik Finance (<http://finance.detik.com/read/2012/04/05/124625/1885898/1034/gawat-cadangan-minyak-ri-habis-12-tahun-lagi>) di akses pada tanggal 14 Januari 2013
- [6] Dybowski, R., Roberts, S.J., 2000. Confidence and prediction intervals for feed forward neural networks. In: Dybowski, R., Gant, V. (Eds.), *Clinical Applications of Artificial Neural Networks*. Cambridge University Press.
- [7] Efron, B. 1979. Bootstrap methods: another look at the jackknife. *Ann. Statist.* 7, 1-26.
- [8] Efron, B. 1982. *The Jackknife, the Bootstrap, and Other Resampling Plans*. SIAM, Philadelphia.
- [9] Efron, B., Tibshirani, R.J., 1993. *An Introduction to the Bootstrap*. Chapman and Hall, London, UK.
- [10] Fausett, Lauren. 1994. *Fundamental of Neural Network: Architectures, algorithm and applications*, Prantice Halt.
- [11] Hanke, J.E., Reitsch, A.G. dan Wichern, D.W. 2003. *Peramalan Bisnis*. Edisi Ketujuh. Alih Bahasa: Devy Anantanur. PT. Prenhallindo. Jakarta.
- [12] Kusumadewi, S. (2004). *Membangun Jaringan Syaraf Tiruan (menggunakan MATLAB & Excel Link)*. Yogyakarta: Graha ilmu.
- [13] Makridakis, S., Wheelwright, S.C., dan McGee, V. Alih bahasa Ir. Hari Suminto. 1999. *Metode dan Aplikasi Peramalan*. Edisi kedua. Binarupa Aksara, Jakarta.
- [14] Suhartono. 2007. *FeedForward Neural Network untuk Pemodelan Runtun Waktu*. Disertasi, Jurusan Matematika, Universitas Gadjah Mada
- [15] Chernick, Michael R., 2007. *Bootstrap Methods A Guide for Practitioners and Researchers (Second Edition)*, Wiley: Newtown, Pennsylvania.
- [16] Teräsvitra, T., Tjostheim, D. and Granger, C.W.J., 1994. "Aspect Modelling Nonlinear Time Series, in RF. Engle and D.L. McFadden", eds. *Handbook of Econometrics*, 4 Chapter 48, 2919-2957. Elsevier Science B.V.
- [17] Wei, W.W., 2006. *Time Series Analysis : Univariate and Multivariate Methods (2nd ed.)*, Addison Wesley.
- [18] Yuza, Mirna. 2010. *Perbandingan Metode Arima Dan Double Exponential Dalam Meramalkan Produksi Minyak Mentah Di Indonesia Tahun 2010*. Tugas Akhir, Jurusan Matematika Prodi Statistika, Universitas Negeri Padang
- [19] Yuza, Mirna. 2013. *Pemodelan Neural Network untuk Peramalan Produksi Minyak Mentah di Indonesia*. Tugas Akhir, Jurusan Statistika Prodi S1 Statistika, ITS
- [20] Zhang, G.P., 2003. A Combined ARIMA and Neural Network Approach for Time Series Forecasting, dalam *Neural Networks in Business Forecasting* (pp. 213-225). New York City: IGI Global