

**PEMODELAN FUNGSI TRANSFER DAN *BACKPROPAGATION NEURAL NETWORK* UNTUK PERAMALAN HARGA EMAS
(Studi Kasus Harga Emas Bulan Juli 2007 sampai Februari 2019)**

Silvia Nur Rinjani¹, Abdul Hoyyi², Suparti³

^{1,2,3} Departemen Statistika FSM Universitas Diponegoro
hoyyi.stat@gmail.com

ABSTRACT

The prestige of investment is increasingly rising as the people educates in managing finances. Gold is an alternative that most people tend to choose to invest. One of the important knowledge in gold investing is to predict the price in the future with factors that influence the price of gold. Therefore, in this research we made a model of gold prices based on crude oil prices. One method to forecast gold prices based on crude oil prices is the transfer function and backpropagation neural network. The results of transfer function model will be used as input for the backpropagation neural network method. The purpose of this research is to get the right forecasting method through the transfer function and backpropagation neural network model that can be used to predict gold prices. The results showed that the transfer function model with $b = 0$, $r = [2]$, $s = 0$ and the ARMA noise model (0, [6]) is the best model to forecast the price of gold with the MAPE value of data out sample as 3,3507%.

Keywords : Gold Price, Crude Oil Prices, Transfer Function, Backpropagation Neural Network, Forecasting

1. PENDAHULUAN

Pamor investasi semakin menanjak seiring teredukasinya masyarakat mengelola keuangan. Investasi merupakan penanaman modal untuk satu atau lebih aktiva dalam jangka waktu yang lama atau singkat dengan harapan akan memperoleh keuntungan di masa yang akan datang. Emas merupakan alternatif yang cenderung dipilih kebanyakan orang untuk berinvestasi.

Salah satu pengetahuan penting dalam berinvestasi emas adalah memprediksi harganya di masa yang akan datang melalui pemodelan harga emas masa lampau dengan faktor-faktor yang mempengaruhi harga emas. Menurut Kusnandar (2010), salah satu faktor yang dapat mempengaruhi harga emas adalah harga minyak mentah. Hal ini dikarenakan saat harga minyak mentah dunia mengalami kenaikan, harga emas di pasar dunia pun ikut terdongkrak. Model statistik yang digunakan untuk memodelkan harga emas berdasarkan harga minyak mentah adalah model fungsi transfer.

Metode peramalan sangat banyak dan seringkali memerlukan asumsi–asumsi yang harus dipenuhi, namun terdapat juga model yang tidak memerlukan asumsi salah satunya *Neural Network* (NN). Model NN dibedakan menjadi 2 yaitu *Feedforward Neural Network* (FFNN) dan *Recurrent Neural Network* (RNN). Yang termasuk kelas FFNN di antaranya adalah *Backpropagation Neural Network* yang merupakan model sederhana jika digunakan untuk menyelesaikan masalah data *time series*.

Berdasarkan latar belakang tersebut pada penelitian ini dilakukan pemodelan Fungsi Transfer dan *Backpropagation Neural Network* untuk peramalan harga emas dengan variabel *input* harga minyak mentah periode bulan Juli 2007 sampai Februari 2019.

2. TINJAUAN PUSTAKA

2.1 Konsep Dasar Runtun Waktu

Data runtun waktu diartikan sebagai rangkaian pengamatan yang berurutan terhadap suatu variabel berdasarkan waktu dengan interval waktu yang tetap (Wei, 2006). Jika data runtun waktu mempunyai struktur probabilistik dan dapat diketahui pola pergerakannya dari waktu ke waktu maka dapat dianalisis untuk menentukan kondisi pada saat ini dan kondisi pada periode mendatang (peramalan).

2.2 Stasioneritas Data

2.2.1 Stasioneritas dalam Mean

Menurut Tsay (2010) pengujian secara formal untuk melihat stasioneritas dalam data runtun waktu dapat dilakukan melalui uji *Augmented Dickey-Fuller* (ADF). Untuk mengetahui keberadaan akar unit yang menunjukkan data tidak stasioner dalam suatu model proses *Autoregressive* (AR) orde p maka digunakan persamaan berikut:

$$Z_t = \beta Z_{t-1} + \sum_{i=1}^{p-1} \phi_i \Delta Z_{t-i} + e_t$$

Berikut ini adalah tahap-tahap untuk uji ADF:

Hipotesis:

$H_0: \beta = 1$ (terdapat akar unit atau data tidak stasioner)

$H_1: \beta < 1$ (tidak terdapat akar unit atau data stasioner)

Statistik uji:

$$ADF_{hitung} = \frac{(\hat{\beta}-1)}{\text{std}(\hat{\beta})}$$

H_0 ditolak jika nilai $ADF_{hitung} <$ nilai tabel *critical value* ADF 5% atau prob. $ADF < \alpha$.

2.2.2 Stasioneritas dalam Varian

Data *time series* yang tidak stasioner dalam varian perlu dilakukan transformasi untuk menstasionerkannya. Transformasi yang biasa dilakukan adalah transformasi *Box-Cox*.

Tabel 1. Transformasi *Box-Cox* untuk beberapa nilai λ

λ (<i>lambda</i>)	-1	-0.5	0	0.5	1
Transformasi	$1/Z_t$	$1/\sqrt{Z_t}$	$\text{Ln}(Z_t)$	$\sqrt{Z_t}$	Z_t

2.3 Autocorrelation Function dan Partial Autocorrelation Function

Autocorrelation function (ACF) merupakan statistik kunci dalam analisis data *time series*, yaitu menyatakan ukuran korelasi (hubungan linear) *time series* itu dengan dirinya sendiri dengan *lag* $0, 1, 2, \dots, k$ yang didefinisikan sebagai berikut:

$$r_k = \hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2}$$

Partial autocorrelation function (PACF) menunjukkan besarnya korelasi antara pengamatan ke- t yaitu Z_t dengan pengamatan waktu-waktu sebelumnya yaitu $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k}$ yang didefinisikan sebagai berikut:

$$\phi_{kk} = \frac{|\mathbf{P}_k^*|}{|\mathbf{P}_k|}$$

dengan

$$\mathbf{P}_k \text{ adalah matriks autokorelasi } k \times k, \text{ yaitu } \begin{bmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & 1 \end{bmatrix}$$

P_k^* adalah matriks P_k dengan kolom terakhir diganti dengan $\begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_k \end{bmatrix}$

2.4 Model Runtun Waktu

Model Autoregressive (AR)

Bentuk umum model AR dengan orde p atau disingkat AR(p) adalah sebagai berikut:

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \dots + \phi_p \dot{Z}_{t-p} + a_t$$

Model Moving Average (MA)

Bentuk umum dari model MA orde q adalah sebagai berikut:

$$\dot{Z}_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}$$

Model Autoregressive Moving Average atau ARMA

Model *autoregressive moving average* merupakan campuran dari AR orde p dan MA orde q , dapat ditulis ARMA (p,q) dengan bentuk umumnya adalah sebagai berikut:

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \dots + \phi_p \dot{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}$$

Model Autoregressive Integrated Moving Average atau ARIMA

Model *autoregressive integrated moving average* merupakan model *time series* yang non stasioner. Oleh karena itu, diperlukan pembedaan (*differencing*) agar dapat menjadi stasioner. Model ARIMA(p,d,q) merupakan campuran antara AR orde p dan MA orde q dengan *differencing* orde d . Bentuk umum dari model ini adalah sebagai berikut:

$$\phi_p(B)(1-B)^d \dot{Z}_t = \theta_q(B)a_t$$

Model Subset ARIMA

Menurut Tarno (2013) himpunan bagian model *time series* yang lain adalah model subset ARIMA. Model subset ARIMA merupakan bagian dari model ARIMA tergeneralisasi, sehingga tidak dapat dinyatakan dalam bentuk umum. Sebagai contoh subset ARIMA([1,5],0,[1,12]) dapat ditulis sebagai berikut:

$$(1 - \phi_1 B - \phi_5 B^5)Z_t = (1 - \theta_1 B - \theta_{12} B^{12})a_t$$

2.5 Asumsi Pemodelan ARIMA

Adapun asumsi model ARIMA adalah residual model berdistribusi normal, tidak terdapat korelasi antar residual di semua lag (*white noise*) dan memiliki varian residual model yang konstan (Wei, 2006).

2.6 Pemodelan Fungsi Transfer

Fungsi transfer merupakan gabungan dari model ARIMA univariat dan analisis regresi berganda sehingga menjadi suatu model yang mencampurkan pendekatan deret berkala dengan pendekatan kausal.

2.6.1 Model Fungsi Transfer

Bentuk umum dari model fungsi transfer dengan *input* tunggal (X_t) dan *output* tunggal (Y_t) dalam Makridakis *et al.* (1999) adalah sebagai berikut:

$$y_t = \frac{\omega_s(B)}{\delta_r(B)} x_{t-b} + \frac{\theta_q(B)}{\phi_p(B)} a_t$$

dengan:

$$\omega_s(B) = \omega_0 - \omega_1 B - \omega_2 B^2 - \dots - \omega_s B^s,$$

$$\delta_r(B) = 1 - \delta_1 B - \delta_2 B^2 - \dots - \delta_r B^r,$$

$$\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q,$$

$$\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p,$$

y_t menyatakan deret *output* yang telah stasioner
 x_t menyatakan deret *input* yang telah stasioner
 a_t menyatakan nilai gangguan random yang diasumsikan berdistribusi identik dan independen
 r, s, p, q dan b menyatakan konstanta (orde dalam fungsi transfer)

2.6.2 Identifikasi Model Fungsi Transfer

Menurut Makridakis *et al.* (1999) tahap identifikasi model fungsi transfer adalah sebagai berikut:

1. Mempersiapkan deret *input* dan *output*

Pada tahap ini dilakukan uji stasionertas pada deret *input* dan *output*.

2. Pemutihan (*Prewhitening*) deret *input*

Tahap pemutihan deret *input* merupakan proses transformasi deret yang berkorelasi menuju sifat *white noise* yang tidak berkorelasi.

Persamaan deret *input* yang telah mengalami pemutihan adalah:

$$\beta_t = \frac{\phi_p(B)}{\theta_q(B)} x_t$$

3. Pemutihan (*Prewhitening*) deret *output*

Agar dapat mempertahankan integritas hubungan fungsional dari fungsi transfer maka harus dilakukan juga transformasi untuk deret *output*.

$$\gamma_t = \frac{\phi_p(B)}{\theta_q(B)} y_t$$

4. Perhitungan korelasi silang (*cross correlation*) dan autokorelasi untuk deret *input* dan *output* yang sudah diputihkan

$$r_{xy}(k) = \hat{\rho}_{xy}(k) = \frac{c_{xy}(k)}{\sqrt{c_{xx}(0)c_{yy}(0)}} = \frac{c_{xy}(k)}{s_x s_y}$$

5. Penaksiran langsung bobot respon impuls

$$v_k = r_{\beta\gamma}(k) \frac{s_\gamma}{s_\beta} \quad \text{untuk } k = 1, 2, \dots$$

6. Penetapan (b,r,s) untuk model fungsi transfer

Tiga parameter kunci di dalam model fungsi transfer adalah (b,r,s) dimana b menunjukkan keterlambatan pengaruh deret *input*, r menunjukkan derajat fungsi $\delta(B)$ yang menunjukkan seberapa lama deret *output* waktu ke-t dipengaruhi oleh deret *output* pada waktu t-k dan s menunjukkan derajat fungsi $\omega(B)$ yang menunjukkan seberapa lama deret *output* dipengaruhi oleh deret *input*.

7. Penentuan model deret *noise*

$$N_t = Y_t - v_0 X_t - v_1 X_{t-1} - v_2 X_{t-2} - \dots - v_g X_{t-g}$$

di mana g adalah nilai praktis yang dipilih peramal.

Model ini mengikuti model ARIMA($p_n, 0, q_n$) tertentu dan dapat diidentifikasi dengan menyelidiki plot ACF dan PACF.

2.6.3 Estimasi Parameter Model Fungsi Transfer

Setelah melakukan identifikasi model fungsi transfer, maka dilanjutkan dengan mengestimasi parameter-parameternya, yaitu $\omega = (\omega_0, \omega_1, \dots, \omega_s)'$, $\delta = (\delta_1, \dots, \delta_r)'$,

$\phi = (\phi_1, \dots, \phi_p)'$, $\theta = (\theta_1, \dots, \theta_q)'$ dan σ_a^2 . Menurut Wei (2006), persamaan fungsi transfer ditulis sebagai berikut:

$$y_t = \frac{\omega_s(B)}{\delta_r(B)} x_{t-b} + \frac{\theta_q(B)}{\phi_p(B)} a_t$$

Diasumsikan bahwa a_t adalah deret *white noise* yang berdistribusi normal $N(0, \sigma^2)$ sehingga fungsi likelihood bersyarat dari a_t yaitu:

$$L(\delta, \omega, \phi, \theta, \sigma_a^2 | b, x, y, x_0, y_0, a_0) = (2\pi\sigma_a^2)^{-n/2} \exp \left[-\frac{1}{2\sigma_a^2} \sum_{t=1}^n a_t^2 \right]$$

$$\log(L) = -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log(\sigma_a^2) - \frac{1}{2\sigma_a^2} \sum_{t=1}^n a_t^2$$

dengan x_0, y_0, a_0 adalah beberapa nilai awal untuk menghitung a_t .

Maka estimasi parameter fungsi transfer didapatkan dengan meminimalkan fungsi jumlah kuadrat bersyarat (*Conditional Least Square*) berikut:

$$S(\delta, \omega, \phi, \theta | b) = \sum_{t=t_0}^n a_t^2$$

di mana $t_0 = \max\{p + r + 1, b + p + s + 1\}$

Tidak ada rumus jadi (*closed form*) untuk estimasi parameter fungsi transfer $\delta_i, \omega_j, \phi_k$ dan θ_l . Sehingga harus dilakukan dengan proses iteratif. Perhitungan iteratif dilakukan menggunakan metode *Newton Raphson*.

2.6.4 Diagnostik Model Fungsi Transfer

1. Pengujian korelasi silang

Bertujuan untuk memeriksa apakah residual (a_t) model fungsi transfer dan deret *input* yang telah diputihkan (β_t) saling independen. Uji korelasi silang dapat menggunakan uji *Ljung-Box* dengan statistik uji: $Q_0 = m(m+2) \sum_{j=0}^K (m-j)^{-1} \hat{\rho}_{\beta a}^2(j)$

dengan m merupakan banyaknya residual (a_t), K merupakan jumlah *lag* maksimum dan $\hat{\rho}_{\beta a}(j)$ merupakan korelasi silang antara residual (a_t) model fungsi transfer dengan *input* yang telah diputihkan (β_t) pada lag ke- j . H_0 ditolak jika nilai $Q_0 > \chi_{\alpha; K-r-s}^2$ atau $p_{value} < \alpha$.

2. Pengujian autokorelasi

Bertujuan untuk melihat apakah terdapat korelasi antar residual (a_t) model fungsi transfer. Pengujian dilakukan melalui uji *Ljung-Box* dengan statistik uji:

$$Q_1 = m(m+2) \sum_{j=1}^K (m-j)^{-1} \hat{\rho}_a^2(j)$$

dengan m merupakan banyaknya residual (a_t) dan $\hat{\rho}_a^2(j)$ adalah autokorelasi residual pada lag ke- j . H_0 ditolak jika nilai $Q_1 > \chi_{\alpha; K-p-q}^2$ atau $p_{value} < \alpha$.

2.6.5 Pemilihan Model Fungsi Transfer Terbaik

Pemilihan model fungsi transfer yang terbaik dilakukan jika terdapat dua atau lebih model yang terbentuk yang nantinya model yang terpilih layak digunakann dalam peramalan. Salah satu pendekatan yang digunakan dalam pemilihan model yaitu menggunakan *Akaike's Information Criteria* (AIC).

$$AIC(M) = n \ln \sigma_{\hat{\epsilon}}^2 + 2M$$

dengan M adalah jumlah parameter dan n merupakan banyaknya pengamatan. Model terbaik merupakan model yang memiliki nilai AIC terkecil (Wei, 2006).

2.7 Model Feedforward Neural Network dengan Algoritma Backpropagation

Arsitektur model FFNN terdiri atas satu lapis *input*, satu atau lebih lapis tersembunyi, dan satu lapis *output*. Dalam model ini, perhitungan respon atau *output* dilakukan dengan memproses *input* mengalir dari satu lapis maju ke lapis berikutnya secara berurutan.

Algoritma *Backpropagation* disebut sebagai propagasi balik karena ketika jaringan diberikan pola masukan sebagai pola pelatihan maka pola tersebut menuju ke unit-unit

pada lapisan tersembunyi untuk diteruskan ke unit-unit lapisan keluaran. Selanjutnya, unit-unit lapisan keluaran memberikan tanggapan yang disebut sebagai keluaran jaringan. Saat keluaran jaringan tidak sama dengan keluaran yang diharapkan maka keluaran akan menyebar mundur (*backward*) pada lapisan tersembunyi diteruskan ke unit pada lapisan masukan. Oleh karenanya mekanisme pelatihan tersebut dinamakan *backpropagation*.

Pelatihan *algoritma backpropagation* meliputi 3 fase. Fase pertama adalah fase maju. Pola masukan dihitung maju mulai dari layar masukan hingga layar keluaran menggunakan fungsi aktivasi yang ditentukan. Fase kedua adalah fase mundur. Selisih antara keluaran jaringan dengan target yang diinginkan merupakan kesalahan yang terjadi. Kesalahan tersebut dipropagasikan mundur, dimulai dari garis yang berhubungan langsung dengan unit-unit di layar keluaran. Fase ketiga adalah modifikasi bobot untuk menurunkan kesalahan yang terjadi (Siang, 2005).

Dalam *backpropagation*, fungsi aktivasi yang dipakai harus memenuhi beberapa syarat yaitu: kontinu, terdiferensial dengan mudah dan merupakan fungsi yang tidak turun. Fungsi aktivasi yang memenuhi karakteristik tersebut yaitu fungsi *sigmoid* biner, *sigmoid bipolar* dan *linear*.

Model *feedforward neural network* algoritma *backpropagation* secara sistematis dapat dituliskan sebagai berikut:

$$y_k = f_o(\sum_{j=1}^p w_{kj} f_h[v_{j0} + \sum_{i=1}^n x_i v_{ji}] + w_{k0})$$

dengan

w_{k0} : bobot yang menghubungkan antara bias dan *neuron* ke-k pada *output*

w_{kj} : bobot yang menghubungkan antara *neuron* ke-j pada *hidden layer* dan *neuron* ke-k pada *output*

v_{j0} : bobot yang menghubungkan antara bias dan *neuron* ke-j pada *hidden layer*

v_{ji} : bobot yang menghubungkan antara *neuron* ke-i pada *input* dan *neuron* ke-j pada *hidden layer*

f_o : merupakan fungsi aktivasi yang digunakan pada *output*

f_h : merupakan fungsi aktivasi yang digunakan pada *hidden layer*

2.8 Pemilihan Model Terbaik

Pemilihan model terbaik didasarkan pada nilai residual untuk nilai ramalan *out sample*. Semakin kecil nilai kriteria pemilihan model maka semakin besar kemungkinan suatu model tersebut dipilih. Model dikatakan baik jika model tersebut memiliki nilai MAPE yang kecil (Wei, 2006). Berikut rumus MAPE (*Mean Absolute Percentage Error*) (Makridakis *et al.*, 1999):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{z_i - \hat{z}_i}{z_i} \right| \times 100\%$$

Menurut Halimi *et al.* (2013) dalam Saputri (2017) kriteria MAPE adalah sebagai berikut:

1. MAPE < 10% : kemampuan peramalan sangat baik
2. 10% ≤ MAPE < 20% : kemampuan peramalan baik
3. 20% ≤ MAPE < 50% : kemampuan peramalan cukup
4. MAPE ≥ 50% : kemampuan peramalan buruk

2.9 Investasi Emas

Sejak dulu emas telah dikenal sebagai alat investasi dan alat yang baik untuk melindungi nilai/aset kekayaan ketika masa-masa sulit. Hal ini karena emas adalah benda yang nilainya sangat stabil. Pada kenyataan sehari-hari, harga emas tidak hanya bergantung kepada situasi permintaan dan penawaran. Harga emas juga dipengaruhi oleh situasi

perekonomian secara keseluruhan. Faktor-faktor yang mempengaruhi harga emas sebagai berikut (Kusnandar, 2010):

1. Kenaikan inflasi melebihi yang diperkirakan
2. Terjadi kepanikan finansial
3. Harga minyak mengalami kenaikan
4. Naiknya permintaan emas
5. Situs politik dunia
6. Suku Bunga

2.10 Harga Minyak Mentah Dunia

Crude oil atau minyak mentah merupakan minyak bumi yang belum diolah dan belum dapat digunakan. Harga minyak mentah dunia diukur berdasarkan *spot price* dari berbagai jenis minyak mentah, yang paling sering adalah *West Texas Intermediate* (WTI) dan Brent. WTI merupakan minyak mentah yang berkualitas tinggi karena wujudnya yang “*light-weight*” serta memiliki kandungan sulfur yang rendah. WTI memiliki kandungan sulfur sekitar 0,24% (Hecht, 2019). Untuk alasan inilah, WTI sering disebut minyak mentah yang ringan dan manis. Kandungan ini sangat bagus untuk dijadikan sebagai bahan bakar kendaraan, inilah mengapa WTI dijadikan sebagai acuan harga minyak mentah di Amerika.

3. METODELOGI PENELITIAN

3.1 Jenis dan Sumber Data

Data yang digunakan dalam penelitian ini merupakan data sekunder yang terdiri dari data harga emas dan harga minyak mentah yang diperoleh dari situs Investing.com (www.investing.com). Data tersebut berupa data bulanan periode bulan Juli 2007 sampai Februari 2019.

3.2 Variabel Penelitian

Dalam penelitian ini, ada dua jenis variabel yang digunakan, yaitu variabel *output* (Y) dan variabel *input* (X). Variabel *output* dalam penelitian ini adalah harga emas yang standar perhitungannya menggunakan *London Fix Gold* sedangkan variabel inputnya adalah harga minyak mentah yang diukur berdasarkan *West Texas Intermediate* (WTI).

3.3 Langkah-Langkah Analisis Data

1. Melakukan uji stasioneritas pada deret *input* dan *output*.
2. Melakukan identifikasi model ARIMA dari deret *input*.
3. Melakukan estimasi dan uji signifikansi parameter model ARIMA dari deret *input*.
4. Melakukan uji diagnostik pada model ARIMA dari deret *input*.
5. Pemilihan model ARIMA terbaik dari deret *input* berdasarkan nilai AIC terkecil.
6. Melakukan pemutihan pada deret *input* dan deret *output*.
7. Menghitung korelasi silang (*cross correlation*) dan autokorelasi untuk deret *input* dan *output* yang sudah diputihkan.
8. Menetapkan (b,r,s) untuk model fungsi transfer.
9. Melakukan identifikasi model ARMA deret gangguan (*noise*).
10. Melakukan estimasi dan uji signifikansi parameter model fungsi transfer yang mungkin terjadi.
11. Melakukan uji diagnostik pada model fungsi transfer yang mungkin terjadi.
12. Pemilihan model fungsi transfer terbaik berdasarkan nilai AIC terkecil.
13. Melakukan pemodelan *Feedforward Neural Network* dengan Algoritma *Backpropagation*.

14. Menetapkan model Fungsi Transfer dan *Backpropagation Neural Network* terbaik berdasarkan nilai MAPE data *out sample* terkecil.
15. Melakukan peramalan harga emas untuk beberapa periode kedepan dengan menggunakan model terbaik.

4. HASIL DAN PEMBAHASAN

4.1 Pemodelan Fungsi Transfer

4.1.1 Pengujian Stasioneritas pada Deret *Output* dan *Input*

Pada data deret *output* harga emas dan deret *input* harga minyak mentah secara visual dan uji *Augmented Dickey-Fuller* (ADF) tidak stasioner dalam *mean* sehingga dilakukan proses *differencing* 1 kali dan diperoleh nilai prob. masing-masing data yaitu 0,0000 sehingga dapat disimpulkan bahwa data setelah *differencing* 1 kali sudah stasioner dalam *mean*. Pada uji stasioneritas dalam varian dapat digunakan transformasi *Box-Cox* dan diperoleh nilai *rounded value* (λ) data deret harga emas dan deret harga minyak mentah adalah satu yang dapat disimpulkan bahwa data setelah *differencing* 1 kali sudah stasioner dalam varian.

4.1.2 Pemodelan ARIMA Deret *Input* Harga Minyak Mentah

Berikut ini tabel hasil kesimpulan dari pengujian signifikansi parameter, pengujian asumsi independensi residual, normalitas residual dan homogenitas varian residual (ARCH-LM), serta nilai AIC untuk masing-masing model ARIMA yang mungkin untuk deret *input* harga minyak mentah.

Tabel 2. Uji Signifikansi dan Uji Diagnostik Model ARIMA Harga Minyak Mentah Setelah *Differencing*

Model	Signifikansi Parameter	Idependensi Residual	Normalitas Residual	ARCH-LM	AIC
ARIMA([1,5],1,[1,2,5])	Tidak	Ya	Ya	Tidak	887.465
ARIMA([1,5],1,[5])	Ya	Ya	Ya	Tidak	883.051
ARIMA([1,5],1,0)	Ya	Ya	Ya	Tidak	885.556
ARIMA(1,1,1)	Tidak	Ya	Ya	Tidak	890.526
ARIMA(0,1,[5])	Ya	Tidak	Ya	Tidak	890.883

Berdasarkan Tabel 2 diketahui model yang memiliki nilai AIC terkecil adalah model ARIMA ([1,5],1,[5]), maka model ARIMA ([1,5],1,[5]) terpilih menjadi model terbaik dari semua model yang mungkin, dengan modelnya:

$$x_t = 0,23764x_{t-1} + 0,33721x_{t-5} + a_t - 0,66343a_{t-5}$$

4.1.3 Pemutihan Deret *Input* dan *Output*

Setelah didapatkan model ARIMA terbaik untuk deret *input* maka tahap pemutihan deret *input* dan *output* dapat dilakukan, dengan model pemutihan deret *input* sebagai berikut:

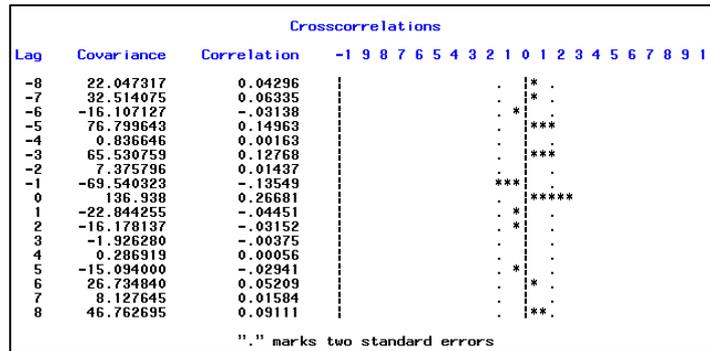
$$\beta_t = x_t - 0,23764x_{t-1} - 0,33721x_{t-5} + 0,66343\beta_{t-5}$$

sedangkan model pemutihan deret *ouput* adalah sebagai berikut:

$$\gamma_t = y_t - 0,23764y_{t-1} - 0,33721y_{t-5} + 0,66343\gamma_{t-5}$$

4.1.4 Perhitungan Korelasi Silang

Pembentukan model awal fungsi transfer diawali dengan tahap perhitungan korelasi silang antara deret harga emas dan deret harga minyak mentah yang telah dilakukan pemutihan. Hasil perhitungan korelasi silang ini berupa plot *Cross Correlation Function* (CCF).



Gambar 1. Plot Cross Correlation Function antara β_t dan γ_t

4.1.5 Penetapan Nilai (b,r,s) Model Fungsi Transfer

Berdasarkan plot CCF pada Gambar 1 dapat diketahui lag yang pertama kali signifikan adalah lag nol. Sehingga diperoleh nilai $b=0$. Sedangkan untuk beberapa nilai b,r,s dugaan yang lain dapat dilihat pada Tabel 3.

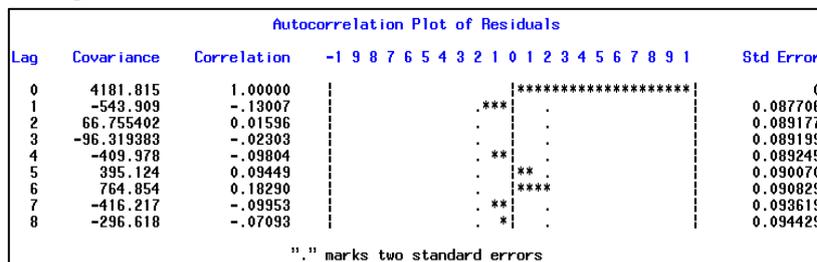
Tabel 3. Identifikasi Nilai (b,r,s) Fungsi Transfer

No	Nilai (b,r,s)	Semua Parameter Model Signifikan	AIC
1	0,0,0	Ya	1476,436
2	0,1,0	Tidak	1467,512
3	0,0,1	Tidak	1466,876
4	0,1,1	Tidak	1467,928
5	0,2,0	Tidak	1456,540
6	0,0,2	Tidak	1456,521
7	0,[2],0	Ya	1454,914
8	0,0,[2]	Tidak	1455,257

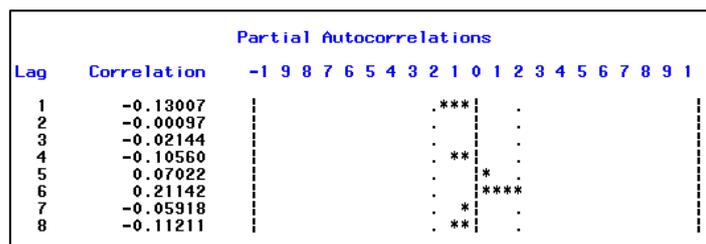
Berdasarkan Tabel 3, nilai (b,r,s) yang terbaik untuk memodelkan fungsi transfer harga emas berdasarkan harga minyak mentah yaitu $b=0, r=[2], s=0$.

4.1.6 Identifikasi Model Deret Noise

Identifikasi model ARMA deret noise dilakukan dengan melihat plot ACF dan PACF residual model fungsi transfer.



Gambar 2. Plot ACF Residual Model Fungsi Transfer



Gambar 3. Plot PACF Residual Model Fungsi Transfer

Beberapa dugaan model ARMA deret *noise* yang mungkin yaitu ARMA ([6],[6]), ARMA ([6],0) dan ARMA (0,[6]).

4.1.7 Pemilihan Model Fungsi Trasfer Terbaik

Berikut ini tabel uji signifikansi, uji diagnostik dan nilai AIC dari model fungsi transfer dan beberapa model *noise* yang mungkin.

Tabel 4. Uji Signifikansi dan Uji Diagnostik Model Fungsi Transfer

Nilai (b,s,r)	Model <i>noise</i>	Signifikansi Parameter	Korelasi Silang	Autokorelasi	AIC
0,[2],0	ARMA([6],[6])	Tidak	Ya	Ya	1454.203
0,[2],0	ARMA([6],0)	Ya	Ya	Ya	1452.253
0,[2],0	ARMA(0,[6])	Ya	Ya	Ya	1452.249

Berdasarkan Tabel 4 diketahui model yang memiliki nilai AIC terkecil adalah model fungsi transfer (0,[2],0)–(0,[6]), maka model fungsi transfer harga minyak mentah (0,[2],0) dengan model deret *noise* yaitu ARMA (0,[6]) terpilih menjadi model terbaik dari semua model yang mungkin, dengan modelnya:

$$Y_t = Y_{t-1} - 0,54525Y_{t-2} + 0,54525Y_{t-3} + 2,37823X_t - 2,37823X_{t-1} + a_t + 0,54525a_{t-2} + 0,19244a_{t-6} + 0,10493a_{t-8}$$

4.2 Pemodelan dengan *Backpropagation Neural Network*

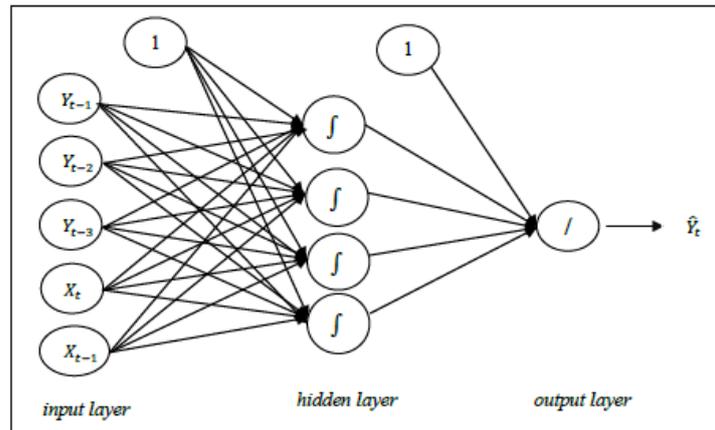
Pemodelan *backpropagation neural network* menggunakan lima *input* berdasarkan *lag* variabel yang signifikan dari model fungsi transfer terbaik yang diperoleh pada tahap sebelumnya yaitu Y_{t-1} , Y_{t-2} , Y_{t-3} , X_t dan X_{t-1} . Sedangkan dalam *output layer* terdapat satu variabel target yaitu Y_t . Arsitektur ini menggunakan satu *hidden layer* dengan jumlah *neuron* di dalamnya dibatasi sebanyak 1 sampai 10 *neuron*. Fungsi aktivasi yang digunakan di *hidden layer* adalah *sigmoid biner* sedangkan di *output layer* menggunakan fungsi aktivasi *linear*.

Setelah proses *training* dilakukan dengan jumlah *neuron hidden layer* sebanyak 1 hingga 10, maka diperoleh nilai MAPE proses *training* untuk masing-masing model dengan jumlah *hidden layer* yang berbeda-beda. Untuk mendapatkan model dengan arsitektur jaringan terbaik maka perlu dipilih model dengan nilai MAPE proses *training* terkecil.

Tabel 5. Perbandingan Nilai MAPE Proses *Training*

Jumlah <i>Neuron Hidden Layer</i>	MAPE	Jumlah <i>Neuron Hidden Layer</i>	MAPE
1	7,2477	6	6,5219
2	7,6903	7	6,6124
3	7,4211	8	6,6212
4	6,5166	9	6,9827
5	6,8216	10	6,5402

Berdasarkan Tabel 5 dapat diketahui bahwa hasil ramalan data *in sample* dengan 4 *neuron* memiliki nilai MAPE terkecil, sehingga model *backpropagation neural network* untuk model fungsi transfer harga emas berdasarkan harga minyak mentah yang dibangun dari 4 *neuron* pada *hidden layer* dengan *input* Y_{t-1} , Y_{t-2} , Y_{t-3} , X_t dan X_{t-1} merupakan model yang optimal untuk meramalkan harga emas dengan bentuk arsitekturnya disajikan pada Gambar 4.



Gambar 4. Arsitektur Model *Backpropagation Neural Network*

Berdasarkan arsitektur jaringan pada Gambar 4 didapatkan persamaan model *backpropagation neural network* sebagai berikut.

$$\begin{aligned}
 Y_t = & -0,0751 - \frac{0,2398}{1 + e^{-(-9,7053 + 2,1396Y_{t-1} + 6,4901Y_{t-2} - 5,9992Y_{t-3} - 3,97008X_t + 70,0139X_{t-1})}} \\
 & + \frac{0,0797}{1 + e^{-(-2,0360 + 0,2925Y_{t-1} + 5,8494Y_{t-2} - 6,3348Y_{t-3} + 63,4561X_t + 47,9800X_{t-1})}} \\
 & + \frac{0,4373}{1 + e^{-(-7,2768 + 8,7896Y_{t-1} - 4,1888Y_{t-2} + 3,0718Y_{t-3} + 30,8599X_t + 21,6860X_{t-1})}} \\
 & + \frac{0,5333}{1 + e^{-(-4,5477 + 7,5094Y_{t-1} + 3,9492Y_{t-2} - 1,7662Y_{t-3} + 31,4368X_t - 87,5998X_{t-1})}}
 \end{aligned}$$

4.3 Pemilihan Model Terbaik

Perbandingan hasil peramalan harga emas untuk data *out sample* dengan model fungsi transfer dan model *backpropagation neural network* dapat dilihat pada Tabel 6.

Tabel 6. Perbandingan Kriteria Keباikan Model berdasarkan Hasil Peramalan Data *Out Sample*

Model	Nilai MAPE Data <i>Out Sample</i> (%)
Fungsi Transfer	3,3507
<i>Backpropagation Neural Network</i>	4,7313

Berdasarkan Tabel 6 dapat dilihat bahwa untuk peramalan harga emas menggunakan metode fungsi transfer memberikan hasil peramalan yang lebih baik dibandingkan dengan metode *backpropagation neural network*. Sehingga dapat disimpulkan bahwa model fungsi transfer merupakan model terbaik yang dapat digunakan untuk meramalkan harga emas untuk 5 periode ke depan.

4.4 Hasil Peramalan

Tabel 7. Hasil Peramalan Harga Emas

Periode	Harga Emas US\$ per troy ounce
Maret 2019	1228,9176
April 2019	1228,7659
Mei 2019	1227,5308
Juni 2019	1227,5142
Juli 2019	1227,7568

Setelah terpilih model terbaik didasarkan pada nilai MAPE data *out sample* maka selanjutnya dapat dilanjutkan dengan meramalkan harga emas untuk 5 periode ke depan menggunakan model fungsi transfer. Hasil peramalan harga emas 5 bulan ke depan dapat dilihat pada Tabel 7.

5. KESIMPULAN

Berdasarkan hasil dan pembahasan yang telah dilakukan, maka dapat diambil kesimpulan sebagai berikut:

1. Model fungsi transfer dengan nilai $b=0$, $r=[2]$, $s=0$ dan model *noise* ARMA(0,[6]) adalah model terbaik yang diperoleh dari hasil identifikasi, dengan modelnya sebagai berikut:

$$Y_t = Y_{t-1} - 0,54525Y_{t-2} + 0,54525Y_{t-3} + 2,37823X_t - 2,37823X_{t-1} + a_t + 0,54525a_{t-2} + 0,19244a_{t-6} + 0,10493a_{t-8}$$

2. Model *backpropagation neural network* menghasilkan arsitektur terbaik dengan menggunakan lima *neuron* pada *input layer*, empat *neuron* pada *hidden layer* dan satu *neuron* pada *output layer*. Model yang terbentuk sebagai berikut:

$$Y_t = -0,0751 - \frac{0,2398}{1 + e^{-(9,7053+2,1396Y_{t-1}+6,4901Y_{t-2}-5,9992Y_{t-3}-3,97008X_t+70,0139X_{t-1})}} + \frac{0,0797}{1 + e^{-(2,0360+0,2925Y_{t-1}+5,8494Y_{t-2}-6,3348Y_{t-3}+63,4561X_t+47,9800X_{t-1})}} + \frac{0,4373}{1 + e^{-(7,2768+8,7896Y_{t-1}-4,1888Y_{t-2}+3,0718Y_{t-3}+30,8599X_t+21,6860X_{t-1})}} + \frac{0,5333}{1 + e^{-(4,5477+7,5094Y_{t-1}+3,9492Y_{t-2}-1,7662Y_{t-3}+31,4368X_t-87,5998X_{t-1})}}$$

3. Berdasarkan perbandingan nilai MAPE data *out sample*, model fungsi transfer memberikan hasil peramalan yang lebih baik dibandingkan dengan model *backpropagation neural network* dengan nilai MAPE sebesar 3,3507%.

DAFTAR PUSTAKA

- Hecht, A. 2019. *Understanding the Crude Oil Market : Pricing Differentials Between Brent Crude and WTI*. <https://www.thebalance.com/crude-oil-brent-versus-wti-808872>. Diakses: 10 Februari 2019.
- Kusnandar, R. 2010. *Cara Cerdas Berkebun Emas*. Jakarta: Trans Media.
- Makridakis, S., Wheelwright, S. C., dan McGee, V. E. 1999. *Metode dan Aplikasi Peramalan*. Diterjemahkan oleh: Ir. Hari Suminto. Jakarta: Binarupa Aksara. Terjemahan dari: *Forecasting 2nd Edition*.
- Saputri, A. F. 2017. *Prediksi Jumlah Penumpang Kereta Api Menggunakan Model Variasi Kalender dengan Deteksi Outlier (Studi kasus: PT.Kereta Api Indonesia DAOP IV Semarang)*. *Jurnal Gaussian*. 6(3):281-289.
- Siang, J. J. 2005. *Jaringan Syaraf Tiruan dan Pemogramannya Menggunakan Matlab*. Yogyakarta: ANDI.
- Tarno. 2013. *Kombinasi Prosedur Pemodelan Subset ARIMA dan Deteksi Outlier untuk Prediksi Data Runtun Waktu*. Prosiding Seminar Nasional Statistika Universitas Diponegoro.
- Tsay, R. S. 2010. *Analysis of Financial Time Series Third Edition*. Chicago: John Wiley & Sons, Inc.
- Wei, W. W. S. 2006. *Times Series Analysis Univariate and Multivariate methods Second Edition*. New York: Addison Wesley Publishing Company.