

PERAMALAN MENGGUNAKAN MODEL *FEED FORWARD NEURAL NETWORK* DENGAN ALGORITMA *ADAPTIVE SIMULATED ANNEALING*
(Studi kasus: Harga minyak mentah dunia yang dipublikasikan oleh OPEC)

Affan Hanafaie¹, Sugito², Sudarno³

^{1,2,3} Departemen Statistika, Fakultas Sains dan Matematika, Universitas Diponegoro
e-mail : sugitostat@gmail.com

ABSTRACT

Today, crude oil trading industry is still an important industry in the world because it still has high fuel oil consumption. The crude oil prices tend to fluctuate causing the prediction of crude oil in the coming periods to be a challenge. Forecasting the price of crude oil can be done by various methods, one of them is ARIMA Box-Jenkins model with OLS method to estimate the parameter, but this method has several assumptions that must be met. As time goes by, many methods that discovered, one of them is artificial neural network which can combined with various parameter optimization methods such as Adaptive Simulated Annealing algorithm. Adaptive Simulated Annealing algorithm is an optimization method that inspired by the process of crystallization, the advantages of this algorithm has a running time faster than similar algorithms. The combination of artificial neural networks and Adaptive Simulated Annealing algorithms can be used to model the historical data without requiring assumptions in the analysis. Based on the analysis on this research, the best model is obtained FFNN 2-5-1 with MAPE value of 1.0042%.

Keywords: neural network, Adaptive Simulated Annealing, crude oil.

1. PENDAHULUAN

Indonesia dikenal sebagai negara yang kaya akan sumber daya alam, hasil bumi serta hasil tambang yang sangat melimpah, salah satunya adalah minyak bumi. Industri minyak bumi di Indonesia sudah lama berjalan, setelah 73 tahun merdeka sumber energi utama Indonesia tidak banyak berubah dengan tetap mengandalkan bahan bakar fosil ini. Bahan bakar fosil yang paling banyak digunakan di Indonesia didominasi oleh bahan bakar minyak dengan persentase sebesar 33.8%, bahan bakar gas sebesar 23.9%, bahan bakar batu bara sebesar 34.6% dan 7.7% berbasis energi baru terbarukan. Dalam rentang waktu antara tahun 1970 hingga akhir tahun 1990 Indonesia menjadi produsen minyak dan gas dunia. Kemudian pada awal tahun 1997 Indonesia mengalami resesi ekonomi yang mengakibatkan perubahan drastis kondisi perekonomian Indonesia. Sejak saat itu produksi minyak di Indonesia semakin menurun, dan saat ini produksi minyak mentah di Indonesia berada di kisaran 875.000 barel per hari dengan tingkat kebutuhan minyak hasil produksi sekitar 1.500.000 barel per hari (www.esdm.go.id).

Menurut Wei (2006) dalam analisis runtun waktu bagian yang paling penting adalah untuk meramalkan nilai di masa yang akan datang. Istilah ramalan lebih sering digunakan daripada istilah perkiraan pada literatur runtun waktu, hasil peramalan runtun waktu pada umumnya berdasarkan teori umum dari *linier prediction*. Dalam praktiknya terkadang asumsi tersebut justru menjadi kendala ketika tidak terpenuhi pada saat proses analisis, oleh karena itu diperlukan metode alternatif untuk mengatasi kendala tersebut dengan tetap memberikan hasil estimasi yang baik, salah satunya adalah metode *Adaptive Simulated Annealing* karena hanya diperlukan membangun model dan melakukan optimalisasi bobot tanpa melakukan uji asumsi. Penggunaan metode *Adaptive Simulated Annealing* dapat dikombinasi dengan model *Neural Network*, berdasarkan penelitian sebelumnya yang dilakukan oleh Mousavi et al. (2017) penggunaan *Neural Network* dan *Adaptive Simulated*

Annealing mampu meningkatkan kemampuan prediksi model, dan dari perbandingan yang dilakukan mampu memberikan hasil yang lebih baik dari kombinasi Neural Network dengan *Support Vector Machine*.

Artificial Neural Network atau yang biasa disebut jaringan syaraf tiruan merupakan sistem untuk memproses informasi yang memiliki karakteristik mirip dengan jaringan syaraf pada makhluk hidup (Fauset, 1994). Dalam perkembangannya *Artificial Neural Network* lebih dikenal dengan nama *Neural Network* tanpa menggunakan imbuhan *Artificial*. Secara garis besar *Neural Network* terdiri dari dua tahapan dalam proses pengolahan informasi atau data masukan, yaitu tahap *learning* dan tahap *testing*. Dalam tahap *training* proses perhitungan bobot optimal dapat menggunakan berbagai metode optimasi, salah satunya adalah metode *Adaptive Simulated Annealing* atau yang lebih dikenal dengan *Simulated Annealing*. Kelebihan algoritma *Adaptive Simulated Annealing* yaitu memiliki waktu *running* yang lebih cepat dibandingkan dengan algoritma sejenisnya seperti algoritma genetika (Adewole et al., 2012). *Simulated Annealing* merupakan metode optimasi yang diadaptasi dari proses pembuatan logam padat dengan metode *cold working*.

2. TINJAUAN PUSTAKA

2.1. Minyak Bumi

Minyak bumi merupakan salah satu hasil tambang potensial yang dimiliki oleh Indonesia, hal ini dibuktikan dengan banyaknya wilayah di Indonesia yang memiliki potensi minyak bumi. Selain menjadi menjadi hasil tambang potensial untuk dijual faktanya minyak bumi menjadi salah satu kebutuhan energi masyarakat Indonesia yang masih sulit tergantikan. Pada tahun 2015 diketahui cadangan potensial minyak sebanyak 3,70 miliar barel dan cadangan terbukti sebanyak 3,60 miliar barel. Cadangan minyak bumi di Indonesia tersebar di berbagai daerah, dimana sebagian besarnya berada di Sumatera sebesar 66,35% dari total cadangan minyak bumi nasional atau sebanyak 4,83 miliar barel. Sedangkan di daerah Jawa dan Kalimantan masing-masing memiliki cadangan minyak bumi sebanyak 1,78 miliar barel dan 0,52 barel, sisanya sebanyak 0,15 barel terdapat di daerah Papua, Maluku, dan Sulawesi (DEN, 2016).

2.2. Analisis Runtun Waktu

Data runtun waktu memiliki ruang lingkup yang sangat luas, oleh karena itu mengakibatkan analisis runtun waktu menjadi sebuah ilmu yang tidak terbatas ruang lingkup penerapannya (Cryer & Chan, 2008). Analisis runtun waktu merupakan salah satu prosedur statistika yang diterapkan untuk meramalkan keadaan yang akan datang berdasarkan data masa lalu.

2.3. Fungsi Autokorelasi

Menurut wei (2006), dari suatu runtun waktu yang stasioner (Z_t), terdapat nilai mean $E(Z_t) = \mu$ dan varians $Var(Z_t) = E(Z_t - \mu)^2 = \sigma^2$ yang konstan. Kovarian antara Z_t dan Z_{t+1} adalah sebagai berikut :

$$\gamma_k = cov(Z_t, Z_{t+k})$$

Suatu runtun waktu stasioner dapat diestimasi rata-rata (μ) dan fungsi autokorelasi (ρ_k) sebagai berikut:

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{cov(Z_t, Z_{t+k})}{cov(Z_t, Z_t)}$$

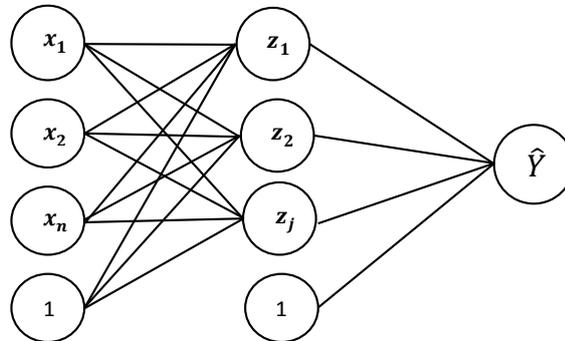
2.4. Fungsi Autokorelasi Spasial

Fungsi autokorelasi parsial (PACF) dapat diturunkan berdasarkan model regresi dengan Z_{t+k} sebagai variabel terikat dari sebuah proses stasioner dengan rata-rata nol yang diregresikan dengan variabel $Z_{t+k-1}, Z_{t+k-2}, \dots, Z_t$ pada lag ke- k (Wei, 2006). Dengan fungsi PACF sebagai berikut:

$$\phi_{kk} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} & \rho_1 \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} & \rho_2 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_1 & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} & \rho_{k-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_1 & 1 \end{vmatrix}}$$

2.5. Jaringan Syaraf Tiruan

Menurut Haykin (2009) jaringan syaraf tiruan terinspirasi dari cara kerja otak manusia yang sangat berbeda dengan komputer digital pada umumnya, dimana otak manusia sangat kompleks, tidak linier, dan bersifat paralel dalam memproses informasi. Pada *neural network* terdapat beberapa komponen didalamnya, menurut Kusumadewi (2003), *neural network* memiliki beberapa bagian utama yang menyusunnya seperti halnya pada otak manusia antara lain: input, fungsi aktivasi, neuron/node, bias & threshold, hidden layer, dan output.



Gambar 1. Ilustrasi Model FFNN dengan satu *hidden layer*

2.6. Pre-processing dan Post-Processing

Pada komputasi menggunakan jaringan syaraf tiruan seringkali sebelum dilakukan tahap pelatihan dilakukan penskalaan pada input dan target sehingga data masuk pada skala tertentu, hal tersebut bertujuan supaya data dapat diproses sesuai dengan fungsi aktivasi yang digunakan (Warsito, 2009). Proses mengubah skala data sebelum dilakukan tahap pelatihan disebut pre-processing, sedangkan proses penskalaan setelah dilakukan tahap pelatihan disebut post-processing. menurut Patro & Sahu (2015) transformasi dilakukan untuk mengubah skala data dan transformasi juga bermanfaat untuk mengurangi nilai *error* untuk prediksi atau peramalan. Salah satu transformasi yang sudah dikenal adalah transformasi min-max, dengan rumus sebagai berikut:

$$x'_t = \left(\frac{x_t - \min(x)}{\max(x) - \min(x)} \right)$$

2.7. Mean Absolute Error (MAE)

Willmot dan Matsuura (2005) mengindikasikan bahwa MAE merupakan skala pengukuran error yang paling alami dari rata-rata skala pengukuran error tidak seperti RMSE

maupun MSE, MAE merupakan skala pengukuran error yang tidak bersifat ambigu. MAE dapat dihitung dengan rumus sebagai berikut:

$$MAE = \frac{1}{n} \sum_{t=1}^n |\hat{Y}_t - Y_t|$$

2.8. Mean Absolute Percentage Error (MAPE)

Dalam penaksiran model diperlukan alat untuk mengukur kemampuan model terutama untuk peramalan, salah satu alat tersebut adalah Mean Absolute Percentage Error atau MAPE. Menurut Hyndman dan Koehler (2006) persentase error sudah sangat sering digunakan untuk membandingkan kemampuan peramalan dari beberapa data set yang berbeda, dengan rumus MAPE sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| 100\% \times \frac{\hat{Y}_t - Y_t}{Y_t} \right|$$

2.9. Adaptive Simulated Annealing

Metode adaptive simulated annealing atau yang biasa dikenal dengan simulated annealing adalah sebuah metode optimasi modern yang diadaptasi dari proses pembuatan kristal logam yang menggunakan teknik cold working. Menurut Rao (2009), proses pendinginan dalam pembuatan kristal yang terjadi dalam cold working dapat dikontrol dengan menggunakan distribusi peluang Boltzmann dengan energi yang disimbolkan dengan E dan suhu disimbolkan dengan T dengan peluang sebagai berikut:

$$P(E) = e^{-E/cT}$$

dimana P(E) adalah peluang energi yang diterima pada level E, dan c adalah konstanta Boltzmann dengan nilai sebagai berikut:

$$c = 1,38 \times 10^{-23} \text{J/K} = 1,38 \times 10^{-16} \text{erg/K.}$$

Menurut Szu (1987) pada dasarnya penurunan suhu buatan (T_k) akan berbeda dengan suhu termodinamika sebenarnya (T), suhu buatan tersebut nilainya berbanding terbalik dengan fungsi logaritma dari waktu pada saat itu dengan suhu awal adalah T_0 , suhu pada iterasi ke-k (T_k) dapat dihitung dengan rumus sebagai berikut:

$$\frac{T_k}{T_0} = \frac{1}{\ln(1+k)}$$

Secara sederhana langkah-langkah perhitungan algoritma *Simulated Annealing* dapat dituliskan sebagai berikut:

1. Menetapkan nilai w_i dengan $i = 0$ sebagai bobot awal dan menetapkan *stopping criteria*.
2. Menghitung nilai $f_1 = f(w_1)$.
3. Bangkitkan nilai baru w_{i+1} disekitar w_i dan hitung nilai $f(w_{i+1})$.
4. Hitung suhu pada iterasi ke-i dengan rumus $T_k = \frac{T_0}{\ln(1+k)}$
5. Hitung $\Delta f = \Delta E = f(w_{i+1}) - f(w_i)$.
6. Jika nilai ΔE bernilai kurang dari sama dengan nol maka nilai w_{i+1} diterima dan lanjut ke nomor 7, jika ΔE bernilai lebih dari nol maka dihitung nilai peluang $P(E) = e^{-\Delta E/cT}$.
7. Bangkitkan nilai random antara 0 dan 1 dan kemudian bandingkan dengan nilai $P(E)$, jika nilai $P(E)$ lebih kecil dari bilangan random yang dibangkitkan maka tolak nilai w_{i+1} , jika tidak terima nilai w_{i+1} sebagai bobot baru.
8. Jika *stopping criteria* sudah tercapai maka iterasi dihentikan dan nilai w_{i+1} menjadi vektor bobot akhir, jika tidak maka w_{i+1} menjadi w_i dan proses diulangi mulai nomor 2.

2.10 Peramalan

1. Recursive Forecasting

Menurut Ahmed & Khalid (2017) metode recursive forecasting adalah metode peramalan beberapa langkah ke depan dengan menggunakan model yang sama dimana hasil peramalan yang terakhir digunakan sebagai nilai input pada peramalan selanjutnya, namun hasil peramalan metode ini memungkinkan memberi hasil yang tidak akurat untuk peramalan jangka panjang.

2. Direct Forecasting

Metode direct forecasting adalah metode peramalan yang berdasarkan prinsip peramalan dimana setiap langkah peramalan saling bebas satu sama lain, sehingga untuk meramalkan sejumlah (h) langkah ke depan membutuhkan model sebanyak (H) dimana peramalan yang dilakukan pada setiap langkah tanpa memasukkan nilai hasil peramalan sebelumnya (Ahmed & Khalid, 2017).

3. METODE PENELITIAN

3.1. Sumber Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini adalah data sekunder yang merupakan data harga minyak mentah dunia yang dikeluarkan OPEC dan diperoleh dari <http://www.opec.org> mulai tanggal 2 Januari 2015 hingga tanggal 3 Mei 2018. Data dibagi menjadi dua bagian, yaitu 90% data training dan 10% data testing. data training digunakan untuk membangun model dan data testing digunakan untuk menghitung eror dari peramalan model.

3.2. Teknik Pengolahan Data

Model neural network yang digunakan dalam penulisan tugas akhir ini adalah model Feed Forward Neural Network (FFNN) dengan fungsi aktivasi sigmoid biner dan fungsi aktivasi linier. Arsitektur jaringan FFNN yang dibangun adalah dengan input x_i dimana $i = 1, 2, \dots, p$ dan satu unit hidden layer, sedangkan untuk mencari hasil yang terbaik untuk melakukan peramalan akan dilakukan percobaan, yaitu meminimalkan MAE dengan memasukkan kombinasi beberapa input sesuai plot ACF dan PACF serta kombinasi jumlah hidden nodes sebanyak 5 dan 10, serta pemberian beberapa nilai sebagai batas bobot pada tahap training dengan metode Adaptive Simulated Annealing dan suhu awal sebesar 100. Langkah-langkah dalam proses *training* dan *testing* FFNN dengan metode optimasi *Adaptive Simulated Annealing* adalah sebagai berikut:

1. Identifikasi lag
Identifikasi lag bertujuan untuk menentukan variabel x sebagai input yang akan digunakan berdasarkan hasil plot PACF.
2. Inisialisasi fungsi & input
Inisialisasi input bertujuan untuk menentukan nilai-nilai tertentu yang diinginkan, dalam analisis ini yang ditentukan nilai-nilainya antara lain: jumlah iterasi, batas atas dan batas bawah bobot. Sedangkan inisialisasi fungsi bertujuan untuk menentukan fungsi yang akan diminimalkan, pada tugas akhir ini gunakan fungsi MAE dan MAPE.
3. Pre-Processing
Transformasi data untuk proses training maupun testing yang dilakukan pada analisis yang dilakukan bertujuan untuk mengecilkan skala data untuk menyesuaikan skala data dengan fungsi aktivasi yang digunakan, yaitu fungsi aktivasi sigmoid biner.
4. Inisialisasi bobot awal
Inisialisasi bobot awal pada tahap iterasi yang pertama adalah sebagai bobot awal untuk menghitung nilai eror awal.
5. Inisialisasi suhu awal

Inisialisasi suhu awal ditujukan sebagai nilai awal dalam pembentukan suhu pada tahap iterasi berikutnya

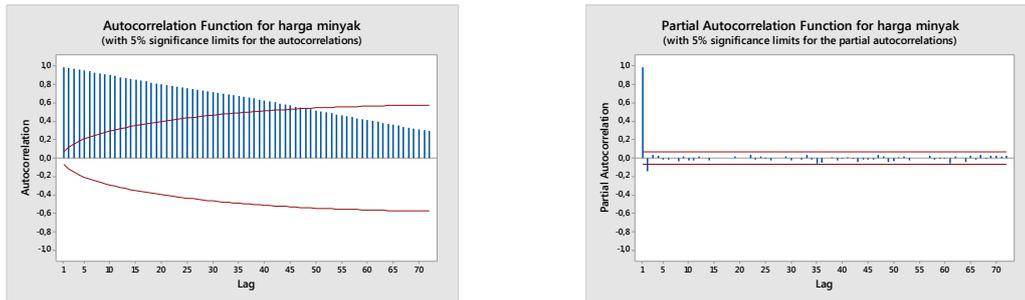
6. Perhitungan eror awal
Perhitungan eror awal dilakukan sebagai pembandingan hasil akhir iterasi apakah terlihat adanya perubahan nilai eror setelah dilakukan proses iterasi dan perhitungan eror awal digunakan untuk menghitung peluang penerimaan pada iterasi selanjutnya.
7. Membangkitkan bilangan acak seragam (0,1)
Pembangkitan bilangan acak seragam (0,1) dilakukan untuk mendapatkan bobot baru untuk iterasi selanjutnya.
8. Menghitung suhu baru
Perhitungan suhu baru dilakukan dengan skala yang sudah ditetapkan untuk melakukan perhitungan peluang penerimaan.
9. Menghitung eror
Perhitungan eror pada setiap iterasi sangat penting untuk dilakukan, selain untuk dibandingkan dengan stopping criteria tapi juga untuk menghitung peluang penerimaan pada proses Adaptive Simulated Annealing.
10. Menghitung nilai peluang penerimaan
Perhitungan peluang penerimaan sangat penting karena dari peluang penerimaan inilah dapat diputuskan apakah bobot awal yang digunakan akan digantikan dengan bobot baru atau tidak.
11. Mengganti bobot baru
Penggantian bobot baru dilakukan jika bobot baru yang sebelumnya dibangkitkan dianggap memberikan hasil yang lebih baik pada tahap iterasi.
12. Melakukan looping
Looping yang dilakukan adalah pengulangan tahapan ke-7 sampai tahap ke-11 sampai mendapatkan hasil yang optimal atau sampai memenuhi salah satu stopping criteria.
13. Tahap testing
Pada tahap ini bobot optimal yang sudah didapatkan digunakan untuk menghitung output baru menggunakan data testing.
14. Post-Processing
Tujuan transformasi data pada akhir proses iterasi bertujuan untuk mengembalikan skala data ke skala semula karena sebelumnya sudah dilakukan pengecilan skala data.
15. Menghitung nilai MAPE
Perhitungan nilai MAPE dilakukan setelah data melalui tahap post-processing sehingga nilai data yang digunakan sudah kembali pada skala aslinya.
16. Pemilihan model terbaik
Pemilihan model terbaik yang dilakukan pada tugas akhir ini adalah dengan menggunakan kriteria MAPE yang diperoleh dari perhitungan MAPE pada tahap testing.
17. Peramalan
Tujuan dari proses peramalan ini adalah untuk mengetahui harga minyak mentah dunia yang akan datang atau pada periode berikutnya berdasarkan model terbaik yang digunakan.

4. HASIL DAN PEMBAHASAN

4.1 Penentuan Input dan Target Jaringan

Berdasarkan Gambar 2 bisa disimpulkan data runtun waktu harga minyak mentah dunia yang digunakan tidak bisa dimodelkan menggunakan model MA karena nilai ACF-nya terus meluruh atau turun secara eksponensial, namun dapat dimodelkan secara

autoregresif karena terpotong pada lag 1 dan 2 pada plot PACF, sehingga berdasarkan Gambar 2 dapat digunakan variabel Y_{t-1} dan Y_{t-2} sebagai variabel input dalam jaringan dengan Y_t sebagai targetnya.



Gambar 1. Plot ACF dan PACF

4.2 Arsitektur Jaringan

Jaringan yang dibangun adalah FFNN yang terdiri dari 3 lapisan, yaitu lapisan masukan (input), lapisan tersembunyi (hidden layer), dan lapisan keluaran (output). Dalam menentukan variabel input dalam jaringan syaraf tiruan tidak ada ketentuan tertentu, namun pada penelitian ini variabel input yang digunakan dibatasi berdasarkan kesimpulan dari plot ACF dan PACF. Begitu juga dengan jumlah neuron/hidden nodes tidak ada ketentuan yang menyatakan berapa seharusnya jumlah hidden nodes yang digunakan, sehingga dibatasi sejumlah 5 dan 10 yang akan dikombinasi dengan variabel input untuk membangun beberapa model. Hasil kombinasi tersebut menghasilkan 6 model FFNN, yaitu:

1. Y_{t-1} sebagai variabel input dengan jumlah *hidden nodes* sebanyak 5.
2. Y_{t-1} sebagai variabel input dengan jumlah *hidden nodes* sebanyak 10.
3. Y_{t-2} sebagai variabel input dengan jumlah *hidden nodes* sebanyak 5.
4. Y_{t-2} sebagai variabel input dengan jumlah *hidden nodes* sebanyak 10.
5. Y_{t-1} dan Y_{t-2} sebagai variabel input dengan jumlah *hidden nodes* sebanyak 5.
6. Y_{t-1} dan Y_{t-2} sebagai variabel input dengan jumlah *hidden nodes* sebanyak 10.

4.3 Pre-Processing

Karena dalam penggunaan fungsi aktivasi sigmoid binner diperlukan skala data yang sesuai dengan skala yang ada pada fungsi sigmoid binner yaitu antara 0 dan 1, maka data yang digunakan dalam proses training baik input maupun target perlu diubah skalanya dengan rumus sebagai berikut:

$$x'_t = \left(\frac{x_t - \min(x)}{\max(x) - \min(x)} \right)$$

$$x'_1 = \left(\frac{x_1 - 22,48}{64,96 - 22,48} \right)$$

$$x'_1 = \left(\frac{51,78 - 22,48}{64,96 - 22,48} \right)$$

$$x'_1 = 0,6897$$

$$x'_2 = \left(\frac{48,87 - 22,48}{64,96 - 22,48} \right)$$

$$x'_2 = 0,6212$$

$$\vdots$$

$$x'_{775} = \left(\frac{64,84 - 22,48}{64,96 - 22,48} \right)$$

$$x'_{775} = 0,9972$$

4.4 Proses Training dengan Algoritma Adaptive Simulated Annealing (ASA)

Dalam praktiknya tidak ada aturan tertentu mengenai batas yang harus digunakan dalam ASA, sehingga pada tugas akhir kali ini diuji coba beberapa kali dengan 4 batas yang berbeda beda, batas yang digunakan antara lain: $-\infty < w < \infty$, $-5 \leq w \leq 5$, $-3 \leq w \leq 3$, dan $-1 \leq w \leq 1$. Masing-masing batas tersebut akan digunakan untuk ke-6 model jaringan yang sudah dibuat sebelumnya, dengan prosedur sebagai berikut:

1. Inisialisai Bobot Awal

Inisialisasi bobot awal dilakukan sebelum dilakukannya proses iterasi pertama kali, jadi inisialisasi bobot awal dilakukan pada iterasi ke-0. Bobot awal yang dipakai diperoleh dari membangkitkan bilangan random dengan banyaknya bilangan random sesuai dengan jumlah bobot yang ada dalam jaringan, dipilih model dengan Y_{t-1} dan Y_{t-2} sebagai variabel input dan jumlah *hidden nodes* sebanyak 5 dengan interval pembangkitan bilangan random antara -1 dan 1 sebagai ilustrasinya. Maka untuk bobot awal dibangkitkan bilangan random sebanyak 21 sebagai berikut:

Tabel 1. Bobot Awal (w_0)

Bobot	Keterangan
0,0994	input Y_{t-1} ke hidden layer 1
0,7383	input Y_{t-2} ke hidden layer 1
0,2821	input Y_{t-1} ke hidden layer 2
0,1202	input Y_{t-2} ke hidden layer 2
0,8342	input Y_{t-1} ke hidden layer 3
0,7642	input Y_{t-2} ke hidden layer 3
0,7657	input Y_{t-1} ke hidden layer 4
0,0948	input Y_{t-2} ke hidden layer 4
0,7107	input Y_{t-1} ke hidden layer 5
0,4631	input Y_{t-2} ke hidden layer 5
0,0942	hidden layer 1 ke output
0,5846	hidden layer 2 ke output
0,8208	hidden layer 3 ke output
0,1455	hidden layer 4 ke output
0,8669	hidden layer 5 ke output
0,9696	bias ke hidden layer 1
0,0956	bias ke hidden layer 2
0,3879	bias ke hidden layer 3
0,7694	bias ke hidden layer 4
0,2949	bias ke hidden layer 5
0,8759	bias ke output

Setelah diperoleh bobot awal selanjutnya adalah menghitung output jaringan untuk menghitung nilai erornya, ilustrasi perhitungan output jaringan dari model yang digunakan sebagai berikut:

$$\hat{Y}_t = \psi_0 \left\{ b w_{b0} + \sum_{j=1}^m w_j \psi_1 \left(b w_{bj} + \sum_{i=1}^n w_{ij} x_{it} \right) \right\}$$

$$z_t(j) = \left(b w_{bj} + \sum_{i=1}^n w_{ij} x_{it} \right)$$

$$z_1(1) = 1 \times 0,9696 + [(0,0994 \times 0,6212) + (0,7383 \times 0,6897)]$$

$$z_1(1) = 1,540583$$

$$z_1(2) = 1 \times 0,0956 + [(0,2821 \times 0,6212) + (0,1202 \times 0,6897)]$$

$$z_1(2) = 0,353756$$

$$z_1(3) = 1 \times 0,3879 + [(0,8342 \times 0,6212) + (0,7642 \times 0,6897)]$$

$$z_1(3) = 1,43323$$

$$z_1(4) = 1 \times 0,7694 + [(0,7657 \times 0,6212) + (0,0948 \times 0,6897)]$$

$$z_1(4) = 1,310466$$

$$z_1(5) = 1 \times 0,2949 + [(0,7107 \times 0,6212) + (0,4631 \times 0,6897)]$$

$$z_1(5) = 1,055828$$

$$\hat{Y}_t = \psi_0 \{ b w_{b0} + \sum_{j=1}^m w_j \psi_1(z_t(j)) \}$$

$$\hat{Y}'_1 = 0,8759 + \left[\frac{0,0942}{1 + \exp(-1,540583)} + \frac{0,5846}{1 + \exp(-0,353756)} + \frac{0,8208}{1 + \exp(-1,43323)} + \frac{0,1455}{1 + \exp(-1,310466)} + \frac{0,8669}{1 + \exp(-1,055828)} \right]$$

$$\hat{Y}'_1 = 2,717406$$

Perhitungan tersebut dilakukan hingga diperoleh nilai \hat{Y}_{775} , kemudian dihitung nilai MAE sebagai $f(x)$ sebagai berikut:

$$MAE = \frac{1}{n} \sum_{t=1}^n |\hat{Y}_t - Y_t|$$

$$MAE = \frac{1}{775} \sum_{t=1}^{775} |\hat{Y}'_t - Y_t|$$

$$MAE = \frac{1}{775} (|2,717406 - 0,5670| + |2,6874 - 0,5251| + \dots + |2,8630 - 0,9971|)$$

$$MAE = 2,0904$$

2. Menetapkan suhu awal

Suhu awal pada proses ASA adalah suhu buatan yang dimisalkan sebagai suhu akhir proses pemanasan pada proses pengkristalan. Penetapan suhu awal berfungsi sebagai acuan dalam menentukan suhu pada proses iterasi selanjutnya dalam proses ASA, sampai saat ini belum ada ketentuan berapa suhu pada proses ASA sehingga pada tugas akhir ini digunakan suhu awal sebesar 100 sesuai dengan *default* dari program matlab.

3. Inisialisai Bobot Baru

Inisialisasi bobot baru dilakukan pada saat iterasi pertama, inisialisasi bobot baru bertujuan untuk memperoleh bobot yang lebih optimal dengan membangkitkan bobot secara random dengan batas sesuai peneliti, sesuai dengan kasus yang diilustrasikan maka digunakan batas antara -1 dan 1. Setelah diperoleh bobot baru selanjutnya adalah menghitung kembali output jaringan untuk menghitung nilai error baru seperti perhitungan sebelumnya.

4. Menghitung Suhu Sistem

Setelah dilakukan penetapan suhu awal sebesar 100, pada iterasi yang akan berlangsung ke-k dibutuhkan variabel suhu pada iterasi tersebut supaya dapat dilakukan perhitungan peluang penerimaan pada tahap evaluasi bobot. Proses perhitungan suhu pada iterasi pertama diilustrasikan sebagai berikut:

$$T_k = \frac{T_0}{\ln(1+k)}$$

$$T_1 = \frac{100}{\ln(1+1)}$$

$$T_1 = 144,2695$$

5. Evaluasi Bobot

Evaluasi bobot merupakan tahap dimana bobot baru yang dibangkitkan akan dipertimbangkan apakah bobot tersebut akan menggantikan bobot awal yang sebelumnya digunakan sebagai bobot optimal. Dalam tugas akhir ini proses ASA yang dilakukan bertujuan untuk meminimalkan nilai MAE dari model jaringan syaraf tiruan, proses evaluasi yang dilakukan adalah sebagai berikut:

$$P[E_{i+1}] = \min\{1, e^{-\Delta E/cT}\}$$

$$e^{-\Delta E/cT} = \exp - \frac{f(x_{i+1}) - f(x_i)}{cT}$$

$$e^{-\Delta E/cT} = \exp - \frac{0,881478 - 2,0904}{1 \times 144,2695}$$

$$e^{-\Delta E/cT} = \exp - \frac{-1,20895}{144,2695}$$

$$e^{-\Delta E/cT} = 1,0084$$

$$P[E_{i+1}] = \min\{1, 1,0084\}$$

$$P[E_{i+1}] = 1$$

Berdasarkan hasil evaluasi diperoleh nilai peluang penerimaan sebesar 1, sehingga dapat disimpulkan bahwa bobot baru yang dibangkitkan akan dipakai sebagai bobot optimal. Langkah langkah sebelumnya terus diulangi sampai tercapai iterasi maksimal atau *stopping criteria* telah terpenuhi.

6. Proses *Testing*

Setelah langkah-langkah sebelumnya terus diulangi sampai tercapai iterasi maksimal atau ada *stopping criteria* yang terpenuhi, akan memberikan hasil bobot optimal. Bobot optimal dalam proses *training* akan digunakan sebagai bobot untuk melakukan proses *testing* dan pada proses testing akan dilakukan proses *post-processing* dan dihitung nilai MAPE-nya. Langkah perhitungan dalam tahap *post-processing* diilustrasikan sebagai berikut:

$$x'_t = \left(\frac{x_t - \min(x)}{\max(x) - \min(x)} \right)$$

$$x'_t = \left(\frac{x_t - \min(x)}{\max(x) - \min(x)} \right)$$

$$(\max(x) - \min(x)) \times x'_t = (x_t - \min(x))$$

$$[(\max(x) - \min(x)) \times x'_t] + \min(x) = x_t$$

$$x_{776} = [(71,34 - 60,52) \times 0,38787] + 60,52$$

$$x_{776} = 64,7168$$

Proses perhitungan dilanjutkan dengan langkah dan cara yang sama hingga diperoleh nilai $x_{861} = 70,5902$, kemudian dilanjutkan dengan menghitung nilai MAPE dengan ilustrasi perhitungan sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| 100\% \times \frac{\hat{Y}_t - Y_t}{Y_t} \right|$$

$$MAPE = \frac{100\%}{86} \left[\left| \frac{\hat{Y}_{776} - Y_{776}}{Y_{776}} \right| + \left| \frac{\hat{Y}_{777} - Y_{777}}{Y_{777}} \right| + \dots + \left| \frac{\hat{Y}_{861} - Y_{861}}{Y_{861}} \right| \right]$$

$$MAPE = \frac{100\%}{86} \left[\left| \frac{64,7168 - 65,86}{65,86} \right| + \left| \frac{65,4287 - 65,85}{65,85} \right| + \dots + \left| \frac{70,5902 - 70,66}{70,66} \right| \right]$$

$$MAPE = 2,0240 \%$$

4.5 Hasil Proses Training dan Testing

Tabel 2. Seleksi Model Terbaik

No.	Hidden Nodes	Input	Batas Bobot	Running Ke-	MAPE
1	5	Y_{t-1}	$-3 < w < 3$	3	1,0758
2	10	Y_{t-1}	$-1 < w < 1$	2	1,2691
3	5	Y_{t-2}	$-3 < w < 3$	4	1,4648
4	10	Y_{t-2}	$-3 < w < 3$	2	1,6849
5	5	Y_{t-1} dan Y_{t-2}	$-1 < w < 1$	3	1,0042
6	10	Y_{t-1} dan Y_{t-2}	$-1 < w < 1$	4	1,3364

Berdasarkan Tabel 2 dapat disimpulkan dari ke-6 model, yang memberikan nilai MAPE terkecil adalah pada model nomor 5 dengan arsitektur jaringan menggunakan Y_{t-1} dan Y_{t-2} sebagai variabel *input* dengan jumlah *hidden nodes* sebanyak 5 dan batas bobot antara -1 dan 1 yang diperoleh pada *running* program ke-4 dengan nilai MAPE sebesar 1,0042%.

4.6 Peramalan Harga Minyak Mentah Dunia

Berikut ini adalah perbandingan hasil antara *recursive forecasting*, *direct forecasting*, dan data harga minyak terbaru yang disajikan pada Tabel 12 berikut ini:

Tabel 3. Hasil Peramalan

t Langkah ke Depan	Hasil Permalan		Nilai Aktual
	Recursive	Direct	
1	70,49	70,49	70,97
2	70,31	72,96	72,43
3	70,18	71,06	72,10
4	70,09	71,12	73,95
5	70,04	71,57	74,44
6	70,00	71,13	74,40
7	69,97	72,88	74,20
8	69,95	72,89	75,47
9	69,94	72,46	75,18
10	69,93	72,51	76,75
MAPE	5,2200%	2,9268%	

Berdasarkan Tabel 12 Metode *direct forecasting* memberikan hasil peramalan yang lebih baik daripada *recursive forecasting* karena nilai MAPE-nya lebih kecil.

5. KESIMPULAN

Berdasarkan hasil analisis dan pembahasan pada bab sebelumnya, dapat diambil beberapa kesimpulan sebagai berikut:

1. Model terbaik harga minyak mentah dunia yang diperoleh adalah model FFNN (2-5-1) dengan Y_{t-1} dan Y_{t-2} sebagai variabel input dengan jumlah hidden nodes sebanyak 5 serta interval batas bobot $-1 \leq w \leq 1$.
2. Model Feed Forward Neural Network dengan algoritma Adaptive Simulated Annealing mampu memberikan hasil pemodelan dengan nilai eror yang kecil yaitu dengan nilai MAE sebesar 0,039 dan mampu memberikan model dengan kemampuan peramalan yang sangat baik dengan MAPE 1,0042%.
3. Proses iterasi algoritma Adaptive Simulated Annealing dengan model Feed Forward Neural Network memberikan hasil yang lebih baik dengan jumlah iterasi maksimal sama ketika diberikan batas bobot dengan interval tertentu daripada tidak diberikan batas bobot pada proses iterasinya.
4. Metode direct forecasting memberikan hasil peramalan yang lebih baik daripada recursive forecasting, karena pada hasil peramalan dengan metode direct forecasting menghasilkan nilai MAPE yang lebih kecil.
5. Hasil peramalan harga minyak mentah dunia (USD/Barrel) periode 4 Mei 2018 sampai 13 Mei 2018 dengan metode direct forecasting yaitu: 70,49; 72,96; 71,06; 71,12; 71,57; 71,13; 72,88; 72,89; 72,46; dan 72,51.

DAFTAR PUSTAKA

- Adewole, A.P., Otubamowo, K., & Egunjobi, T.O. 2012. A Comparative Study of Simulated Annealing and Genetic Algorithm for Solving the Travelling Salesman Problem. *International Journal of Applied Information Systems (IJ AIS)*. Vol.4, No.4.
- Ahmed, A. & Khalid, M. 2017. Multi-step Ahead Wind Forecast Using Nonlinear Autoregressive Neural Network. *Energy Procedia*. Vol.134, 192-204
- Cryer, J.D. & Chan, K. 2008. *Time Series Analysis with Application in R*. Springer. USA.
- Dewan Energi Nasional. 2016. *Outlook Energi Indonesia 2016*. Jakarta Selatan.
- Doreswamy & Vastrad, C.M. 2013. Performance of Analysis of Neural Network Models for Oxazolines and Derivatives Descriptor Dataset. *International Journal of Information Sciences and Techniques (IJIST)*. Vol.3, No.6.
- Fausett, L. 1994. *Fundamental of Neural Network*. Prentice Hall. New Jersey.
- Haykin, S. 2009, *Neural Network and Learning Machines*. Third Edition. Pearson Education. New Jersey.
- Hyndman, R.J. & Koehler, A.B. 2006. Another Look at Measures of Forecast Accuracy. *International Journal of Forecasting*, Vol.22, No.4, 679-688.
- Kusumadewi, S. 2003. *Artificial Intelligent (Teknik dan Aplikasinya)*. Graha Ilmu. Yogyakarta.
- Mousavi, S.M., Mostavi, E.S., & Jiao, P. 2017. Next Prediction Model for Daily Solar Radiation On Horizontal Surface Using a Hybrid Neural Network and Simulated Annealing Method. *Energy Conversion and Management*. Vol. 153, 671-682.
- Patro, S.G. & Sahu, K.K. (2015). Normalization: A Preprocessing Stage. *IARJSET*. 10.17148/IARJSET.2015.2305.
- Rao, S.S. 2009. *Engineering Optimization: Theory and Practice*. John Wiley & Sons, Inc. Hoboken. New Jersey.
- Szu, H. 1987. Fast Simulated Annealing. *Physics Letter A*. Vol.122, Issue 3-4, 157-162
- Warsito, B. 2009. *Kapita Selektta Statisitka Neural Network*. BP Universitas Diponegoro. Semarang.
- Wei, W.W.S. 1994. *Time Series Analysis: Univariate and Multivariate Methods*. Adison-Wesley Publishing Company Inc. Kanada.
- Anonim. 17 Agustus 2017. 2017. *HUTRI ke-72 Jadi Momentum Untuk Raih Kemerdekaan Energi*. Kementerian Energi dan Sumber Daya Mineral Republik Indonesia. Diakses 25 Oktober 2017. <https://www.esdm.go.id/id/berita-unit/direktorat-jenderal-ebtke/hut-ri-ke-72-jadi-momentum-untuk-raih-kemerdekaan-energie>.