



PERAMALAN PENGGUNAAN BAHAN BAKAR PADA PEMBANGKIT LISTRIK TENAGA GAS UAP MENGUNAKAN METODE *BACKPROPAGATION* *NEURAL NETWORK*

EMI FATCHURIN¹, ARIS FANANI², M. HAFIYUSHOLEH³

^{1,2,3}Universitas Islam Negeri Sunan Ampel Surabaya

emyfatchurin05@gmail.com

ABSTRAK

Bahan bakar merupakan komponen utama dalam pembangkitan energi listrik. Penggunaan bahan bakar yang efektif dan efisien tentu saja disesuaikan dengan kebutuhan beban yang diminta sehingga tidak ada energi yang terbuang dan tidak akan terjadi kekurangan bahan bakar dalam proses pembangkitan. Kekurangan bahan bakar dapat mengakibatkan pembangkit listrik tidak beroperasi sementara. Untuk itu dibutuhkan suatu perencanaan yang baik dengan melakukan prediksi terhadap penggunaan bahan bakar gas yang akan digunakan pada periode mendatang. Dengan kata lain, mengoptimalkan pemakaian dan pemesanan bahan bakar pada unit pembangkit dilakukan agar tercipta manajemen sumberdaya energi yang efektif dan efisien. Penelitian ini bertujuan untuk memprediksi dan mempersiapkan bahan bakar, biaya yang dibutuhkan untuk proses pembangkitan, serta menentukan tingkat akurasi pembangkit listrik dengan menggunakan metode *backpropagation neural network*. Hasil Prediksi penggunaan bahan bakar gas Unit PLTGU PT. PJB Unit Pembangkitan Gresik pada minggu ke-1 bulan Oktober yaitu sebesar 24.814 KNm³/h sehingga biaya yang dibutuhkan untuk keperluan bahan bakar gas yaitu sebesar Rp 92.695.620.617 dengan MAPE sebesar 15,0825%. Hal tersebut menunjukkan bahwa model yang dibangun oleh jaringan *backpropagation* termasuk ke dalam kategori baik dalam memprediksi karena nilai *error* berada diantara 10-20% dan akurasinya sebesar 84,9175%. Arsitektur jaringan *Backpropagation* yang paling optimal yaitu dengan menggunakan 1 *hidden layer* dengan 9 *node*, *momentum* 0,9 dan *learning rate* 0,01.

Kata Kunci: Peramalan, Bahan Bakar Gas, PT. PJB UP Gresik, *Backpropagation Neural Network*

ABSTRACT

Fuel is the main component in generating electrical energy. The use of effective and efficient fuel is of course adjusted to the required load requirements so that no energy is wasted and there will be no shortage of fuel in the generation process. Lack of fuel can cause the power plant to temporarily not operating. For that, we need good planning by predicting the use of natural gas that will be used in the coming period. In other words, optimizing the use and ordering of fuel in the generating unit is done to create an effective and efficient energy resource management. This study aims to predict and prepare the fuel, the costs required for the generation process, and to determine the level of accuracy of the electricity generator using the *backpropagation neural network* method. Prediction Results of the use of gas fuel from the PLTGU Unit of PT. PJB of the Gresik Generation Unit in the 1st week of October is 24,814 KNm³ / h, so the cost needed for gas fuel is IDR 92,695,620,617 with a MAPE of 15.0825%. This shows that the

model built by the backpropagation network is included in the good category in predicting because the error value is between 10-20% and the accuracy is 84.9175%. The most optimal Backpropagation network architecture is by using 1 hidden layer with 9 nodes, momentum 0.9 and learning rate 0.01.

Keywords: Forecasting, Gas Fuel, PT. PJB UP Gresik, Backpropagation Neural Network

1 Pendahuluan

Energi listrik memiliki peran yang sangat penting dalam kehidupan masyarakat sebagai penunjang segala aktivitasnya. Seiring dengan pertumbuhan penduduk Indonesia yang berkembang pesat serta perkembangan teknologi, industri dan pendidikan yang semakin meningkat, maka kebutuhan akan energi listrik pun juga semakin meningkat. Aktivitas rumah tangga dan sektor industri sangat bergantung pada energi listrik, sehingga kebutuhan akan energi listrik harus dipenuhi selama 24 jam, Firdaus[1]. Untuk memenuhi permintaan kebutuhan listrik sebagaimana yang dinyatakan oleh Tarigan[2], maka pemerintah membangun salah satu perusahaan BUMN sebagai penyedia jasa kebutuhan energi listrik yang ada di Indonesia yaitu PT. PLN (Persero). PT. PLN memiliki dua anak perusahaan yaitu Pembangkit Jawa-Bali (PJB) dan Indonesia Power (IP). Dua perusahaan inilah yang menghasilkan energi listrik untuk disalurkan ke seluruh penjuru Indonesia.

Dalam pembangkitan energi listrik diperlukan bahan bakar yang memadai. Bahan bakar merupakan komponen utama dalam pembangkitan energi listrik. Penggunaan bahan bakar yang efektif dan efisien disesuaikan dengan kebutuhan permintaan beban sehingga tidak ada energi yang terbuang ataupun kurangnya bahan bakar dalam pembangkit listrik. Prediksi terhadap penggunaan bahan bakar sangat diperlukan untuk mempersiapkan kebutuhan bahan bakar pada periode yang akan datang serta meminimalisir terjadinya kerugian bagi pihak perusahaan maupun konsumen, Baskoro[3]. Hal ini mengingat adanya kekurangan bahan bakar yang tersedia dapat berakibat terhentinya proses pembangkitan yang sedang berlangsung. Selain itu, persediaan bahan bakar yang relatif kecil akan mengakibatkan frekuensi pembelian bahan bakar menjadi lebih sering sehingga biaya pemesanan bahan bakar untuk proses pembangkitan menjadi lebih besar, Amri[4]. Oleh karenanya, prediksi penggunaan bahan bakar gas untuk sistem pembelanjaan diperlukan agar biaya produksi seimbang dengan harga jual daya listrik yang dibangkitkan.

Beberapa metode yang dapat digunakan untuk melakukan prediksi antara lain: *adaptive neuro fuzzy inference system* (ANFIS) oleh Azizah[5], Ata dan Kocyigit[6], Khasanah[7], *FTS-Markov Chain* oleh Amalutfia dan Hafiyusholeh[8], logika *fuzzy* oleh Effendi[9], Jaringan Syaraf Tiruan *Backpropagation* oleh Adnyana[10], neural network [11] dan lain sebagainya. Kelebihan dari jaringan syaraf tiruan terletak pada kemampuan belajar yang dimilikinya. Dengan kemampuan tersebut, pengguna tidak perlu merumuskan kaidah atau fungsinya. Jaringan syaraf tiruan akan belajar mencari kaidah atau fungsinya sendiri sehingga jaringan syaraf tiruan mampu digunakan untuk menyelesaikan masalah yang rumit. Metode backpropagation melatih jaringan untuk mendapatkan keseimbangan antara kemampuan jaringan untuk mengenali pola yang digunakan selama pelatihan serta kemampuan jaringan untuk memberikan respon yang benar terhadap pola masukan yang serupa dengan pola yang dipakai selama pelatihan. Jaringan syaraf tiruan backpropagation merupakan metode yang paling sederhana dan mempunyai konsep belajar yang mudah dipahami dibandingkan dengan metode-metode jaringan syaraf tiruan yang lain, Tindriyani[12].

Berdasarkan penelitian sebelumnya, diketahui bahwa jaringan syaraf tiruan menggunakan metode *backpropagation* menghasilkan tingkat akurasi yang cukup tinggi sehingga sangat tepat digunakan untuk melakukan prediksi. Oleh karena itu pada penelitian kali ini akan dilakukan peramalan penggunaan bahan bakar gas metode jaringan syaraf tiruan

dengan judul penelitian “Peramalan Penggunaan Bahan Bakar Pada Pembangkit Listrik Tenaga Gas Uap Menggunakan Metode *Backpropagation Neural Network* (Studi Kasus: PT. Pembangkitan Jawa Bali Unit Pembangkitan Gresik).

2 Tinjauan Pustaka

2.1 Pembangkit Listrik Tenaga Gas Uap

PLTGU merupakan suatu instalasi peralatan yang berfungsi untuk mengubah energi panas menjadi energi listrik. Pada dasarnya, PLTGU merupakan sistem yang menggabungkan prinsip kerja PLTG dan PLTU dengan siklus ganda (*combined cycle*). Peralatan utamanya terdiri dari *gas turbine*, HRSG (*Heat Recovery Steam Generator*), *steam turbine*, generator dan alat pendukung lainnya. Pada PLTGU, energi hasil pembakaran bahan bakar digunakan untuk menggerakkan turbin gas yang digandeng satu poros dengan generator. Sisa hasil gas buang dari gas turbine dimanfaatkan untuk memanaskan air pada pipa-pipa yang terdapat di HRSG sehingga berubah menjadi uap. Uap yang dihasilkan di HRSG digunakan untuk menggerakkan steam turbine. Energi mekanik dari turbin digunakan untuk memutar generator sehingga menghasilkan energi listrik yang selanjutnya diparalelkan dengan jaringan interkoneksi Jawa Bali, Tarigan[2].

2.2 Peramalan

Peramalan yaitu dugaan atau proses memperkirakan kejadian di masa mendatang. Peramalan memberikan suatu kejadian yang belum pasti tentang apa yang akan terjadi di masa mendatang, namun peramalan dapat digunakan sebagai acuan agar dapat memperkecil suatu kesalahan, Kurniawan[13].

2.3 Metode *Backpropagation*

Backpropagation merupakan salah satu algoritma pembelajaran yang paling umum digunakan dalam jaringan syaraf tiruan. Metode ini melatih jaringan untuk mendapatkan keseimbangan antara kemampuan jaringan dalam mengenali pola selama proses pelatihan serta memberikan respon yang benar terhadap pola masukan yang serupa namun tidak sama dengan pola yang dipakai selama pelatihan. Algoritma yang digunakan dalam *backpropagation* yaitu pembelajaran terawasi dan banyak lapisan pada perceptron, Rufiyanti[14]. *Backpropagation* bekerja melalui proses iteratif dengan menggunakan sekumpulan data latih lalu membandingkan nilai prediksi dari jaringan yang telah dibangun dengan nilai sesungguhnya. *Backpropagation* melakukan proses pembelajaran dengan menggunakan pola penyesuaian bobot dari arsitektur jaringan syaraf tiruan dengan arah mundur untuk mencapai nilai kesalahan yang minimum antara nilai keluaran hasil prediksi dengan nilai keluaran yang sesungguhnya, Andrijasa dan Mistianingsih[15].

Fungsi aktivasi merupakan penentu diteruskan atau tidaknya sinyal dari *input neuron*. Dalam *backpropagation*, fungsi aktivasi yang digunakan harus memenuhi beberapa syarat yaitu kontinu, terdiferensial dengan mudah dan fungsi tersebut merupakan fungsi tidak turun. Terdapat beberapa fungsi aktivasi yang sering digunakan dalam jaringan syaraf tiruan, Rufiyanti[14], yaitu

1. Fungsi Sigmoid Biner

Fungsi sigmoid biner memiliki range 0 sampai 1. Fungsi ini sering digunakan pada jaringan syaraf yang nilai output terletak antara interval 0 sampai 1, Rufiyanti[14]. Fungsi ini dirumuskan seperti pada Persamaan (1) dan (2) berikut:

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

dengan turunan,

$$f'(x) = f(x)[1 - f(x)] \quad (2)$$

Pelatihan pada algoritma *Backpropagation* terdiri dari tiga tahap yaitu:

1. Langkah 1: Inisialisasi nilai bobot awal dengan nilai random yang kecil.
2. Fase 1 : Propagasi maju (*feedforward*)

Langkah 2: Hitung semua keluaran

Untuk mendapatkan nilai unit pada *output layer*, perhitungan dilakukan dari lapisan ke lapisan.

a) Pada *hidden layer*

Rumus untuk mencari keluaran unit tersembunyi pada *hidden layer* z_j ($j= 1,2,3,\dots,p$) ditunjukkan pada Persamaan (3) dan (4).

$$z_{net\ j} = v_{j0} + \sum_{i=1}^n x_i v_{ji} \quad (3)$$

$$z_j = f(z_{net\ j}) \quad (4)$$

keterangan:

v_{j0} : bobot bias dari input layer ke hidden layer ($j = 1, 2, 3, \dots, p$)

x_i : unit masukan ke- i ($i = 1, 2, 3, \dots, n$)

v_{ji} : bobot unit masukan pada input layer ke hidden layer

z_j : unit keluaran ke- j pada hidden layer ($j = 1, 2, 3, \dots, p$)

$f(z_{net\ j})$: fungsi aktivasi

b) Pada *output layer*

Hitung semua unit keluaran di *output layer* y_k ($k = 1,2,\dots,m$) dengan menggunakan rumus pada Persamaan (5) dan (6).

$$y_{net\ k} = w_{k0} + \sum_{j=1}^p z_j w_{kj} \quad (5)$$

$$y_k = f(y_{net\ k}) \quad (6)$$

keterangan:

w_{k0} : bobot bias dari hidden layer ke output layer

z_j : unit keluaran ke- j pada hidden layer ($j = 1, 2, 3, \dots, p$)

w_{kj} : bobot unit masukan pada input layer ke hidden layer

y_k : unit keluaran pada hidden layer

$f(y_{net\ k})$: fungsi aktivasi

3. Fase 2 : Propagasi mundur

Langkah 3: Hitung perubahan pada bobot

Untuk menghitung perubahan pada bobot, vektor output pada tiap-tiap lapisan dibandingkan dengan nilai *output(target)* yang diharapkan.

a) Pada *output layer*

Hitung faktor δ unit keluaran berdasarkan keluaran pada setiap unit keluaran y_k ($k = 1,2,\dots,m$) dengan menggunakan rumus pada Persamaan (7).

$$\delta_k = (t_k - y_k)y_k(1 - y_k) \quad (7)$$

keterangan:

δ_k : unit kesalahan ke- k

t_k : nilai asli target ke- k

y_k : unit keluaran ke- k

Hitung suku perubahan bobot w_{kj} (yang akan digunakan untuk merubah bobot w_{kj}) dengan laju pembelajaran α menggunakan rumus pada Persamaan (8).

$$\Delta w_{kj} = \alpha \delta_k z_j; (k = 1, 2, \dots, m); j = (0, 1, \dots, p) \quad (8)$$

keterangan:

Δw_{kj} : suku perubahan bobot w_{kj}

α : laju pembelajaran

δ_k : unit kesalahan ke-k

z_j : unit keluaran ke-j pada hidden layer $j = (1, 2, \dots, p)$

b) Pada hidden layer

Hitung faktor δ unit tersembunyi berdasarkan pada nilai error menggunakan rumus pada Persamaan (9).

$$\delta_{net j} = \sum_{k=1}^m \delta_k w_{kj} \quad (9)$$

Faktor δ unit tersembunyi dapat dicari menggunakan Persamaan (10).

$$\delta_j = \delta_{net j} f'(z_{net j}) = \delta_{net j} z_j (1 - z_j) \quad (10)$$

Hitung suku perubahan bobot v_{ji} (yang akan digunakan untuk merubah bobot v_{ji}) dengan laju pembelajaran α menggunakan rumus pada Persamaan (11).

$$\Delta v_{ji} = \alpha \delta_j x_i; (j = 1, 2, \dots, p); i = (0, 1, \dots, n) \quad (11)$$

4. Fase 2 : Perubahan bobot

Langkah 4: Hitung semua perubahan nilai bobot

a) Pada *output layer*

Perubahan nilai bobot yang menuju unit keluaran dapat dihitung menggunakan rumus pada Persamaan (12).

$$w_{kj}(\text{baru}) = w_{kj}(\text{lama}) + \Delta w_{kj}; (k = 1, 2, \dots, m); (j = 0, 1, \dots, p) \quad (12)$$

b) Pada *hidden layer*

Perubahan bobot yang menuju ke unit tersembunyi dapat dihitung menggunakan rumus pada Persamaan (13).

$$v_{ji}(\text{baru}) = v_{ji}(\text{lama}) + \Delta v_{ji}; (j = 1, 2, \dots, p); (i = 0, 1, \dots, n) \quad (13)$$

Setelah tahap pelatihan selesai, tahap selanjutnya yaitu tahap pengujian. pada tahap ini, langkah yang dilakukan hanya sampai pada fase 1 saja yaitu propagasi maju. seluruh bobot masukan diambil dari nilai bobot terakhir dari tahap pelatihan. pada tahap pengujian jaringan diharapkan dapat mengenali pola berdasarkan data baru yang diberikan, Rufiyanti[14].

2.4 Momentum

Pada standar *backpropagation*, perubahan bobot didasarkan atas gradien yang terjadi untuk pola yang dimasukkan pada saat itu. Modifikasi yang dapat dilakukan adalah menggunakan momentum, yaitu dengan melakukan perubahan bobot yang didasarkan atas arah gradien pola terakhir dan pola sebelumnya yang dimasukkan. Penambahan momentum dimaksudkan untuk menghindari perubahan bobot yang mencolok yang diakibatkan oleh adanya data yang sangat berbeda dengan data lainnya. Variabel momentum dapat

meningkatkan waktu pelatihan dan stabilitas dari proses pelatihan. Dengan penambahan momentum, bobot baru pada waktu ke $(t + 1)$ didasarkan atas bobot pada waktu t dan $(t - 1)$, Rufiyanti[14]. Jika μ adalah konstanta ($0 \leq \mu \leq 1$) yang menyatakan parameter momentum, maka bobot baru dihitung berdasarkan persamaan (14) dan (15) berikut:

$$\begin{aligned} w_{kj}(t + 1) &= w_{kj}(t) + \alpha \delta_k z_j + \mu(w_{kj}(t) - w_{kj}(t - 1)) \\ w_{kj}(t + 1) &= w_{kj}(t) + \Delta w_{kj} + \mu(w_{kj}(t) - w_{kj}(t - 1)) \end{aligned} \quad (14)$$

$$\begin{aligned} v_{ji}(t + 1) &= v_{ji}(t) + \alpha \delta_j x_i + \mu(v_{ji}(t) - v_{ji}(t - 1)) \\ v_{ji}(t + 1) &= v_{ji}(t) + \Delta v_{ji} + \mu(v_{ji}(t) - v_{ji}(t - 1)) \end{aligned} \quad (15)$$

keterangan:

- $w_{kj}(t)$: bobot mula-mula pola kedua dari hidden ke output
- $\alpha \delta_k z_j$: hasil dari perhitungan Δw_{kj}
- $w_{kj}(t - 1)$: bobot mula-mula pada data ke-1 iterasi pertama
- μ : momentum
- $v_{ji}(t)$: bobot mula-mula pola kedua dari input ke output
- $\alpha \delta_j x_i$: hasil dari perhitungan Δv_{ji}
- $v_{ji}(t - 1)$: bobot mula-mula pada data ke-1 iterasi pertama

2.5 Mean Squared Error (MSE)

Mean Squared Error merupakan suatu metode untuk menghitung nilai kesalahan berdasarkan pada data-data kesalahan yang dikuadratkan atau untuk membandingkan data aktual dengan hasil peramalan JST, Habibi dan Riksakomara[16]. Perhitungan MSE dihitung dengan menggunakan rumus pada Persamaan (16) sebagai berikut:

$$MSE = \frac{1}{n} \sum_{t=1}^n (A_t - F_t)^2 \quad (16)$$

Dengan n menyatakan banyaknya data, A_t nilai asli target ke- t , dan F_t menyatakan nilai peramalan data ke- t .

2.6 Mean Absolute Error (MAPE)

Untuk mendapatkan peramalan yang akurat, perlu dilakukan evaluasi terhadap hasil peramalan. Salah satu metode evaluasi yang digunakan adalah dengan melihat nilai MAPE. Nilai MAPE didapatkan dengan cara membagi hasil kesalahan absolut dengan nilai observasi pada setiap periode. Hasil peramalan dikatakan semakin akurat jika nilai MAPE semakin kecil, Habibi dan Riksakomara[16]. Dihitung dengan menggunakan rumus pada Persamaan (17).

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \times 100\% \quad (17)$$

Tabel 1: Kriteria MAPE

MAPE	Kategori Kemampuan Prediksi
<10%	Sangat baik
10% - 20%	Baik
20% - 50%	Cukup baik

>50%	Buruk
------	-------


3 Metode penelitian

Data yang digunakan merupakan data mingguan penggunaan bahan bakar gas pada gas turbine PLTGU blok 1 dari tahun 2015 sampai tahun 2019 dalam satuan KNm³/h (*Kilo Normal Cubic Metric Per Hour*). Data berjumlah 208 data yang merupakan data aliran bahan bakar selama 208 minggu mulai minggu pertama pada bulan Oktober 2015 hingga minggu terakhir pada bulan September 2019. Data tersebut dibagi untuk data pelatihan (*training*) dan pengujian (*testing*). Data yang digunakan sebagai data *training* sebanyak 80% dan *data testing* sebanyak 20%. Data latih yang digunakan sebanyak 167 data dan 41 data digunakan untuk data uji.

Pada penelitian ini digunakan fungsi aktivasi *sigmoid biner*. Data yang akan digunakan pada tahap latih (*training*) dan tahap uji (*testing*) harus dinormalisasikan agar keluaran jaringan sesuai dengan fungsi aktivasi yang digunakan atau memiliki nilai serupa dengan *sigmoid biner* yaitu antara 0 sampai 1. Fungsi *sigmoid biner* adalah fungsi asimtotik (tidak pernah mencapai 0 ataupun 1), maka transformasi data hendaknya dilakukan pada interval yang lebih kecil yaitu [0.1, 0.9]. Normalisasi bertujuan agar jaringan tidak mengalami kegagalan ketika melakukan pelatihan dan pengujian dengan menggunakan rumus pada persamaan (18) berikut:

$$x' = \frac{0,8(x - b)}{(a - b)} + 0,1 \quad (18)$$

Momentum (μ) merupakan perubahan bobot baru yang dipengaruhi oleh bobot sebelumnya. Besarnya momentum yaitu antara 0 sampai 1. Jika besar momentum = 0, maka perubahan bobot hanya dipengaruhi oleh gradien. Sedangkan jika besar momentum = 1 maka perubahan bobot akan sama dengan perubahan bobot sebelumnya. Semakin besar learning rate (α) yang digunakan maka akan semakin besar langkah pembelajaran.



Gambar 1: Arsitektur jaringan

Gambar 1 merupakan arsitektur jaringan dengan 12 *node* pada *input layer*, 9 *node* pada *hidden layer*, dan 1 *node* pada *output layer*. *Input* ($x_1, x_2, x_3, \dots, x_{12}$) yang digunakan yaitu data mingguan penggunaan bahan bakar gas pada PLTGU. Untuk perhitungan pertama, data pada minggu ke-1 sampai minggu ke-12 dijadikan sebagai data input dan data ke-13 sebagai data target. Untuk perhitungan selanjutnya, data ke-2 sampai data ke-13 dijadikan sebagai data input dan data ke-14 sebagai data target. Begitupun seterusnya.

Arsitektur jaringan yang digunakan pada penelitian ini yaitu 1 *input layer* dengan 12 *node*, 1 *hidden layer* dengan 9, 12, 15 dan 25 *node*, dan 1 *output layer* dengan 1 *node*. Hal

lain yang ditentukan oleh penulis pada tahap *backpropagation* adalah *learning rate* untuk setiap jaringan dimana dilakukan percobaan dengan nilai 0,01 dan 0,05 dan momentum dengan nilai 0,9 dan 0,8 dengan batas *error* 0,0001. Setelah mendapatkan hasil peramalan, maka data harus di denormalisasikan untuk mengembalikan nilai asli dari peramalan tersebut dengan menggunakan rumus pada Persamaan (19).

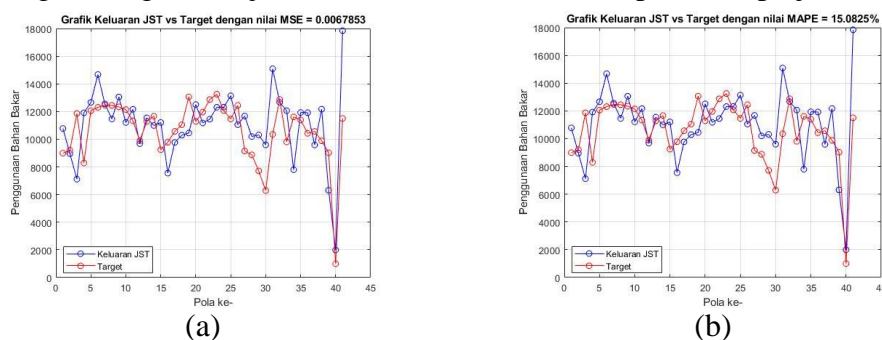
$$x = \frac{(x' - 0,1)(a - b)}{0,8} + b \quad (19)$$

Untuk menghitung biaya konsumsi bahan bakar gas pada PLTGU Blok 1 PT. PJB Unit Pembangkitan Gresik digunakan hasil prediksi konsumsi bahan bakar gas dalam satuan *Milion Standard Cubic Feet* (MMSCF) diubah kedalam satuan *Milion British Thermal Unit* (MMBTU). *Milion British Thermal Unit* (MMBTU) didapatkan dari *Milion Standard Cubic Feet* (MMSCF) dikalikan dengan *Gross Heating Value*(GHV). Fix GHV = 1050 BTU/SCF. Biaya konsumsi bahan bakar gas diperoleh dari data aliran bahan bakar gas dalam satuan *Milion British Thermal Unit* (MMBTU) dikalikan dengan harga bahan bakar gas dengan asumsi US\$ 7 dan dikalikan dengan kurs *dollar* yang berlaku saat ini US\$ 1 = Rp 13616,88,-.

4 Hasil dan Pembahasan

Dalam jaringan syaraf tiruan, proses peramalan menggunakan data *time series* yang pertama dilakukan adalah menentukan jumlah *neuron input* jaringan, parameter pembelajaran, serta data latih yang berupa data *input* pelatihan dan target pelatihan yang digunakan pada saat proses pelatihan. Setelah proses pelatihan selesai hingga mencapai toleransi *error* yang ditentukan maka didapat bobot dan bias optimal yang kemudian digunakan sebagai bobot dalam pengujian. Pada proses pengujian, langka yang dilakukan hanya pada fase 1 saja yaitu propagasi maju. Seluruh bobot masukan diambil dari bobot terakhir pada tahap pelatihan. Jaringan melakukan perhitungan terhadap data pengujian yang terdiri dari data *input* pengujian dan data target pengujian dengan arsitektur jaringan dan parameter yang sama saat pelatihan.

Hasil yang diperoleh pada tahap pengujian ditampilkan pada Gambar 2 menunjukkan grafik perbandingan nilai keluaran JST dengan nilai target yang sesungguhnya. Pada bagian (a) dan (b) masing-masing menunjukkan nilai MSE dan MAPE pada tahap uji sebagai berikut:



Gambar 2: Hasil pengujian dengan momentum 0,9 dan *learning rate* 0,01

Gambar 2 menampilkan hasil pengujian yang diperoleh dari 9 *node* pada *hidden layer*, dengan momentum 0,9 dan *learning rate* 0,01. Hasil MSE yang dipetoleh sebesar 0,0067853 dan MAPE sebesar 15,0825%.

Hasil yang diperoleh dari pemrograman menggunakan metode *backpropagation neural network* mendapatkan MSE dan MAPE pada tahap uji dengan percobaan banyaknya *node* pada *hidden layer*, momentum dan nilai *learning rate* ditunjukkan pada Tabel 2 sebagai berikut:

Tabel 2: Hasil percobaan

No	Hidden layer	Momentum	Learning rate	MSE uji	MAPE uji
1	1 hidden layer dengan 9 node	0,9	0,01	0,0067853	15,0825%
2		0,9	0,05	0,0061513	18,6608%
3		0,8	0,01	0,0093315	19,1083%
4		0,8	0,05	0,0069094	19,6915%
5	1 hidden layer dengan 12 node	0,9	0,01	0,0064908	17,9615%
6		0,9	0,05	0,0097756	18,4945%
7		0,8	0,01	0,0071060	19,6221%
8		0,8	0,05	0,0059483	18,7761%
9	1 hidden layer dengan 15 node	0,9	0,01	0,0059174	18,0863%
10		0,9	0,05	0,0059828	18,4882%
11		0,8	0,01	0,0074827	19,4464%
12		0,8	0,05	0,0091083	19,9356%
13	1 hidden layer dengan 25 node	0,9	0,01	0,0084123	17,1721%
14		0,9	0,05	0,0058443	18,3351%
15		0,8	0,01	0,0065686	19,9342%
16		0,8	0,05	0,0055230	17,6972%

Dari tabel diatas dapat dilihat bahwa arsitektur jaringan *Backpropagation* yang paling optimal dalam peramalan penggunaan bahan bakar gas yaitu dengan menggunakan 1 *hidden layer* dengan 9 *node* dengan momentum 0,9 dan *learning rate* 0,01 dengan hasil MAPE uji paling rendah yaitu 15,0825%. Hasil MAPE menunjukkan bahwa model yang dibangun oleh jaringan *backpropagation* termasuk ke dalam kategori baik dalam kemampuan memprediksi karena nilai *error* berada diantara 10-20%. Untuk menghitung nilai akurasi, maka 100% - nilai MAPE, sehingga didapatkan nilai akurasi sebesar 84,9175%. Jaringan inilah yang layak digunakan untuk melakukan peramalan karena memiliki tingkat kesalahan atau MAPE paling rendah. Pada tahap peramalan, langkah yang digunakan sama seperti pada tahap pengujian yaitu hanya fase propagasi maju. Dengan menggunakan data input pada data ke 197 sampai data ke 208 untuk meramalkan data ke 209 atau data pada minggu ke-1 bulan Oktober 2019. Hasil peramalan yang diperoleh yaitu 24814 KNm³/h . Hal tersebut menunjukkan peramalan penggunaan bahan bakar gas pada minggu ke-1 bulan Oktober 2019 sebesar 24814KNm³/h dengan tingkat kesalahan 15, 0825%.

Biaya bahan bakar gas dihitung dengan mengubah satuan bahan bakar *Kilo Normal Cubic Metric Per Hour* (KNm³/h) kedalam satuan MMBTU U/h. 1KNm³ = 0, 0373248MMSCF. MMBTU didapat dari MMSCF dikalikan dengan *Gross Heating Value* (GHV). Fix GHV = 1050 BTU/SCF. Biaya penggunaan bahan bakar diperoleh dari aliran bahan bakar gas dalam satuan *Million British Thermal Unit Per Hour* (MMBTU/h) dikalikan dengan harga bahan bakar gas (7 US\$/MMBTU) kemudian dikalikan dengan harga kurs dolar yang berlaku saat ini (US\$ 1 = Rp 13616,88). Dari Hasil perhitungan biaya bahan bakar diperoleh biaya bahan bakar pada minggu ke-1 bulan Oktober 2019 yaitu sebesar Rp 92.695.620.617.

Hasil MSE ataupun MAPE tersebut walaupun secara numerik lebih besar dibandingkan dengan hasil yang diperoleh pada penelitian Khasanah[17] yang mendapatkan MAPE sebesar 10,418% dan kemampuan memprediksi dan akurasinya sebesar 89,582%, akan tetapi secara kategori memiliki level yang sama. Begitujuga jika dibandingkan dengan penelitian yang dilakukan oleh Rahman[18] yang menggunakan arsitektur jaringan 4 neuron input layer, 3 hidden layer, 1 output 7 layer dengan learning rate 0,4 dan iterasi maksimum 800, menghasilkan nilai MAPE sebesar 16,98%. Secara umum, metode *backpropagation neural network* dapat dikategorikan sebagai model yang baik untuk dipergunakan dalam proses prediksi.

5 Kesimpulan

Berdasarkan hasil peramalan penggunaan bahan bakar pada pembangkit listrik tenaga gas uap menggunakan metode *backpropagation neural network*, maka dapat disimpulkan bahwa: Hasil Prediksi penggunaan bahan bakar gas Unit PLTGU PT. PJB Unit Pembangkitan Gresik pada minggu ke-1 bulan Oktober yaitu sebesar 24.814 KNm³/h sehingga biaya yang dibutuhkan untuk keperluan bahan bakar gas yaitu sebesar Rp 92.695.620.617 dengan MAPE sebesar 15,0825%. Hal tersebut menunjukkan bahwa model yang dibangun oleh jaringan *backpropagation* termasuk ke dalam kategori baik dalam memprediksi karena nilai *error* berada diantara 10-20% dan akurasi sebesar 84,9175%. Arsitektur jaringan *Backpropagation* yang paling optimal yaitu dengan menggunakan 1 *hidden layer* dengan 9 *node*, *momentum* 0,9 dan *learning rate* 0,01.

Daftar Pustaka

- [1] M. Firdaus, "Penentuan Beban Optimal Pada Turbin Gas PLTGU Dengan Menggunakan Nonlinear Programming," Universitas Indonesia, Depok, 2010.
- [2] A. M. Tarigan, H. F. A. Ayjat, and N. Hasananto, "Monitoring Longterm Washing Kompresor Terhadap Efisiensi Kompresor Turbin Gas Block 1 PT. PJB UP Gresik," Malang, 2016.
- [3] D. R. Baskoro, "Peramalan Jangka Pendek Beban Tenaga Listrik Pada PT. PJB UP Gresik Menggunakan Metode Constructive Backpropagation Neural Network Serta Prediksi Kebutuhan Bahan Bakar Gas Pembangkitan," Universitas Jember, 2017.
- [4] I. Amri, Masniar, and J. B. E. Laos, "Simposium Nasional Teknologi Terapan (SNTT) 2013 ISSN 2339-028X," *Simp. Nas. Teknol. Ter.*, vol. 5, pp. 65–70, 2017.
- [5] N. Azizah, K. Adi, and A. Widodo, "Metode Adaptive Neuro Fuzzy Inference System (ANFIS) untuk Prediksi Tingkat Layanan Jalan," *J. Sist. Inf. Bisnis*, vol. 3, no. 3, pp. 127–131, 2016, doi: 10.21456/vol3iss3pp.
- [6] R. Ata and Y. Kocyigit, "An adaptive neuro-fuzzy inference system approach for prediction of tip speed ratio in wind turbines," *Expert Syst. Appl.*, vol. 37, no. 7, pp. 5454–5460, 2010, doi: 10.1016/j.eswa.2010.02.068.
- [7] U. Khasanah, D. C. R. Novitasari, W. D. Utami, and P. K. Intan, "Analisis Peramalan Beban Listrik Jangka Pendek Menggunakan Metode Adaptive Neuro Fuzzy Inference System (Studi Kasus : Pt. Pln (Persero) Area Pengaturan Distribusi Jawa Timur)," *Math Vis.*, vol. 01, no. 01, pp. 17–24, 2019.
- [8] S. Y. Amalutfia and M. Hafiyusholeh, "Analisis Peramalan Nilai Tukar Rupiah Terhadap Dollar dan Yuan Menggunakan FST-Markov Chain," *J. Pendidik. Mat. dan Mat.*, vol. 2, no. 2, pp. 102–113, 2020.
- [9] H. Effendi, "Aplikasi Logika Fuzzy untuk Peramalan Beban Listrik Jangka Pendek Menggunakan Matlab," *Sainstek*, vol. XII, no. 1, pp. 52–58, 2009, [Online]. Available: <http://ejournal.unp.ac.id/index.php/sainstek/article/view/149>.
- [10] I. N. T. Adnyana, I. G. P. S. Wijaya, and M. A. Albar, "Jaringan Syaraf Tiruan Backpropagation Untuk Peramalan Suhu Minimum dan Maksimum," *J-Cosine*, vol. 3, no. 2, pp. 127–136, 2019.
- [11] B. Satria, "Prediksi Volume Penggunaan Air PDAM Menggunakan Metode Jaringan Syaraf Tiruan Backpropagation," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 2, no. 3, pp. 674–684, 2018, doi: 10.29207/resti.v2i3.575.
- [12] N. A. Tindriyani, "Implementasi Neural Network Pada Matlab Untuk Peramalan Konsumsi Beban Listrik Kabupaten Ponorogo Jawa Timur," Universitas Negeri Semarang, Semarang, 2017.
- [13] M. A. Kurniawan, "Penerapan Metode Feed Forward Neural Network (Ffn) Backpropagation Untuk," Universitas Negeri Semarang, Semarang, 2017.

- [14] D. E. Rufiyanti, “Implementasi Jaringan Syaraf Tiruan Backpropagation Dengan Input Model Arima Untuk Peramalan Harga Saham,” Universitas Negeri Semarang, Semarang, 2015.
- [15] M. Andrijasa and Mistianingsih, “Penerapan Jaringan Syaraf Tiruan Untuk Memprediksi Jumlah Pengangguran di Provinsi Kalimantan Timur Dengan Menggunakan Algoritma Pembelajaran Backpropagation,” *J. Inform. Mulawarman*, vol. 5, no. 1, 2010.
- [16] M. Y. Habibi and E. Riksakomara, “Peramalan Harga Garam Konsumsi Menggunakan Artificial Neural Network Feedforward-Backpropagation (Studi Kasus : PT. Garam Mas, Rembang, Jawa Tengah),” *J. Tek. ITS*, vol. 6, no. 2, 2017.
- [17] U. Khasanah and N. Ulinuha, “Prediksi Biaya Konsumsi Bahan Bakar Gas Menggunakan Metode Backpropagation Neural Network,” *J. Sains Mat. dan Stat.*, vol. 5, no. 2, pp. 9–17, 2019.
- [18] A. S. Rachman, I. Cholissodin, and M. A. Fauzi, “Peramalan Produksi Gula Menggunakan Metode Jaringan Syaraf Tiruan,” *Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 4, pp. 1683–1689, 2018, [Online]. Available: <https://www.researchgate.net/publication/322963136>.