

---

**NEURAL NETWORK AUTOREGRESSIVE EXOGENOUS (NNARX) UNTUK  
MERAMALKAN INFLOW DEBIT AIR DI WADUK GAJAH MUNGKUR  
KABUPATEN WONOGIRI**

NEURAL NETWORK NEURAL NETWORK AUTOREGRESSIVE EXOGENOUS  
(NNARX) TO FORECAST INFLOW WATER IN GAJAH MUNGKUR RESERVOIR  
KABUPATEN WONOGIRI

<sup>1)</sup>Virgania Sari, <sup>2)</sup> Alfi Nur Adli Yusuf

<sup>1,2)</sup>Program Studi D-III Statistika

Akademi Statistika Muhammadiyah Semarang

Jl Prof Dr Hamka Km 1 Ngaliyan Kota Semarang, Jawa Tengah, Indonesia

[virganasari@aismuh.ac.id](mailto:virganasari@aismuh.ac.id), [alfinuradli98@gmail.com](mailto:alfinuradli98@gmail.com)

**ABSTRAK**

Waduk Gajah Mungkur merupakan waduk terletak di Kabupaten Wonogiri Jawa Tengah, waduk ini dibangun untuk membendung sungai Bengawan Solo, yang merupakan sungai terpanjang di pulau Jawa. Keberadaan waduk Gajah Mungkur membawa manfaat bagi masyarakat sekitar sebagai PLTA, perikanan, irigasi, penampungan air hujan dan pariwisata. Inflow yang masuk ke Waduk Gajah Mungkur berasal dari sungai Bengawan Solo dan lima anak sungai yang berada di DAS Waduk Gajah Mungkur. Inflow tertinggi pada saat musim hujan dan terendah saat musim kemarau. Debit Inflow diramalkan menggunakan model time series Neural Network Autoregressive Exogenous (NARX) dengan curah hujan di kabupaten Wonogiri sebagai variabel eksogenus. Dari hasil analisis diperoleh model NARX terbaik dengan 5 input delay, 7 neuron hidden dan algoritma Marquardt Lavenberg untuk pembelajaran jaringan dengan nilai MSE 301.8313.

**Kata Kunci** : peramalan, debit inflow, curah hujan, NNARX, Neural Network

**ABSTRACT**

Gajah Mungkur reservoir is located in Wonogiri districts Central Java province was built to accommodate flow of Bengawan Solo river which is the longest river in Java island. Gajah Mungkur reservoir lead to benefits for society as hydroelectric power plant, fishery, irrigation and tourism. Gajah Mungkur reservoir inflow sourced from Bengawan Solo river and its five branches located Gajah Mungkur reservoir watershed. The peak of its inflow at wet season and the minimum at dry season. Inflow debit is predicted by time series model of Neural Network Autoregressive Exogenous (NARX) and rainfall in Wonogiri district as exogenous variable. NNARX provide the best result at 5 delay input, 7 nodes of hidden and Marquardt Lavenberg algorithm as learning algorithm in MSE 301.8313.

**PENDAHULUAN**

Waduk gajah mungkur merupakan waduk terbesar di kabupaten wonogiri, dengan jarak 6km di sebelah selatan kota kabupaten Wonogiri, Jawa Tengah. Waduk ini dibangun untuk membendung sungai Bengawan Solo, yang merupakan sungai terpanjang di pulau Jawa. Adanya waduk ini bermanfaat bagi masyarakat sekitar maupun satu kabupaten, sebagai PLTA, perikanan, irigasi, penampungan air hujan, dan pariwisata. Waduk gajah mungkur dapat menampung air dengan luas tampungan

1.350 km berjarak 3 km dari Kecamatan Wonogiri. Waduk ini dibangun pada tahun 1976 dan membutuhkan sekitar 6 tahun untuk menyelesaikannya sekitar tahun 1981 waduk ini sudah selesai tahap pembangunannya. Pada bulan juli 1980 merupakan bulan dimana waduk ini melakukan pengisian pertamanya, dan pada bulan november 1980 merupakan bulan peresmian waduk gajah mungkur (Samosir, Widandi & Emma, 2015). Pembangunan waduk ini berdampak pada masyarakat yang harus digusur, sekiranya 68.750 jiwa dari 12.500 kepala keluarga yang

menempati 6 kecamatan yang tersebar di 45 desa. Sebanyak 10.709 kepala keluarga terdapat 43616 jiwa melakukan transmigrasi sampai tahun 1981. Luasnya Waduk Gajah Mungkur menjadikan sebuah manfaat bagi masyarakat, dengan adanya waduk yang mempunyai tampungan air sebesar 229 juta m<sup>3</sup>. Selain itu waduk ini juga digunakan sebagai PLTA di kabupaten wonogiri dengan menghasilkan listrik 12,4 MW (BBWS Bengawan Solo, 2012).

Inflow yang masuk ke Waduk Gajah Mungkur berasal dari sungai Bengawan Solo dengan 5 (lima) anak sungainya yang berada di DAS Waduk Gajah Mungkur yaitu Sungai Keduang, Tirtomoyo, Temon, Alang dan Wuryantoro. Inflow waduk sebagian besar terjadi pada musim hujan, berbeda dengan musim kemarau yang menyebabkan sedikitnya inflow yang masuk ke waduk (Miranti, 2010).

Dalam sebuah pengepersian di waduk tentunya akan menghindari yang namanya kesalahan seperti kelebihan atau kekurangan tampungan air dan kekeliruan dalam pembuangan air, hal tersebut dapat menyebabkan banjir pada daerah yang berapa di dataran lebih rendah dari waduk. Maka dari itu untuk mengatasi banyaknya debit air yang keluar, maka perlu dilakukan peramalan debit masuknya air ke waduk. Salah satu metode peramalan debit konvensional yang banyak digunakan untuk operasional bangunan hidrolik adalah teknik peramalan debit sederhana, yaitu dengan menganggap bahwa debit aliran sungai yang terjadi pada periode mendatang akan sama dengan debit yang diukur saat ini (Hatmoko & S. Amirwandi, 2001).

Peramalan adalah metode untuk memperkirakan suatu nilai dimasa depan dengan menggunakan data masa lalu. Peramalan juga dapat diartikan sebagai seni dan ilmu untuk memperkirakan kejadian pada masa yang akan datang (Wardah, 2016).

Menurut penelitian sebelumnya NARX telah berhasil diterapkan dalam prediksi kecepatan angin. Hasil penelitian tersebut menunjukkan bahwa model Neural Network Autoregressive Exogenous (NARX) umumnya memiliki akurasi yang lebih baik dibandingkan dengan Artificial Neural Network (ANN). Hal ini dikarenakan pada ANN output langsung dikalkulasikan dari input melalui koneksi feedforward, sedangkan pada NARX output tidak hanya bergantung pada input saat ini pada network-nya, tetapi juga bergantung pada input saat ini atau input sebelumnya, output, atau state dari network (Richasdy, Jondri, & Msi, 2012).

Neural Network dapat diklasifikasikan menjadi kategori berdasarkan variabel yang mempengaruhi network-nya, yaitu: dynamic (NNARX) dan static (ANN). Statis network tidak memiliki elemen feedback serta tidak ada delay, output langsung dikalkulasikan dari input melalui koneksi feedforward. Di dynamic network, output tidak hanya bergantung pada input saat ini pada network-nya, tetapi juga bergantung pada input saat ini atau input sebelumnya, output, atau state dari network. Dynamic network umumnya lebih baik dari pada static network (meskipun lebih sulit pada proses training). Karena dynamic network memiliki memory, dia bisa dilatih untuk sequential learning atau berdasarkan pola variasi waktu (Richasdy et al., 2012). Dengan menggunakan Algoritma Levenberg Marquardt (LM) yang merupakan pengembangan dari Algoritma Backpropagation standar. Pada algoritma BP standar proses update bobot dan bias menggunakan negative gradient descent secara langsung sedangkan pada algoritma Levenberg Marquardt menggunakan pendekatan matriks Hessian. Algoritma LM dirancang untuk melakukan pendekatan kecepatan training urutan kudea tanpa melakukan perhitungan matriks Hessian (Rahmat, Setiawan, & Purnomo, 2006). Penelitian ini menggunakan data curah

hujan yang terjadi pada kabupaten Wonogiri dan berpengaruh terhadap inflow debit air waduk sebagai variabel exogenusnya.

## METODE

### Pengumpulan Data

Pada karya ilmiah ini menggunakan data sekunder inflow debit air Waduk Gajah Mungkur kabupaten Wonogiri dari bulan Januari 2010 – Desember 2016 yang diperoleh dari Perum Jasa Tirta 1 dan data sekunder curah hujan sebagai variabel eksogenus yang mempengaruhi debit air Waduk Gajah Mungkur kabupaten Wonogiri dari bulan Januari 2010 – Desember 2016 diperoleh dari BMKG Kabupaten Wonogiri.

### Analisa dan Perancangan

#### Pembagian Data

Langkah pertama sebelum dilakukan analisis adalah membagi data menjadi 2 (dua) yaitu data training dan testing. Data training merupakan data yang dipergunakan untuk melakukan pengenalan pola yang nantinya dipakai untuk peramalan. Data training memberikan bobot, bias. Sedangkan data testing merupakan data uji yang akan dipakai untuk menghitung hasil

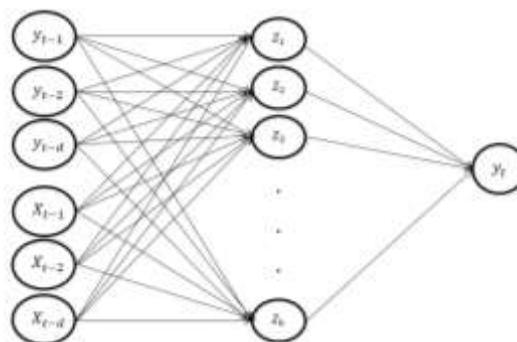
ramalan dan kesalahan ramalan. Dalam penelitian ini menggunakan komposisi data training sebesar 80% dan untuk data testing 20%.

### Normalisasi Data

Sebelum digunakan untuk proses pelatihan, perlu dilakukan penskalaan terhadap data training dan data testing sehingga data tersebut masuk ke dalam suatu range tertentu yang disebut dengan normalisasi data. Data yang dinormalisasi sesuai dengan fungsi aktivasi yang digunakan, dalam penelitian ini digunakan fungsi aktivasi sigmoid biner sehingga data yang dinormalisasi nantinya berbeda dalam range 0 hingga 1.

### Desain Arsitektur Jaringan

Melakukan analisis dan perancangan terhadap sistem yang dibangun, menganalisis metode yang akan digunakan untuk menyelesaikan permasalahan, termasuk menentukan bahasa pemrograman yang akan digunakan, arsitektur, fungsionalitas, dan antarmuka sistem. Input dari sistem ini adalah inflow debit air. Sedangkan output dari sistem ini adalah prediksi inflow debit air dimasa mendatang.



Gambar 1. Desain Arsitektur Jaringan

Secara simbolis output di unit  $y$  adalah sebagai berikut :

$$y(t) = f\{y(t-1), y(t-2), \dots, y(t-d), \\ x(t-2), \dots, x(t-d)\}$$

Keterangan :

$f$  = fungsi aktivasi

$h$  = banyak hidden

$y$  = debit inflow

$d$  = banyak delay

$x$  = debit air hujan

syarat tersebut yaitu fungsi sigmoid biner yang memiliki range (0,1).

### Pelatihan Jaringan

Dalam backpropagation, fungsi aktivasi yang dipakai harus memenuhi beberapa syarat yaitu: kontinu, terdiferensial dengan mudah dan merupakan fungsi yang tidak turun (Humaini, 2015). Oleh karenanya dalam penelitian ini digunakan fungsi yang memenuhi ketiga

Sebelum masuk ke algoritma Lavenberg Marquardt (LM) harus ditentukan dahulu fungsi objektif yang akan dioptimalisasi. Apabila algoritma LM digunakan sebagai algoritma pelatihan jaringan syaraf tiruan, maka tujuannya adalah meminimasi error yang bergantung pada bobot-bobot yang menghubungkan antar neuron. Oleh karena itu, fungsi objektif adalah fungsi error (MSE) yaitu :

$$f(W) = \frac{1}{n} e^T e = \frac{1}{n} \sum_{i=1}^n (o_i - t_i)^2;$$

$$i = 1, 2, \dots, n$$

Algoritma lavenberg Marquardt dengan menggunakan fungsi aktivasi sigmoid biner adalah sebagai berikut:

Langkah 1 : Inisialisasi semua bobot dengan bilangan acak kecil

Langkah 2 : Jika kondisi penghentian belum terpenuhi, lakukan langkah 2 – 8

#### Fase I : Propagasi maju (Feedforward)

Langkah 3 : Tiap unit masukan menerima sinyal dan meneruskannya ke unit tersembunyi di atasnya (unit lapisan tersembunyi).

Langkah 4 : Hitung semua keluaran di unit  $z$  ( $j = 1, 2, \dots, p$ )

$$z\_net_j = v_{j0} + xv_j$$

Kemudian menghitung sinyal output yang selanjutnya akan diteruskan menuju output unit sesuai dengan fungsi aktivasi yang digunakan

$$z_j = f(z\_net_j) = \frac{1}{1 + e^{-z\_net_j}}$$

Langkah 5 : Hitung semua keluaran jaringan di unit  $y$

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

Kemudian menggunakan fungsi aktivasi untuk menghitung sinyal output

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

#### Fase II : Propagasi mundur (Backpropagation)

Langkah 6 : Hitung gradient

$$g = J^T e$$

Dimana elemen matriks Jacobi  $J$  berisi turunan pertama fungsi objektif terhadap bobot yang bersesuaian, dan  $e$  adalah eror jaringan.

$$J = \begin{bmatrix} \frac{\partial f(e_1 w)}{\partial w_1} & \frac{\partial f(e_1 w)}{\partial w_2} & \dots & \frac{\partial f(e_1 w)}{\partial w_n} \\ \frac{\partial f(e_2 w)}{\partial w_1} & \frac{\partial f(e_2 w)}{\partial w_2} & \dots & \frac{\partial f(e_2 w)}{\partial w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial f(e_k w)}{\partial w_1} & \frac{\partial f(e_k w)}{\partial w_2} & \dots & \frac{\partial f(e_k w)}{\partial w_n} \end{bmatrix}$$

Langkah 7 : menghitung matriks

$$H \approx J^T J = (J_i^T J_i + \mu I)$$

Dimana  $\mu$  adalah learning parameter

### Fase III : Perubahan Bobot (Weight Update)

Langkah 8 : Update bobot dilakukan dengan cara sebagai berikut:

$$W_{i+1} = W_i - (J_i^T J_i + \mu I)^{-1} J_i^T e_i$$

Dimana:

- $x$  = unit pada lapisan input
- $z_j$  = unit ke- $j$  pada lapisan *hidden*
- $y$  = unit pada lapisan output
- $f$  = fungsi aktivasi
- $v_j$  = nilai bobot dari input ke *hidden*
- $w_j$  = nilai bobot dari *hiden* ke output
- $v_{jo}$  = nilai bias untuk lapisan *hidden*
- $w_o$  = nilai bias untuk lapisan output
- $z_{net_j}$  = keluaran untuk lapisan *hidden*
- $y_{net}$  = masukan untuk lapisan keluaran

### Denormalisasi Data

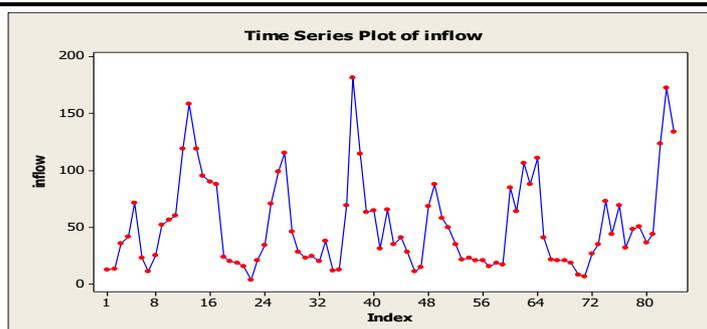
Denormalisasi atau mengembalikan data dilakukan untuk mengkonversikan kembali hasil normalisasi (output) yang dihasilkan oleh jaringan berkisar antara 0 hingga 1 menjadi harga material normal yang sebenarnya.

### HASIL DAN PEMBAHASAN

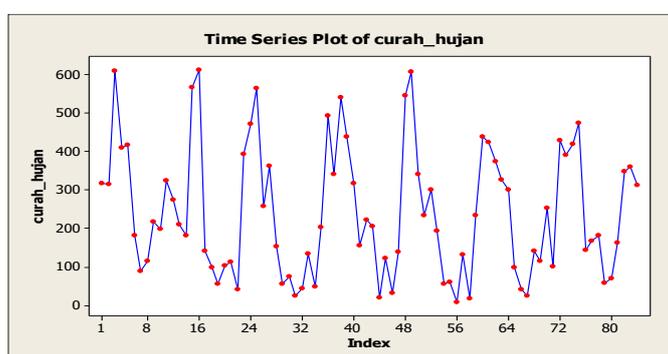
Sebelum dilakukan pengolahan data dibagi menjadi 2 bagian yakni data

training untuk membangun jaringan (periode Januari 2010 – Juli 2015) dan data testing untuk forecasting (periode Agustus 2015 – Desember 2016).

Plot time series data debit inflow dan curah hujan bulanan Waduk Gajah Mungkur dalam kurun waktu Januari 2010 – Desember 2016 yang digunakan untuk menggambarkan atau mendeskripsikan data pengamatan secara umum tersaji dalam Gambar 2 dan Gambar 3.



Gambar 2 Plot Time Series Debit Inflow Waduk Gajah Mungkur



Gambar 3. Plot Time Series Curah Hujan Waduk Gajah Mungkur

Terlihat bahwa data debit inflow Waduk Gajah Mungkur selama periode Januari 2010 sampai Desember 2016 untuk jumlah debit inflow tertinggi terjadi pada bulan Januari tahun 2013 sebesar 181,98 m<sup>3</sup>/dt dan untuk jumlah debit inflow terendah terjadi pada bulan Oktober tahun 2011 sebesar 3,96 m<sup>3</sup>/dt. Sedangkan, curah hujan tertinggi terjadi pada bulan April

tahun 2011 sebesar 612 mm/hari dan untuk curah hujan terendah terjadi pada bulan Agustus tahun 2014 sebesar 8 mm/hari. Selain itu dapat diketahui bahwa dari periode Januari 2010 sampai Desember 2016 debit inflow dan curah hujan mengalami fluktuasi di setiap tahunnya yang juga dapat dilihat berdasarkan rata-rata keduanya pada Tabel dibawah berikut.

Tabel 1 Rata-Rata Debit Inflow Waduk Gajah Mungkur

Tahun	Rata-Rata Debit Inflow (m <sup>3</sup> /dt)
2010	43.6625
2011	57.4533
2012	46.525
2013	59.9967
2014	37.94
2015	44.5217
2016	72.0508

Dari Tabel, dapat diperoleh informasi bahwa rata-rata debit inflow tertinggi terjadi pada tahun 2016 dengan besar aliran 72,05 m<sup>3</sup>/dt dan rata-rata debit inflow terendah terjadi pada tahun 2014 dengan besar aliran 37,94 m<sup>3</sup>/dt.

Tabel 2. Rata-Rata Curah Hujan Waduk Gajah Mungkur

Tahun	Rata-Rata Curah Hujan (mm/hari)
2010	288.6667
2011	248.8333
2012	200.8333
2013	256.5
2014	218.25
2015	218.75
2016	259.9167

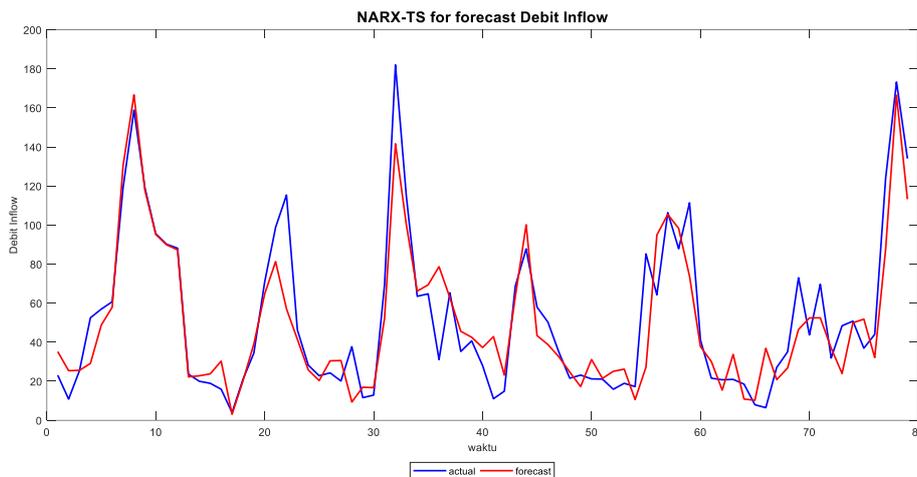
Dari Tabel, dapat diperoleh informasi bahwa rata-rata debit inflow tertinggi terjadi pada tahun 2010 sebesar 288,6667 mm/hari dan rata-rata debit inflow terendah terjadi pada tahun 2014 sebesar 218,25 mm/hari.

Jumlah debit inflow dan curah hujan Waduk Gajah Mungkur rata-rata mengalami kenaikan pada Januari karena pada bulan ini adalah musim penghujan, sehingga debit air hujan yang sebagai sumber air utama masuk cukup banyak untuk selanjutnya digunakan untuk memenuhi kebutuhan sehari-hari masyarakat yang tinggal di sekitar waduk. Sedangkan, untuk jumlah debit inflow dan curah hujan terendah pada bulan Oktober, ini disebabkan karena pada bulan ini terjadi musim kemarau, sehingga debit air hujan yang masuk tidak cukup banyak dibandingkan saat musim penghujan.

Hasil peramalan akan bergantung pada arsitektur jaringan yang dibangun, seperti banyak layer yang digunakan, banyak neuron pada setiap layer dan metode training yang digunakan. Selanjutnya dilakukan *trial dan error* untuk menentukan banyak neuron yang dibutuhkan pada layer hidden. Hasil yang diperoleh dari simulasi tidak konstan (berubah-ubah). Hanya hasil terbaik yang ditampilkan pada bagian ini. Kemudian dari hasil ini dipilih banyak neuron hidden yang menghasilkan Mean Square Error (MSE) terkecil untuk selanjutnya digunakan sebagai batasan nilai MSE pada simulasi selanjutnya.

**Tabel 3. MSE dari Jaringan Syaraf Tiruan**

Arsitektur <i>i-d=1-h-o</i>	MSE	Arsitektur <i>i-d=2-h-o</i>	MSE	Arsitektur <i>i-d=3-h-o</i>	MSE	Arsitektur <i>i-d=4-h-o</i>	MSE	Arsitektur <i>i-d=5-h-o</i>	MSE
<b>1-1-1-1</b>	825.5894	1-2-1-1	755.6558	1-3-1-1	700.1294	1-4-1-1	661.8601	1-5-1-1	552.5951
<b>1-1-2-1</b>	784.3263	1-2-2-1	708.5805	1-3-2-1	644.9689	1-4-2-1	537.4776	1-5-2-1	443.6391
<b>1-1-3-1</b>	692.3684	1-2-3-1	696.7856	<b>1-3-3-1</b>	<b>463.4099</b>	1-4-3-1	611.5552	1-5-3-1	492.4790
<b>1-1-4-1</b>	731.3342	1-2-4-1	663.4549	1-3-4-1	577.4107	1-4-4-1	688.1069	1-5-4-1	492.4336
<b>1-1-5-1</b>	672.4111	1-2-5-1	684.8420	1-3-5-1	538.8253	1-4-5-1	494.4513	1-5-5-1	445.8639
<b>1-1-6-1</b>	677.4783	1-2-6-1	700.2039	1-3-6-1	508.2854	1-4-6-1	450.4864	1-5-6-1	424.6633
<b>1-1-7-1</b>	777.7034	1-2-7-1	632.2827	1-3-7-1	521.4154	1-4-7-1	511.9177	<b>1-5-7-1</b>	<b>301.8313</b>
<b>1-1-8-1</b>	780.6521	1-2-8-1	626.2158	1-3-8-1	558.5840	<b>1-4-8-1</b>	<b>353.3002</b>	1-5-8-1	369.5422
<b>1-1-9-1</b>	664.5342	<b>1-2-9-1</b>	<b>538.1092</b>	1-3-9-1	488.9667	1-4-9-1	457.7423	1-5-9-1	399.0537
<b>1-1-10-1</b>	688.3347	1-2-10-1	696.9389	1-3-10-1	497.4466	1-4-10-1	504.6153	1-5-10-1	491.2555
<b>1-1-11-1</b>	666.3322	1-2-11-1	682.1158	1-3-11-1	462.9833	1-4-11-1	518.0870	1-5-11-1	526.7436
<b>1-1-12-1</b>	613.2290	1-2-12-1	667.9023	1-3-12-1	514.8381	1-4-12-1	433.0564	1-5-12-1	548.8101
<b>1-1-13-1</b>	698.6330	1-2-13-1	849.6548	1-3-13-1	545.4330	1-4-13-1	428.6223	1-5-13-1	476.7563
<b>1-1-14-1</b>	667.1948	1-2-14-1	798.3107	1-3-14-1	445.6902	1-4-14-1	545.4934	1-5-14-1	307.0596
1-1-15-1	<b>580.3077</b>	1-2-15-1	714.7052	1-3-15-1	559.7997	1-4-15-1	599.1677	1-5-15-1	411.4735



**Gambar 4. Plot Time Series Aktual dan Ramalan NNARX Inflow Debit Waduk Gajah Mungkur**

Hasil MSE dari berbagai tipe arsitektur pada Tabel 3 menunjukkan bahwa arsitektur jaringan yang memberikan akurasi peramalan terbaik terdapat pada

konfigurasi 5 input delay, 7 neuron hidden dengan nilai MSE sebesar 301.8313.

## KESIMPULAN

Meramalkan inflow debit air Waduk Gajah Mungkur menggunakan metode Neural Network Autoregressive Exogenous dengan menggunakan curah hujan sebagai variabel tambahan dapat disimpulkan sebagai berikut.

Data debit inflow Waduk Gajah Mungkur selama periode Januari 2010 sampai Desember 2016 mengalami fluktuasi di setiap tahunnya dengan jumlah debit inflow tertinggi terjadi pada bulan Januari tahun 2013 sebesar 181,98 m<sup>3</sup>/dt dan untuk jumlah debit inflow terendah terjadi pada bulan Oktober tahun 2011 sebesar 3,96 m<sup>3</sup>/dt.

Data curah hujan selama periode Januari 2010 sampai Desember 2016 mengalami fluktuasi di setiap tahunnya dengan jumlah curah hujan tertinggi pada bulan April tahun 2011 sebesar 612 mm/hari, dan untuk curah hujan terendah terjadi pada bulan Agustus tahun 2014 sebesar 8 mm/hari.

Dengan pembagian data yaitu 80% untuk data training dan 20% untuk data testing serta dari hasil trial dan error diperoleh hasil terbaik untuk meramalkan inflow debit air Waduk Gajah Mungkur dengan arsitektur yang terdiri dari 5 input delay, 7 neuron hidden dengan nilai MSE sebesar 301.8313. untuk periode Agustus 2015 – Desember 2016.

## DAFTAR PUSTAKA

- Alim, Z. (2008). *Prediksi Kandungan Nitrat Pada Waduk Cisanti Dengan Menyertakan Limpasan Permukaan Sebagai Sumber*. Tugas Akhir. Bandung : Institut Teknologi Bandung.
- Ardhiyanta, D. (2016). *Prediksi Jumlah Produksi Roti Menggunakan Metode Backpropagation*. Skripsi. Yogyakarta : Universitas Sanata Dharma.
- [BBWS Bengawan Solo] Balai Besar Wilayah Sungai Bengawan Solo. 2012. *Profil Pengelolaan Sumber Daya Air Wilayah Sungai Bengawan Solo*. Surakarta : BBWS Bengawan Solo.

- Hadjaratie, L. (2011). *Jaringan Saraf Tiruan untuk Prediksi Tingkat Kelulusan Mahasiswa Diploma Program Studi Manajemen Informatika Universitas Negeri Gorontalo*. Tesis. Bogor : Institut Pertanian Bogor.
- Hatmoko, W, S. Amirwandi. (2001). *Penerapan Metode Thomas-Fiering untuk Peramalan Debit Aliran Sungai Cimanuk di Bendung Rentang*. Prosiding PIT XVII HATHI. Malang
- Humaini, Q. (2015). *Jaringan Syaraf Tiruan Extreme Learning Machine (ELM) untuk Memprediksi Kondisi Cuaca di Wilayah Malang*. Skripsi. Malang : Universitas Islam Negeri Maulana Malik Ibrahim.
- Kusumaningtyas, E.M. (2011). *Kecerdasan Buatan*. Modul Pembelajaran. Surabaya : Politeknik Elektronika Negeri Surabaya.
- Liliana dan Togar A.N. (2012). *Artificial Neural Network Application in Gross Domestic Product Forecasting an Indonesia Case*. Journal of Theoretical and Applied Information Technology, 45(2) : 410-415.
- Miranti, F.A. (2010). *“Peningkatan Kinerja Operasi pada Waduk Wonogiri”*. Skripsi. Surakarta : Universitas Sebelas Maret.
- Mitasari, A.S. (2010). *“Analisis Kewajiban Penyediaan Modal Minimum (CAR) Pengaruhnya Terhadap Profitabilitas (ROE) pada PT. BPR Emasnusantara Sentosa”*. Skripsi. Bandung : Universitas Komputer Indonesia.
- Raharjo, P. (2008). *“Simulasi Sedimentasi dan Analisis Umur Waduk (Studi Kasus Waduk Saguling)”*. Skripsi. Bandung : Institut Teknologi Bandung.
- Jyothi, M. N., Dinakar, V., Teja, N. S. S. R., & Kishore, K. N. (2015). *NARX Based Short Term Wind Power Forecasting Model*. TELKOMNIKA Indonesian Journal of Electrical Engineering, 15(1), 20–25. <https://doi.org/10.11591/telkomnika.v15i1.8070>
- Rahmat, R., Setiawan, R., & Purnomo, M. H. (2006). *Perbandingan Algoritma Levenberg-Marquardt dengan Metoda Backpropagation pada Proses Learning Jaringan Saraf Tiruan untuk Pengenalan Pola Sinyal Elektrokardiograf*. Seminar Nasional Aplikasi Teknologi Informasi (SNATI), 2006(Juni), 39–43.
- Richasdy, D., Jondri, & Msi. (2012). *Implementasi neural network autoregressive with exogenous input (nnarx) terhadap prediksi kecepatan angin*, 1–6.
- Sari, V. (2011). *NEURAL NETWORK UNTUK PREDIKSI HARGA KURS DAN TRADING STRATEGY NEURAL NETWORK UNTUK PREDIKSI HARGA KURS*, 73. Thesis. Bandung : Institut Teknologi Bandung.
- Wardah, S. (2016). *KEMASAN BUNGKUS ( Studi Kasus : Home Industry Arwana Food Tembilahan )*.