

Peramalan Debit Bendungan Dengan Menggunakan Metode *Backpropagation* dan Algoritme Genetika

Beta Deniarrhman Hakim¹, Indriati², Ahmad Afif Supianto³

Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Brawijaya
Email: ¹beta.hakim@gmail.com, ²indriati.tif@ub.ac.id, ³afif.supianto@ub.ac.id

Abstrak

Peramalan debit bendungan diperlukan untuk merencanakan rencana alokasi air untuk berbagai kebutuhan misalnya untuk Pembangkit Listrik Tenaga Air (PLTA), pengendalian banjir dan irigasi. Jaringan saraf tiruan dalam hal ini metode *backpropagation* memiliki metode pembelajaran untuk mengubah bobot dari nilai arsitektur jaringan saraf tiruan tersebut. Algoritme#genetika dapat melakukan optimasi bobot jaringan saraf tiruan untuk menghindari terjadinya lokal minimum yang menjadi kelemahan *backpropagation*. Algoritme genetika akan melakukan optimasi bobot jaringan saraf tiruan sehingga dihasilkan individu sebagai representasi bobot dengan nilai fitness terbaik bobot hasil dari proses optimasi dengan algoritme genetika kemudian digunakan sebagai bobot awal jaringan saraf tiruan metode *backpropagation*. Data yang digunakan sebagai data input adalah data time series debit bendungan bulan sebelumnya. Data yang digunakan adalah data debit bulanan mulai tahun 2008 sampai dengan tahun 2017. Data input akan diproses oleh sistem untuk menghasilkan nilai output yang merupakan nilai peramalan debit bendungan satu bulan ke depan. Parameter pelatihan optimal pelatihan algoritme genetika dan *backpropagation* adalah ukuran populasi=100, jumlah generasi=100, kombinasi Cr dan Mr adalah 0,6 dan 0,4, jumlah iterasi=500, nilai learning rate=0,7. Hasil pengujian menggunakan parameter optimal mendapatkan nilai MSE = 0,04188.

Kata kunci: peramalan, debit bendungan, algoritme genetika, *backpropagation*

Abstract

Dam discharge forecasting is needed to plan water allocation plans for various needs such as for Hydropower plant, flood control and irrigation. Artificial neural network in this case backpropagation method has a learning method to change the weight of the value of the architecture of the artificial neural network. Genetic algorithms can optimize the weight of artificial neural networks to avoid the occurrence of a minimum local which is a weakness of backpropagation. Genetic algorithms will optimize the weight of the artificial neural network so individuals which are produced as a weight representation with the best fitness value resulting from the optimization process with the genetic algorithm then used as the initial weight of the artificial neural network backpropagation method. The data used as input data is the dam discharge time series data the previous months. The data used is monthly debit data from 2008 to 2017. Input data will be processed to produce an output value which is the forecasted value of the dam discharge in the next month. The optimal training parameters for genetic algorithm and backpropagation training are the population size=100, the generation=100, Cr and Mr combination 0,6 and 0,4, the number of iterations = 500, the value of learning rate = 0.7. The test results using optimal parameters get the MSE value = 0.04188.

Keywords: forecasting, dam discharge, genetic algorithm, *backpropagation*

1. PENDAHULUAN

Bendungan merupakan salah satu infrastruktur dalam pengelolaan sumber daya air. Sebagai bangunan tempat tampungan air, beberapa bendungan memiliki beberapa potensi secara ekonomis, salah satunya sebagai

Pembangkit Listrik Tenaga Air (PLTA). Salah satu bendungan yang memiliki fungsi PLTA ini adalah Bendungan Sutami. Bendungan tersebut terletak di Desa Karangates, Kabupaten Malang. Bendungan Sutami memiliki fungsi sebagai pembangkit listrik dengan kapasitas 3 X 35 mW. Fungsi lain dari bendungan ini adalah sebagai pengendali banjir

di wilayah hulu Sungai Brantas. Fungsi lain yang tidak kalah penting adalah untuk mendukung irigasi pada area persawahan sekitar 34.000 ha (Perum Jasa Tirta I, 2014). Sehingga dapat dikatakan bendungan juga ikut serta memiliki peranan yang penting dalam mendukung ketahanan energi dan pangan nasional.

Untuk mengetahui kapasitas maksimal energi yang dihasilkan oleh pembangkit listrik pada periode tertentu di Bendungan Sutami, harus diketahui dulu berapa debit masuk air/inflow yang masuk ke dalam bendungan. Semakin besar debit aliran air yang masuk ke dalam bendungan, semakin besar pula potensi energi listrik yang dapat dihasilkan. Bila debit suatu bendungan dapat diramalkan, maka hasil dari proses tersebut dapat digunakan untuk melakukan perencanaan alokasi air untuk memaksimalkan energi listrik yang dihasilkan turbin PLTA. Selain itu peramalan debit bendungan akan sangat penting dalam merencanakan pola operasi pintu air dalam mengendalikan banjir dan memenuhi kebutuhan irigasi.

Jaringan saraf tiruan telah digunakan dalam beberapa penelitian untuk melakukan peramalan, antara lain Peramalan tinggi muka air sungai (Somlek, et al., 2016) yang menghasilkan nilai *Mean Square Error* (MSE) sebesar 0,1139, peramalan ketinggian muka air waduk (Anindita & Laksono, 2016) dengan hasil *Root Mean Square Error* (RMSE) sebesar 9,2142. Meskipun memiliki kehandalan dalam implementasi peramalan, metode *backpropagation* juga memiliki kelemahan. Kelemahan metode *backpropagation* adalah seringkali terjebak pada kondisi lokal minimum (Liu & Liu, 2016).

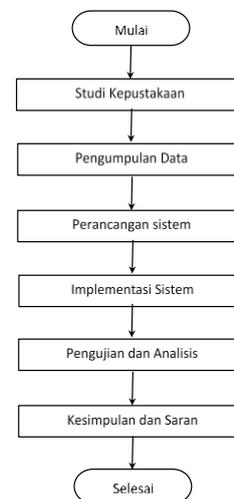
Algoritma genetika termasuk dalam kategori algoritma evolusi. Algoritma genetika merupakan salah satu algoritma yang sering digunakan untuk melakukan optimasi karena mampu memberikan solusi permasalahan yang cukup kompleks (Mahmudy, 2015). Algoritma genetika dapat digunakan untuk melakukan optimasi pada pembobotan nilai jaringan saraf tiruan. Beberapa penelitian yang menggabungkan algoritma genetika dan jaringan saraf tiruan antara lain peramalan aktifitas lalu lintas (Haviluddin, 2015). Pada penelitian ini data yang digunakan adalah data *time series* sebagai data latih dan data uji. Penggunaan algoritma genetika dan jaringan saraf tiruan menunjukkan hasil dengan MSE yang lebih baik dibanding tanpa ada optimasi

dengan algoritma genetika.

Mengacu pada beberapa penelitian sebelumnya, pada penelitian ini akan dilakukan peramalan debit Bendungan Sutami menggunakan jaringan saraf tiruan yang dioptimasi bobotnya menggunakan algoritma genetika. Optimasi jaringan saraf tiruan menggunakan algoritma genetika memungkinkan penggunaan data-data yang ada sebagai bahan untuk pembelajaran dan menghasilkan data keluaran berupa peramalan debit masuk Bendungan Sutami di periode yang akan datang.

2. METODOLOGI

Tahapan-tahapan pada penelitian ini adalah sebagai berikut:



Gambar 1. Tahapan Penelitian

Dalam penelitian ini sesuai dengan Gambar 1. Akan dimulai dengan studi kepustakaan dimana pada tahapan ini akan dilakukan studi mengenai penelitian-penelitian sebelumnya yang relevan dengan topik penelitian. Selain itu juga akan dipelajari dasar-dasar teori yang menunjang penyelesaian penelitian ini. Dasar teori penunjang kegiatan penelitian ini yaitu mengenai algoritme genetika, jaringan saraf tiruan dan metode *backpropagation*. Langkah berikutnya adalah melakukan pengumpulan data. Data yang digunakan dalam penelitian adalah data debit bulanan Bendungan Sutami mulai Januari 008 sampai dengan Desember 2017. Selanjutnya akan dilakukan perancangan sistem serta dilakukan implementasi peramalan debit bendungan dengan menggunakan metode *backpropagation* dan algoritme genetika. Langkah berikutnya adalah melakukan pengujian parameter-parameter dari algoritme

yang digunakan untuk dilakukan analisis sehingga didapatkan suatu kesimpulan.

2.1 Algoritma Genetika

Algoritme genetika merupakan salah satu algoritme evolusi. Algoritme evolusi sendiri adalah suatu jenis teknik optimasi yang terinspirasi oleh proses pada evolusi biologi. Algoritme genetika seringkali digunakan untuk menyelesaikan masalah optimasi dalam beberapa kasus yang memiliki ruang pencarian yang cukup kompleks. Algoritme genetika diperkenalkan pertama kali oleh John Holland dan beberapa rekan di Universitas Michigan (Mahmudy, 2015).

Solusi permasalahan dalam algoritme genetika direpresentasikan sebagai *fitness*. Fungsi *fitness* digunakan untuk mengetahui kualitas suatu individu. Semakin tinggi nilai *fitness*-nya, semakin baik pula individu tersebut untuk dijadikan solusi suatu permasalahan (Mahmudy, 2015). Proses yang dilakukan dalam algoritme genetika yaitu inisialisasi, reproduksi, evaluasi dan seleksi. Inisialisasi adalah proses pembangkitan individu secara acak yang mempunyai gen tertentu. Reproduksi adalah proses untuk menghasilkan keturunan (*offspring*) baru dari individu dalam suatu populasi. Evaluasi adalah proses untuk menghitung nilai *fitness* pada kromosom. Semakin tinggi nilai *fitness* dari suatu kromosom, semakin baik pula kromosom tersebut untuk dijadikan sebagai calon solusi. Seleksi adalah proses pemilihan individu terbaik pada suatu populasi dan *offspring* yang dipertahankan pada generasi selanjutnya (Mahmudy, 2015).

2.1.1 Inisialisasi

Proses inisialisasi adalah prosers pembangkitan himpunan individu baru yang dilakukan secara acak. Masing-masing individu memiliki susunan kromosom tertentu yang mewakili sebuah solusi terkait permasalahan yang akan dipecahkan. Himpunan individu yang telah dibangkitkan diletakkan dalam sebuah penampungan yang disebut dengan populasi. Daya tampung suatu populasi disebut dengan *popSize*.

2.1.2 Reproduksi

Proses reproduksi dilakukan untuk menghasilkan suatu keturunan dari individu-individu dalam populasi. Individu-individu dalam populasi akan dipilih dan akan menghasilkan keturunan yang

disebut *offspring*. Pada proses reproduksi ini terdapat 2 mekanisme untuk menghasilkan *offspring*, yaitu *crossover* dan mutasi. Pada mekanisme *crossover*, harus ditentukan terlebih dahulu nilai *crossover rate* (*cr*). *Crossover rate* mempunyai fungsi untuk menunjukkan perbandingan *offspring* yang dihasilkan dari mekanisme *crossover* terhadap *popSize* sehingga *offspring* yang dihasilkan dapat dituliskan:

$$offspring = cr \times popSize \tag{2.1}$$

Salah satu metode yang dapat diterapkan pada mekanisme *crossover* adalah *one-cut point*. Misal ditentukan nilai *cr*=0,2 dan *popSize*=10, maka nilai *offspring* yang dihasilkan adalah 0,2 x 10 = 2. Sebagai contoh *P₂* dan *P₅* terpilih sebagai *parent*, maka akan menghasilkan 2 *offspring*, yaitu *C₁* dan *C₂*.

<i>P₁</i>	[0,3	3,4	4,6	2,2]
<i>P₅</i>	[5,0	1,5	1,1	2,1]
<i>C₁</i>	[0,3	3,4	1,1	2,1]
<i>C₂</i>	[5,0	1,5	4,6	2,2]

Pada mekanisme mutasi, harus ditentukan dahulu nilai *mutation rate* (*mr*). *Mutation rate* mempunyai fungsi untuk menunjukkan perbandingan *offspring* yang dihasilkan dari mekanisme mutasi terhadap *popSize* sehingga *offspring* yang dihasilkan dapat dituliskan:

$$offspring = mr \times popSize \tag{2.2}$$

Salah satu metode yang diterapkan dalam mekanisme mutasi adalah *reciprocal exchange*. Metode ini memilih dua posisi secara acak dan menukar nilai masing-masing posisi. Misal ditentukan nilai *mr*=0,1 dan *popSize*-10, maka nilai *offspring* yang dihasilkan adalah 0,1 x 10 = 1. Sebagai contoh bila dipilih *P₆* sebagai *parent* dan ditentukan posisi 2 dan 3, maka akan dihasilkan *C₃*.

<i>P₆</i>	[2,3	4,8	1,7	0,1]
<i>C₃</i>	[2,3	1,7	4,8	0,1]

2.1.3 Evaluasi

Proses evaluasi dilakukan untuk menghasilkan nilai *fitness* untuk tiap kromosom. Nilai *fitness* menunjukkan seberapa layak suatu individu untuk dijadikan solusi dalam suatu permasalahan.

2.1.4 Seleksi

Proses seleksi dilakukan untuk mendapatkan individu serta *offspring* dari populasi yang akan dipertahankan pada generasi berikutnya. Salah satu metode yang digunakan adalah *elitism selection*. Pada metode

ini adalah mengumpulkan semua individu dan *offspring* kemudian diambil individu dan *offspring* dengan nilai *fitness* terbaik sejumlah *popSize* untuk dilanjutkan pada generasi selanjutnya.

2.2 Perhitungan MSE

Pada penelitian ini untuk mengukur tingkat kesalahan dalam penelitian digunakan *Mean Square Error* (MSE). MSE adalah salah satu fungsi yang dapat menunjukkan perbedaan antara sebuah peramalan dengan nilai sebenarnya. Semakin kecil nilai MSE, maka semakin kecil pula tingkat kesalahan dalam peramalan (Adwandha, 2017). Cara perhitungan MSE ditunjukkan pada Persamaan 2.3

$$MSE = \frac{1}{n} \sum_{t=1}^n (y'_i - y_i)^2 \tag{2.3}$$

Keterangan:

- n : banyaknya data yang diramalkan
- y' : nilai hasil peramalan
- y : nilai yang sebenarnya

2.3 Fungsi fitness

Fungsi *fitness* merupakan representasi solusi dari suatu permasalahan yang akan diselesaikan. Fungsi *fitness* digunakan untuk mengetahui seberapa baik kualitas dari individu yang ada. Semakin tinggi nilai *fitness* suatu individu, maka semakin baik untuk dijadikan sebagai suatu solusi (Mahmudy, 2015). Fungsi *fitness* pada penelitian ditunjukkan melalui Persamaan 2.4

$$fitness = 1/MSE \tag{2.4}$$

2.4 Jaringan Saraf Tiruan

Jaringan saraf tiruan diperkenalkan oleh Warren McCulloch dan Walter Pitts pada tahun 1943. Metode ini merupakan suatu metode perhitungan yang seolah-olah meniru cara kerja otak manusia. Hubungan antar neuron merupakan karakteristik cara kerja otak manusia. Masing-masing neuron terhubung dengan neuron lain melalui penghubung yang mempunyai nilai bobot. Hubungan ini disebut juga dengan arsitektur, sedangkan metode untuk menentukan nilai bobot penghubungnya disebut dengan pelatihan/training.

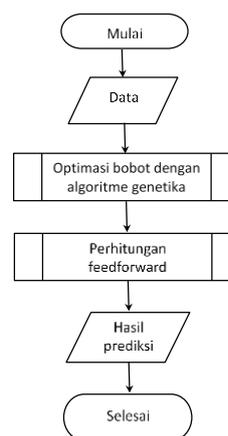
Jaringan saraf tiruan sering diklasifikasikan dengan *single layer* dan *multi layer*. Pada jaringan saraf tiruan *single layer*, *node* pada lapisan *input* akan terhubung secara langsung dengan unit *output*. Suatu jaringan saraf tiruan *multilayer* terdiri dari satu atau lebih jaringan di antara lapisan *input* dan *output*. Jaringan *multi layer* dapat menyelesaikan masalah yang lebih rumit daripada jaringan *single layer*.

Salah satu metode pelatihan bobot pada jaringan saraf tiruan adalah *backpropagation*. *Backpropagation* merupakan salah satu jenis jaringan saraf tiruan dengan metode pembelajaran terawasi (*supervised learning*). Metode ini memiliki karakteristik meminimalkan nilai *error* pada output yang dihasilkan. Terdapat 3 tahapan dalam metode *backpropagation* yaitu *feedforward*, *backpropagation* dan penyesuaian bobot. Dalam metode *backpropagation*, terdapat beberapa persamaan yang digunakan untuk proses pembelajaran yang dilakukan (Fausset, 1994).

3. PEMBAHASAN

3.1 Perancangan Sistem

Sistem yang akan dibangun pada penelitian ini merupakan aplikasi untuk melakukan peramalan debit bendungan. Data debit rata-rata akan dijadikan nilai masukan. Proses perhitungan yang dilakukan aplikasi nantinya adalah optimasi bobot awal yang dilakukan menggunakan algoritme genetika dan bobot hasil dari algoritme genetika tersebut akan dijadikan nilai dalam inialisasi bobot awal dalam proses pembelajaran menggunakan metode *backpropagation*. Hasil dari aplikasi adalah peramalan debit untuk bulan yang akan datang. Secara umum gambaran siste seperti berikut:



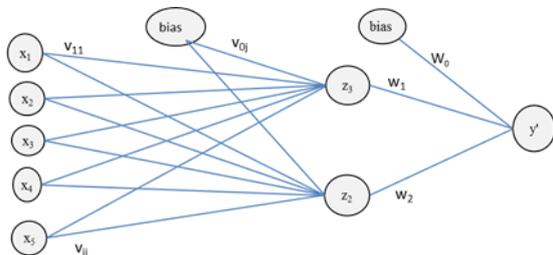
Gambar 2. Diagram Alir Sistem

3.2 Tahapan Algoritma Genetika

3.2.1 Representasi Kromosom

Arsitektur jaringan saraf tiruan akan menentukan representasi kromosom dari tiap individu. Jumlah neuron pada *input layer* ditentukan oleh jumlah bulan yang akan digunakan sebagai *input* pada proses pelatihan. Jumlah neuron pada *hidden layer* akan

menentukan jumlah bobot dan bias yang masuk ke *hidden layer*, selain itu akan menentukan juga jumlah bobot dan bias yang keluar dari *hidden layer* menuju ke *output layer*.



Gambar 3. Arsitektur JST

Dengan arsitektur jaringan saraf tiruan 5-2-1, terdapat 5 neuron pada *input layer*, 2 neuron pada *hidden layer*, 1 *output* seperti pada Gambar 3, maka akan didapatkan representasi kromosom dengan jumlah gen sebanyak 15 gen. *Input* pada sistem berupa data debit bendungan pada 5 bulan sebelumnya.

Representasi kromosom didapatkan dari seluruh nilai bobot pada arsitektur jaringan saraf tiruan. Nilai bobot direpresentasikan dengan $v_{11}, v_{12}, \dots, v_{52}$ dan w_1, w_2 , sedangkan nilai biasnya direpresentasikan dengan v_{01}, v_{02} , dan w_0 . Inisialisasi populasi (*popSize*) terdiri dari 10 individu. Untuk representasi kromosom individu dilakukan secara acak dengan rentang antara -1 sampai dengan 1 dengan representasi kromosom untuk Individu 1 sebagai berikut:

V01	V02	V11	V12	V21	V22	V31	V32
0,328	0,427	0,996	-0,988	0,372	-0,448	0,923	-0,839
V41	V42	V51	V52	W0	W1	W2	
-0,208	-0,026	-0,480	0,843	0,081	-0,101	0,011	

Gambar 4. Representasi Kromosom

3.2.2 Reproduksi

Pada tahapan ini akan dihasilkan *offspring* dari individu terpilih pada generasi awal. Proses yang digunakan adalah proses *crossover* dan mutasi. Metode yang digunakan pada mekanisme *crossover* ini adalah *one cut point*. Pada metode ini ditentukan satu titik potong untuk kemudian dipasangkan dengan kromosom individu yang lain untuk membentuk keturunan yang baru.

Untuk proses mutasi digunakan metode *reciprocal exchange*. Metode ini akan menukar nilai dari 2 buah titik sehingga didapatkan kromosom *offspring* yang baru.

3.2.3 Evaluasi

Proses evaluasi dilakukan dengan cara mendapatkan nilai MSE untuk masing-masing individu baik induk maupun anaknya,

sehingga dapat dilakukan seleksi terhadap individu yang ada. Hasil dari evaluasi masing-masing individu adalah:

Tabel 1. Evaluasi Individu

Individu	MSE	fitness
P1	0,097	10,257
P2	0,113	8,970
P3	0,080	12,519
P4	0,044	22,135
P5	0,052	19,350
P6	0,190	5,276
P7	0,187	5,654
P8	0,060	16,710
P9	0,137	7,263
P10	0,126	7,967
C1	0,098	10,121
C2	0,075	13,381
C3	0,057	17,526

3.2.4 Seleksi

Proses seleksi dilakukan menggunakan metode *elitism selection*. Pemilihan metode ini dilakukan agar setiap individu dengan *fitness* terbaik adalah individu yang akan lolos ke tahap berikutnya. Berdasarkan ukuran populasi, maka individu-individu yang lolos ke tahap berikutnya adalah:

Tabel 2. Seleksi Individu

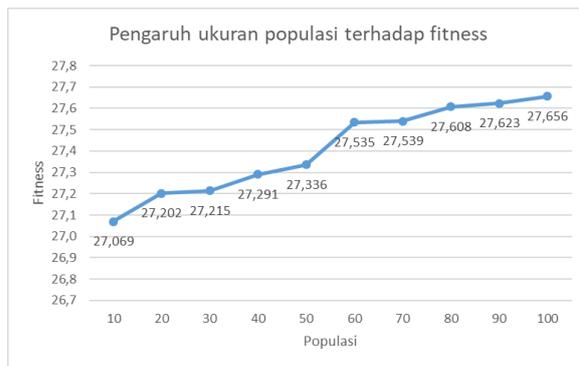
Individu (baru)	Individu (lama)	MSE	fitness
P1	P4	0,045	22,135
P2	P5	0,052	19,350
P3	C3	0,057	17,526
P4	P8	0,060	16,710
P5	C2	0,075	13,381
P6	P3	0,080	12,549
P7	P1	0,097	10,257
P8	C1	0,099	10,111
P9	P2	0,112	8,871
P10	P10	0,125	7,966

4. PENGUJIAN DAN ANALISIS

4.1 Algoritme Genetika

Pengujian berikutnya adalah pengujian parameter-parameter algoritme genetika. Pengujian pertama adalah pengujian pengaruh ukuran populasi. Pengujian ini dilakukan untuk mengetahui pengaruh ukuran populasi terhadap nilai *fitness* yang

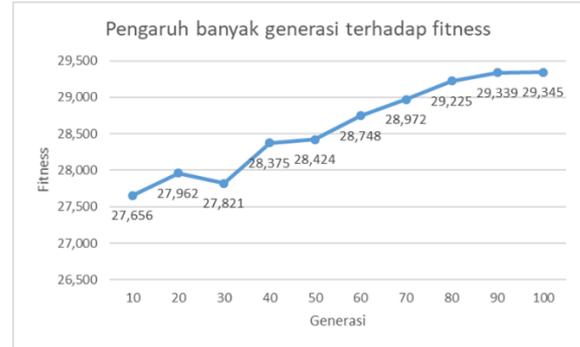
dihasilkan. Semakin tinggi nilai *fitness* yang dihasilkan semakin baik pula hasil pengujian. Pada pengujian ukuran populasi ini digunakan parameter banyak generasi 10, Cr adalah 0,5 dan Mr adalah 0,5. Pengujian dilakukan mulai ukuran populasi 10 sampai dengan 100.



Gambar 5. Grafik hasil pengujian ukuran populasi

Dari hasil uji coba ukuran populasi yang ditampilkan seperti pada Gambar 5, dapat diambil kesimpulan bahwa semakin besar ukuran populasi semakin besar pula nilai *fitness* yang dihasilkan. Ukuran populasi yang besar mencerminkan semakin banyak individu yang dapat ditampung. Semakin banyak individu dalam suatu populasi akan lebih menungkinkan mendapatkan nilai *fitness* dari masing-masing individu yang lebih beragam. Semakin besar ukuran populasi akan memperbesar peluang terjadinya reproduksi baik melalui crossover maupun mutasi sesuai dengan besar parameter Mr dan Cr. Semakin sering terjadi reproduksi maka semakin besar pula peluang untuk mendapatkan nilai *fitness* yang lebih baik dibanding induknya. Nilai *fitness* terbaik didapatkan pada ukuran populasi 100 sebesar 27,65.

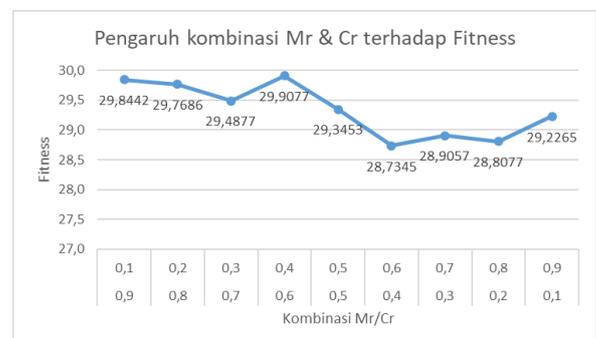
Pengujian banyak generasi ini dilakukan untuk mengetahui pengaruh banyak generasi terhadap nilai *fitness* yang dihasilkan. Parameter yang digunakan pada pengujian ini yaitu ukuran populasi 100, Cr adalah 0,5 dan Mr adalah 0,5. Pengujian dilakukan mulai banyak generasi 10 sampai dengan 100.



Gambar 6. Grafik hasil pengujian banyak generasi

Dari hasil uji coba banyak generasi seperti pada Gambar 6., dapat disimpulkan bahwa semakin banyak generasi maka cenderung mendapatkan nilai *fitness* yang semakin baik. Semakin banyak generasi semakin banyak pula individu yang dihasilkan dan semakin besar pula peluang mendapatkan individu yang memiliki nilai *fitness* yang lebih tinggi. Semakin banyak generasi menunjukkan iterasi yang dilakukan saat proses optimasi menggunakan algoritme genetika, yaitu reproduksi, evaluasi dan seleksi. Semakin sering proses algoritme genetika dilakukan terdapat peluang akan muncul individu baru sebagai individu terbaik dengan nilai *fitness* terbaik. Nilai *fitness* terbaik didapatkan pada banyak generasi 100 sebesar 29,345.

Pengujian kombinasi Cr dan Mr ini dilakukan untuk mengetahui kombinasi Cr dan Mr untuk mendapatkan nilai *fitness* terbaik. Parameter yang digunakan pada pengujian ini yaitu ukuran populasi 100 dan banyak generasi 90.



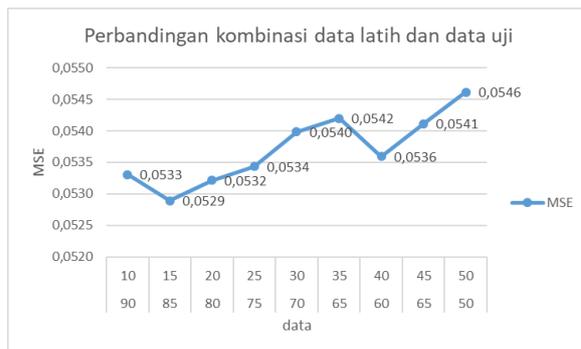
Gambar 7. Grafik pengujian kombinasi Cr dan Mr

hasil pada Gambar 7. dapat disimpulkan bahwa nilai Cr yang lebih besar dibandingkan Mr akan menghasilkan nilai *fitness* yang lebih baik. Nilai Cr dan Mr merupakan parameter yang menentukan

banyaknya jumlah individu yang lahir karena proses reproduksi. Terlihat bahwa pada saat nilai Cr lebih besar daripada Mr, nilai *fitness* yang dihasilkan cenderung lebih besar bila dibandingkan saat nilai Mr lebih besar daripada Cr. Hal tersebut menunjukkan bahwa proses crossover lebih berperan dalam menghasilkan individu-individu dengan nilai *fitness* yang lebih baik dibandingkan proses mutasi. Nilai *fitness* terbaik didapatkan pada kombinasi Cr 0,6 dan Mr 0,4 yaitu sebesar 29,9077.

4.2 Perbandingan Kombinasi Data Latih dan Data Uji

Pengujian ini dilakukan untuk mengetahui komposisi terbaik dari jumlah data latih dan data uji yang digunakan.



Gambar 8. Grafik kombinasi data latih dan data uji

Dari hasil pada Gambar 8 didapatkan bahwa nilai rata-rata MSE terendah didapatkan pada saat rasio data latih:data uji adalah 85:15 dengan nilai MSE terbaik adalah 0,0529. Penggunaan data yang terlalu sedikit cenderung menghasilkan nilai rata-rata MSE yang tinggi, hal tersebut karena terlalu sedikitnya data yang digunakan untuk pembelajaran oleh sistem. Namun data yang banyak juga bukan jaminan bahwa akan didapatkan nilai rata-rata MSE yang paling kecil. Hal tersebut disebabkan adanya kemungkinan jarak antara data tidak membentuk pola yang baik.

4.3 Perbandingan Metode Backpropagation (BP) dan Algoritme Genetika-Backpropagation (GA-BP)

Pengujian ini dilakukan untuk mengetahui perbandingan kinerja metode *backpropagation* dan GA-BP dalam melakukan prediksi debit bendungan.

Tabel 3. Perbandingan BP dan GA-BP

Perco baan	Learning (MSE)		Testing (MSE)	
	BP	GA-BP	BP	GA-BP
1	0,03821	0,03334	0,05025	0,05697
2	0,03655	0,03427	0,06192	0,04539
3	0,03655	0,03627	0,04792	0,04439
4	0,02455	0,02027	0,03792	0,03739
5	0,03455	0,03427	0,04192	0,04739
6	0,02255	0,02739	0,03292	0,03039
7	0,03155	0,02927	0,03792	0,03239
8	0,02955	0,03327	0,03792	0,03739
9	0,04213	0,02960	0,04828	0,04931
10	0,02809	0,02823	0,04477	0,03782
Rata-rata	0,03243	0,03062	0,04417	0,04188

Dari hasil pada Tabel 3 terlihat bahwa hasil pengujian dari GA-BP memiliki nilai MSE yang lebih baik dibandingkan dengan metode *backpropagation*. Nilai MSE yang lebih rendah menunjukkan hasil yang lebih baik

5. KESIMPULAN

Berdasarkan hasil pengujian yang dilakukan, paramete pelatihan optimal algoritme genetika adalah populasi=100, generasi=100, kombinasi Cr dan Mr berturut-turut 0,6 dan 0,4. Parameter pelatihan optimal metode *backpropagation* adalah jumlah iterasi=500, nilai learning rate= 0,7. Hasil pelatihan menggunakan parameter optimal mendapatkan nilai MSE = 0, 04188.

6. DAFTAR PUSTAKA

Adwandha, D. P. D. E. R. P. A., 2017. Prediksi Jumlah Pengangguran Terbuka di Indonesia. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, Vol. 1(No. 4), pp. 341-351.

Anindita, A. P. & Laksono, P., 2016. *Dam Water Level Prediction System Utilizing Artificial Neural Network Back Propagation*. Surabaya, 2016 International Conference on ICT For Smart Society.

Fausset, L., 1994. *Fundamentals of Neural Networks: Architectures, Algorithms and Applications*. s.l.:Oxford: Addisen-Wesley Publishing Compnane, Inc..

Haviluddin, A. R., 2015. *A Genetic-Based Backpropagation Neural Network for Forecasting in Time-Series Data*. s.l.,

- International Conference on Science in Information Technology (ICSITech).
- Liu, Q. & Liu, M., 2016. *A Fault Prediction Method Based on Modified Genetic Algorithm Using BP Neural Network Algorithm*. Budapest, Hungary, IEEE International Conference on Systems, Man, and Cybernetics'.
- Mahmudy, W. F., 2015. *Dasar-Dasar Algoritma Evolusi*. Malang: Program Teknologi Informasi dan Ilmu Komputer (PTIIK) Universitas Brawijaya.
- Perum Jasa Tirta I, 2014. *Manual Operasi dan Pemeliharaan Bendungan Sengguruh*, Malang: Perum Jasa Tirta I.
- Somlek, C., Kaewchainam, N., Simano, T. & So-In, C., 2016. *Usin backpropagation neural network for flood forecasting in PhraNakon Si Ayutthaya, Thailand*. s.l., ICSEC 2015-19th International Computer Science and Engineering Conference.