PENERAPAN ALGORITMA GENETIKA PADA PELATIHAN JARINGAN SYARAF TIRUAN UNTUK PERAMALAN DEBIT *INFLOW* WADUK SENGGURUH

Dafid Eko Firdaus[1], Muh. Arif Rahman[2], Achmad Ridok[3]
Jurusan Ilmu Komputer, Program Teknologi Informasi dan Ilmu Komputer ,
Universitas Brawijaya Malang
Jl. Veteran No.8 Malang, 65145, Indonesia
E-mail: david.firdaus@hotmail.co.id, m_arif @ub.ac.id, acridokg@gmail.com

ABSTRAK

Waduk merupakan salah satu sumber daya yang memiliki banyak fungsi, diantaranya sebagai sumber energi dalam pengelolaan Pembangkit Listrik Tenaga Air (PLTA), irigasi lahan pertanian, pasokan persediaan Perusahaan Air Minum dan berfungsi sebagai pencegah banjir. Dengan vitalnya peran waduk tersebut diperlukan suatu strategi pengelolaan waduk agar mendapatkan hasil yang optimal dalam pengoperasiannya, salah satunya dengan meramalkan debit inflow (debit masuk). Pada penelitian ini digunakan Jaringan Syaraf Tiruan sebagai model peramalan debit inflow dengan metode pelatihan Algoritma Genetika. Pelatihan Jaringan Syaraf Tiruan menggunakan Algoritma Genetika dilakukan dengan mengkodekan bobot dan bias jaringan kedalam kromosom dan nilai fitness didapat dari error hasil proses feddforward. Pada penelitian ini beberapa parameter genetika seperti besar probabilitas crossover (pc) dan jumlah generasi mempengaruhi besar nilai fitness maksimal yang didapat pada proses pelatihan. Hasil pelatihan digunakan untuk melakukan peramalan keakuratan mencapai 87,272%.
Kata kunci : Algoritma Genetika , Jaringan Syaraf Tiruan, Peramalan, Debit Inflow Waduk

ABSTRACT

The reservoir is one resource that has many functions, such as an energy source in the management of Hydroelectric Power Plant (HEPP), irrigation of agricultural land, drinking water supply and serves as a flood prevention. With that many vital role, the reservoir required a management strategy in order to obtain optimal results in the operation, one of them is forecast the inflow. In this study, Artificial Neural Networks are used as inflow forecasting model with Genetic Algorithm training methods. Training Neural Network using Genetic Algorithms is implemented with encode the network weights and biases into the chromosome and fitness values obtained from the cumulative error feedforward process. In this study, several parameters such as the probability of genetic crossover (pc) and the number of generations influence the maximum fitness value obtained in the training process. The results of the training are used to perform forecasting accuracy achieved 87.272%.
Keywords: *Genetic Algorithms, Neural Networks, Forecasting, Reservoir Inflow*

1. Pendahuluan

1.1. Latar Belakang

Waduk merupakan salah satu sumber daya yang memiliki peran penting dalam berbagai sektor kehidupan. Dibangunnya sebuah waduk memiliki beberapa fungsi, diantaranya sebagai sumber energi dalam pengelolaan Pembangkit Listrik Tenaga Air (PLTA), irigasi lahan pertanian, pasokan persediaan Perusahaan Air Minum dan berfungsi sebagai pencegah banjir. Dengan fungsi yang bermacam-macam tentunya diperlukan suatu strategi pengoperasian untuk pengelolaan suatu waduk. Kesalahan dalam pengoperasian dapat menyebabkan kekurangan atau kelebihan tampungan air (*storage*) atau kesalahan pelepasanan air (*release*). Terjadinya banjir adalah salah satu akibat kesalahan dalam penentuan *release* ataupun *storage* yang tidak memadai dapat mengakibatkan *supply* untuk irigasi pertanian menjadi berkurang [1].

Secara umum sistem pengoperasian waduk haruslah mempertimbangkan keseimbangan debit air masuk (*inflow*) dan debit air keluar (*outflow*). Keadaan optimal dari pengoperasian suatu waduk dapat dicapai apabila dalam analisisnya mempertimbangkan *storage* (persediaan) dan *release* (pelepasan air), yaitu dengan memanfaatkan semaksimal mungkin debit air yang ada dan dengan sebijak mungkin mendistribusikan air keluar. Besarnya pengeluaran air dari suatu waduk untuk didistribusikan dipengaruhi oleh besarnya debit *inflow* waduk, dengan diketahui *inflow* maka dapat diatur seberapa *release* (pelepasan air) dan *storage* (persediaan) dapat dipertahankan di level yang seharusnya. Maka penting untuk mengetahui besarnya debit *inflow* di masa yang akan datang [2].

Jaringan Syaraf Tiruan (JST) telah diaplikasikan ke banyak bidang, salah satunya pada tahun 1990an mulai dikembangkan model Jaringan Syaraf Tiruan untuk model hidrologi. Studi yang dilakukan

sebelumnya menyatakan bahwa Jaringan Syaraf Tiruan mampu menghubungkan *input* dan *output* simulasi dan model peramalan besar aliran sungai (*rainfall-runoff*) tanpa membutuhkan stuktur internal DAS [3].

Pengembangan Jaringan Syaraf Tiruan pada proses peramalan dipengaruhi oleh beberapa hal, kualitas data dan arsitektur jaringan (banyak neuron dan banyak layer) berpengaruh pada performansi model JST, serta titik awal penentuan bobot secara *random* berpengaruh pada konvergensi poses pelatihan. Selain itu JST memiliki kelemahan dalam proses *training* yang dapat mengakibatkan komputasi dapat terjebak dalam satu lokal optimum. Dengan demikian dibutuhkan suatu cara agar *optimum global* dapat tercapai. Salah satu algoritma optimasi yang dapat diaplikasikan adalah Algoritma Genetika pada proses pelatihan Jaringan Syaraf Tiruan [4][5].

Algoritma Genetika adalah algoritma pencarian heuristik yang didasarkan atas mekanisme crossover dan mutasi. Algoritma ini diilhami oleh teori evolusi Charles Darwin dimana individu terbaik merupakan kandidat yang dapat bertahan dari seleksi alam. Algoritma genetika dimulai dari pembentukan himpunan kandidat solusi yang disebut populasi, dimana setiap kandidat solusi diwakili oleh satu individu atau kromosom [6].

Dari penelitian sebelumnya yang dilakukan oleh (Putri, 2012) didapatkan hasil bahwa JST dengan pelatihan Algortma Genetika memiliki nilai keakuratan yang tinggi yaitu mencapai 90%. Nilai keakuratan tersebut membuktikan bahwa metode tersebut mampu memberikan solusi masalah yang baik.s Berdasarkan latar belakang yang dijelaskan tersebut, pada penelitian ini digunakan algoritma genetika pada pelatihan jaringan syaraf tiruan untuk peramalan debit inflow harian waduk [7].

2. Metodologi Penelitian

2.1. Data

Data yang digunakan pada penelitian ini adalah data debit *inflow* harian Waduk Sengguruh Kabupaten Malang dan data curah ujan harian dari 4 (empat) stasiun pencatat otomatis disekitar DAS Brantas, yaitu Stasiun Wagir, Stasiun Tangkil, Stasuin Dampit dan Stasiun Pujon yang menginduk ke Waduk Sengguruh. Rentang data selama 2 (dua) tahun dari tahun 2008 hingga 2009 yang diambil dari Perum Jasa Tirta I dengan alamat Jl. Surabaya 2A Malang.

Waduk Sengguruh terletak di Desa Sengguruh, Kecamatan Kepanjen, Kabupaten Malang, Propinsi Jawa Timur. Waduk Sengguruh dibangun sebagai penahan sedimen yang masuk ke Waduk Sutami, sehingga dapat memperpanjang umur ekonomis Waduk Sutami. Fungsi lain adalah sebagai pembangkit tenaga listrik dengan daya terpasang 2 x 14,5 MW dan produksi listrik tahunan 91 juta kWh.

Waduk Sengguruh dialiri air dari Sunggai Amprong dan Sungai Lesti, keduanya merupakan sub-DAS Brantas. Data debit harian waduk ini akan dperamalan untuk membantu pengoperasian waduk secara optimal.

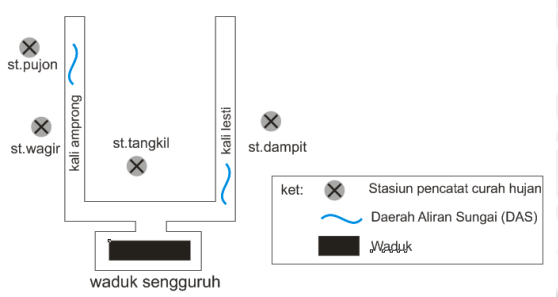

Gambar 1. Denah Waduk Sengguruh

2.2. Model Jaringan Syaraf Tiruan

Pada penelitian ini data *input* didapat dari data curah hujan dan data debit dihari ke-*t*. Untuk data curah hujan, terdapat empat data curah hujan yang didapat dari empat stasiun pencatat otomatis di sekitar sub-Das Brantas yang digunakan sebagai parameter *input.seda* sedangkan debit *inflow* waduk sengguruh diramal pada waktu *(t+1)*. Sehingga jumlah neuron yang digunakan adalah 5 pada neuron *input* dan 1 pada neuron *output*. Untuk banyak neuron dan banyak lapiran pada *hidden layer* tidak ada ketentuan yang mengikat, sehingga pada penelitan in digunakan 1 *layer* dan 5 neuron pada *hidden layer*. Penentuan ini mengacu pada penelitian (Setian, 2004) yang menggunakan arsitektur 5-5-1 yaitu dengan 5 neuron *input*, 5 neuron *hidden* dan 1 neuron *output* didapat hasil peramalan yang cukup baik [3].

Arsitektur jaringan yang digunakan pada penelitian ini ditunjukkan pada gambar 2.

Langkah-langkah proses *feedforward* adalah [6] :

1. Inisialisasi bobot (ambil bobot awal dengan nilai random yang cukup kecil).
2. Kerjakan langkah-langkah berikut selama kondisi berhenti bernilai salah.

   Untuk tiap-tiap pasangan elemen yang akan dilakukan pembelajaran, kerjakan:

Feedforward:

a. Tiap-tiap neuron input (xi, i=1, 2, 3, ..., n) menerima sinyal xi dan meneruskan sinyal tersebut ke semua neuron pada lapisan di atasnya (lapisan tersembunyi).

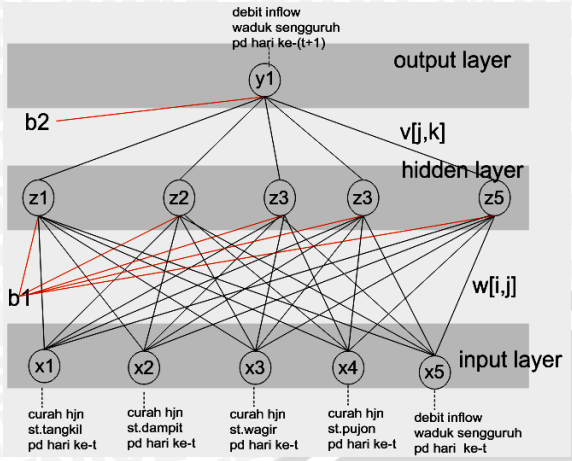

Gambar 2. Arsitktur jaringan syaraf yang digunakan

b. Tiap-tiap neuron pada suatu lapisan tersembunyi (zj, j=1, 2, 3, ..., p) menjumlahkan sinyal-sinyal input terbobot :

$$z_in_j = w_{0j} + \sum_{i=1}^{n} x_i w_{ij}$$

c. Gunakan fungsi aktivasi untuk menghitung sinyal outputnya :

$$z_j = f(z_in_j) = \frac{1}{1 + e^{z_in_j}}$$

d. Tiap-tiap neuron output (yk, k=1, 2, 3, …, m) menjumlahkan sinyal-sinyal input terbobot.

$$y_in_k = v_{0k} + \sum_{i=1}^{p} z_i v_{jk}$$

e. Gunakan fungsi aktivasi untuk menghitung sinyal outputnya :

$$y_k = f(y_in_k) = \frac{1}{1 + e^{y_in_k}}$$

2.3. Pelatihan JST dengan AG

Tujuan digunakan algoritma genetika pada penelitian ini adalah sebagai algoritma pelatihan pada jaringan syaraf tiruan.

Algoritma genetika yang mampu mencapai global optima, dimaksudkan sebagai pengganti algoritma pelatihan yang selama ini ini sering digunakan misalnya *backpropagation,* sehingga diharapkan jaringan syaraf tiruan mampu melakukan peramalan debit *inflow* harian dengan baik. Proses pelatihan JST menggunakan AG dilakukan dengan langkah-langkah di bawah ini:

1. Mengkodekan bobot dan bias JST ke dalam kromosom dengan reprsentasi *real*.
2. Menentukan fungsi *fitness* suatu kromosom yaitu mendapatkan komulatif *error* dari satu kali proses penalaran maju (*feedforward*) dengan satu set data latih.
3. Inisialisasi populasi dengan random kromosom. Setiap kromosom diisi dengan nilai random antara -1 hingga 1 sebagai representasi dari bobot JST.
4. Melakukan proses genetika untuk mendapatkan inidividu terbaik.

Secara jelas alur pelatihan JST menggunakan Algoritma Genetika dapat dilihat gambar 4.

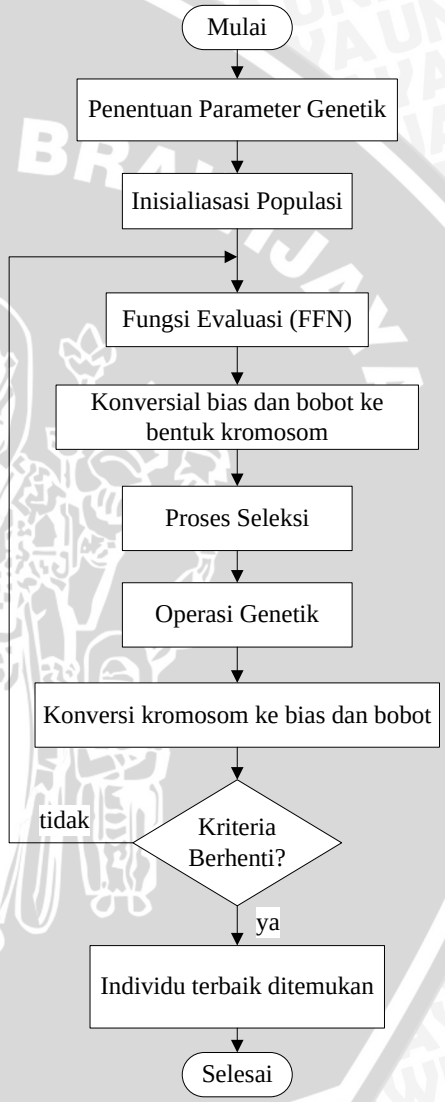

Gambar 4. Alur Pelatihan JST menggunakan AG

2.3.1. Pengkodean Kromosom

Konfigurasi bobot (*weight*) pada satu struktur jaringan syaraf tiruan di*encode* kedalam satu individu pada Algoritma genetika. Kromosom hanya berisi bobot tidak berisi topologi dari jaringan. Bobot dan bias dari jaringan syaraf tiruan dikodekan

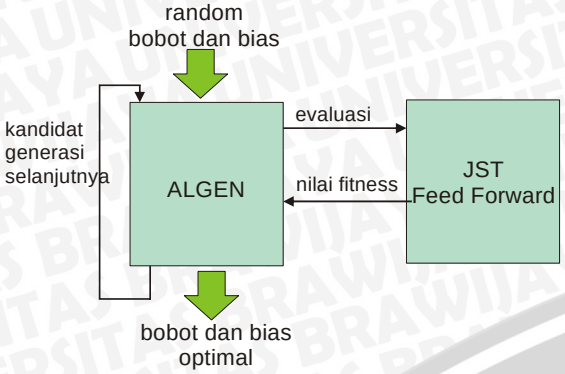

Gambar 3. Proses pelatihan JST menggunakan GA

kedalam gen-gen yang membentuk satu kromosom utuh. Bentuk kromosom secara struktur data merupakan *array* satu dimensi yang nantinya akan diisi dengan bobot dan bias. Secara visual pengkodean dari arsitektur jaringan kedalam satu kromosom dijelaskan pada Lampiran 1.

2.3.2. Nilai *Fitness*

Fungsi *fitness* atau fungsi evaluasi digunakan untuk mendapatkan nilai kekuatan (*fitness*) atau nilai yang menunjukkan seberapa baik suatu individu atau kromosom. Dalam penelitian ini kromosom yang berupa konfiguragi bobot dan bias suatu jaringan, maka nilai *fitness* didapat dengan proses *feedforward* untuk menghitung *output* jaringan kemudian dihitung selisih *output* tersebut dengan data aktual. Dapat dikatakan nilai *fitness* didapat dari perhitungan *error* suatu jaringan dengan menggunakan bobot tertentu (sesuai dengan nilai kromosom). Proses *feedforward* ini dilakukan sesuai dengan banyak data sehingga dilakukan berulang dan *error* komulatif digunakan sebgai nilai *fitness*. Fungsi fitness yang digunakan pada penelitian ini diperoleh dari persamaa beikut

$$f = \frac{1}{1 + \sum_{k=0}^{m} (y_k - t_k)^2}$$

f= fungsi *fitness*
t_k= target pada untuk jaringan syaraf tiruan
y_k= *output* yang dihasilkan pada proses *feedforward*

.

2.3.3. Seleksi Orang Tua

Metode seleksi yang akan digunakan dalam penelitian adalah *Roulette Wheel Selection*. Pada metode *Roulette Wheel Selection* individu-individu pada populasi dipetakan kedalam segmen-segmen garis berskala secara berurutan, dimana lebar dari segmen yang ditempati individu sebanding dengan besar *fitness* yang dimikinya. Sehingga individu yang memiliki *fitness* bagus akan memiliki segmen yang lebih besar. Kemudian mekanisme pemilihannya adalah dengan membangkitkan bilangan *random* dan individu yang menempati segmen yang sesuai dengan bilangan *random* yang telah dibangkitkan merupakan individu terpilih[6].

Individu ke	1	2	3	4
Fitness	169	576	64	361
Probabilitas	14,4%	49,2%	5,5%	30,9%

Gambar 5. Contoh seleksi *parent* menggunakan *Roulette Wheel Selection*

2.3.4. *Crossover*

Metode *crossover* yang digunakan adalah *simple arithmetic crossover*, yaitu metode persilangan dimana keturunan (*child*) didapat dengan melakukakan operasi rata-rata nilai gen dari *parent* pada titik tertentu. Tidak semua *parent* mengalami proses persilangan, hanya *parent* yang mampu melewati batas peluang *crossover* yang berhak menikuti proses persilangan . *Child* diperoleh dengan persamaan:

$x'_1 = \alpha \cdot x_1 + (1 - \alpha) \cdot x_2$ dan
$x'_2 = \alpha \cdot x_2 + (1 - \alpha) \cdot x_1$

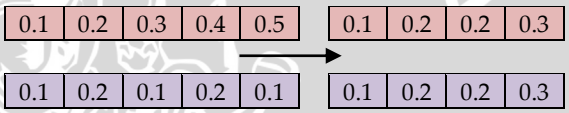

Gambar 6. Arithmetical Crossover dengan a=1/2.

2.3.5. Mutasi

Mutasi pada *floating point representation* ada dua macam metode mutasi yang dapat digunakan, salah satunya adalah *Uniform Mutation.* Operator jenis ini membutuhkan satu *parent* x dan akan menghasilkan satu child x'. Uniform mutation memilih satu komponen secara acak dari vector *parent* x = {x1,....,xq} untuk kemudian menghasilkan *child* x'= {x1,.xk...,xq}. Dimana x-k merupakan bilangan random antara batas bawah (left(k)) dan batas atas (right(k)) [7].

Uniform mutation digunakan pada penelitian ini yaitu dengan mengganti nilai gen yang terkena mutasi pada *parent* dengan nilai random antara 0 dan 1. Seperti halnya *crossover*, tidak semua *parent* mengalami mutasi. Hanya parent dengan peluang melebihi probabilitas mutasi yang akan mengalami proses mutasi. Mutasi menghasilkan satu keturuan yang berarti menghasilkan konfigurasi bobot dan bias yang baru pada jaringan.

3. Perancangan

Sistem yang akan dibuat mengadopsi model JST sebagai mesin peramalan dibit *inflow* waduk. Model JST terlebih dahulu harus dilakukan proses pencarian konfigurasi bobot yang optimal sebelum

dilakukan proses peramalan. Ada beberapa tahapan yang dilalui sistem, diantaranya tahap normalisasi data, tahap pelatihan data dan tahap peramalan. Sebelum dilakukan proses pelatihan maupun peramalan, data harus terlebih dahulu dilakukan normalisasi agar data berada pada batas yang sudah ditetapkan, yaitu antara *range* [0,1]. Kemudian dilakukan proses pelatihan data dimana proses *learning* terjadi pada tahap ini, yaitu proses pencarian konfiguasi bobot dan bias yang optimal sehingga dapat digunakan untuk tahap peramalan. Tahapan yang akan dilakukan secara umum disajikan dalam *flowchart* pada gambar 8.

Secara umum sistem yang dibangun terbagi menjadi dua proses utama, yaitu :

1. Pelatihan (*training*) dan
   JST terlebih dahulu harus dilakukan proses *training* atau pencarian konfigurasi bobot yang optimal sebelum dilakukan proses peramalan. Dalam sistem ini digunakan Algoritma Genetika untuk mencari konfigurasi bobot JST yang optimal, langkah-langkah pelatihan JST dengan AG dijelaskan pada gambar 4.
2. Pengujian (*testing*)
   Konfigurasi bobot dan bias yang didapat dari proses pelatihan kemudian digunakan pada proses testing atau disebut sebagai proses peramalan. *Input* data curah hujan hari tertentu (hari ke-*t*) dan debit hari sebelumnya (hari ke-(*t-n*)) dilakukan proses *feedforward* dengan bobot dan bias yang didapat *output* berupa hasil peramalan debit i*nflow* pada hari berikutnya (hari ke-(*t*+1)).

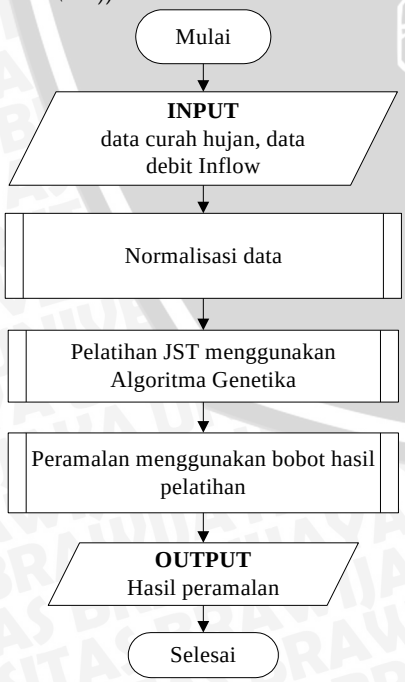

Gambar 7. Alur Proses Sistem secara umum

4. Hasil dan Pembahasan

Uji coba pada penelitian peramalan debit *inflow* Waduk Sengguruh ini dilakukan untuk mengetahui parameter genetika apa saja yang mempengaruhi hasil pelatihan jaringan syaraf tiruan, dengan menggunakan algoritma genetika sebagai algoritma pembelajaran.

Pengujian pertama adalah mengetahui pengaruh perubahan peluang crossover dan peluang mutasi terhadap nilai fitness yang dihasilkan pada proses pelatihan JST dengan menggunakan AG.

Berdasarkan grafik perbandingan *pc* dan *pm* dengan nilai *fitness* pada lampiran 2, dapat dilihat seiring perubahan nilai peluang *crossover* maka nilai *fitness* yang didapat cenderung semakin besar. Perubahan nilai *fitness* juga dipengaruhi oleh peluang mutasi sehingga tidak semua nilai *fitness* naik untuk setiap kenaikan peluang *crossover*, namun pada nilai peluang mutasi yang sama nilai *fitness* cenderung meningkat pada setiap kenaikan nilai *crossover*. Hal tersebut dapat disebabkan karena semakin sering proses *crossover* terjadi sehingga variasi individu yang didapat semakin banyak. Telah diketahui bahwa semakin besar nilai peluang *crossover* maka semakin banyak kemungkinan individu yang disilangkan (*crossover*), tentunya akan semakin banyak individu baru yang diciptakan. Dengan demikian peluang untuk didapatkan individu yang memiliki nilai *fitness* yang tinggi akan semakin besar.

Sedangkan untuk peluang mutasi dapat kita lihat pada grafik di bawah, bahwa setiap kenaikan nilai peluang mutasi tidak diikuti pula dengan kenikan *fitness*. Misalkan pada saat nilai peluang *crossover* 0.6, dimana nilai *fitness* turun dari peluang mutasi 0.1 hingga 0.5 kemudian naik kembali setelah peluang mutasi diatas 0.5. hal tersebut berbeda pada saat nilai peluang *crossover* 0.8, dimana nilai *fitness* cenderung turun seiring bertambahnya nilai peluang mutasi. Dengan demikian nilai peluang mutasi yang tinggi tidak selalu menghasilkan nilai *fitness* yang tinggi pula. Metode mutasi yang digunakan yaitu *uniform mutation* dimana beberapa nilai gen pada kromosom diganti secara acak dengan bilang antara 0 dan 1 tidak menjamin anak hasil mutasi memiliki *fitness* yang lebih baik. Sedikitnya jumlah gen yang dimutasi memungkinkan kromosom *parent* dengan *fitness* yang rendah tidak mampu memperbaiki nilai *fitness* secara signifikan dan masih mewariskan sifat buruknya kepada kromosom anak. Hal inilah yang menyebabkan nilai peluang mutasi secara tidak teratur mempengaruhi besar nilai *fitness* pada proses pelatihan.

Pengujian yang kedua adalah mengetahui pengaruh perubahan jumlah generasi terhadap besar nilai *fitness* maksimum yang dihasilkan pada pelatihan JST dengan AG. Hasil uji coba disajikan dalam grafik pada lampiran 3.

Grafik perbandingan jumlah generasi dan nilai *fitness* di atas dapat dikatakan cenderung naik, yaitu setiap pertambahan jumlah generasi akan diikuti pula bertambahnya nilai *fitness.* Meskipun pada kenyataannya nilai *fitness* akan mengalami penurunan pada generasi 300, tapi pada akhirnya grafik akan naik kembali. Grafik yang fluktuatif disebabkan oleh *starting point* algoritma genetika yang *random*, hal ini mengakibatkan rentang nilai yang didapat tidak seragam. Sehingga harus dilakukan beberapa kali uji coba untuk kemudian dilakukan rata-rata.

Jumlah generasi yang tinggi akan mengakibatkan proses evolusi semakin sering dilakukan, sehingga semakin besar kesempatan untuk terjadinya proses pembentukan individu-individu baru. Pada setiap satu generasi, akan dilakukan beberapa kali proses *crossover* dan mutasi, dimana pada proses ini individu baru akan dihasilkan. Semakin sering proses *crossover* dilakukan maka individu baru yang terbentuk akan semakin banyak dan variasi *fitness* akan semakin beragam. Dengan demikian kemungkinan ditemukannya individu dengan nilai *fitness* tinggi akan semakin besar.

Pengujian berikutnya dilakukan untuk mengetahui pengaruh ukuran populasi terhadap nilai *fitness* yang didapat pada proses pelatihan JST dengan AG. Hasil uji coba disajikan dalam grafik pada lampiran 4.

Ukuran populasi yang besar memungkinkan terdapat variasi individu yang beragam dan ukuran populasi yang kecil kemungkinan variasi individu bisa terbatas sedikit. Jika dilihat dari grafik hasil uji coba di atas yang *fluktuatif,* tidak menjamin bahwa ukuran populasi yang besar dapat menghasilkan nilai *fitness* yang besar pula begitu juga dengan sebaliknya. Hal ini dapat disebabkan pada saat pemilihan *parent* untuk proses *crossover* dan mutasi. Pada populasi yang besar tentunya proporsi individu dengan nilai *fitness* rendah juga semakin besar, sehingga individu tersebut memiliki peluang lebih besar untuk terpilih sebagai *parent.* Apabila *parent* yang terpilih adalah individu dengan nilai *fitness* kecil, anak yang dihasilkan dari proses rekombinasi juga kemungkinan memiliki nilai *fitness* kecil. Hal yang sama terjadi pada ukuran populasi yang kecil dimana variasi individu di dalamnya sedikit. Individu yang akan terpilih sebagai *parent* memiliki variasi terbatas, dan anak yang dihasilkan memungkinkan memiliki sifat yang mirip dengan nilai *fitness* yang hampir dekat (tidak mengalami improvisasi). Dengan demikian untuk menghasilkan nilai *fitness* yang maksimal perlu dilakukan pencarian berapakah ukuran populasi idel, pada uji coba ini nilai *fitness maximum* didapat pada saat ukuran populasi 250.

Untuk mengetahui akurasi peramalan oleh sistem maka dilakukan pengujian tingkat akurasi. Pengujian dengan melakukan proses peramalan dengan JST menggunakan konfigurasi bobot terbaik yang didapat selama pelatihan, yaitu menggunakan konfigurasi bobot dari kromosom dengan nilai *fitness* 0,1994.

Grafik menunjukkan bahwa output jaringan dapat mengikuti pola dari naik dan turunnya nilai debit *inflow* aktual. Jarak antara output jaringan dan data aktual ini bervariasi dan jarak paling besar dapat mencapai puluhan. Jarak yang mendominasi adalah satuan. Nilai MAPE pada proses peramalan ini adalah 11,05%.

Untuk mengetahui pengaruh nilai *fitness* dengan tingkat akurasi dari sistem dilakukan pengujian nilai MAPE sebanyak 10 kali untuk kemudian mendapatkan nilai rata-ratanya. Pengujian 10 kali dilakukan dengan konfigurasi bobot JST yang berbeda-beda yang didapat dari proses pelatihan menggunakan algoritma genetika. Berikut hasi uji coba dapat dilihat pada tabel 1.

Tabel 1 Uji coba akurasi

No.	Fitness	MAPE	MAPE (%)
1	0,19176	0,1340	13,405%
2	0,19362	0,1388	13,883%
3	0,19486	0,1272	12,722%
4	0,19501	0,1287	12,868%
5	0,19502	0,1288	12,878%
6	0,19508	0,1230	12,302%
7	0,19658	0,1282	12,822%
8	0,19735	0,1237	12,374%
9	0,198	0,1309	13,085%
10	0,19948	0,1222	12,220%
Rata-rata		0,1286	12,856%

Berdasarkan tabel 1 di atas setelah dilakukan uji coba beberapa kali menggunakan kromosom dengan fitness yang berbeda, didapatkan nilai akurasi MAPE berkisar diantara 12%. Tidak ada pergerakan data yang signifikan baik naik maupun turun dengan nilai selisih yang besar. Dapat dilihat pada tabel 1 bahwa nilai MAPE terbesar terjadi pada saat nilai

fitness 0,19362 dan MAPE terkecil terjadi pada fitness terbesar yaitu 0,19948. Nilai MAPE yang diperoleh tidak stabil, namun cenderung berada pada rentang nilai yang tetap seiring dengan bertambahnya nilai fitness.

Banyaknya data latih untuk jaringan syaraf tiruan mempengaruhi nilai fitness, semakin banyak data maka akan semakin banyak nilai *error* yang dihitung dan dijumlahkan untuk mendapatkan nilai *fitness*. Sehingga semakin banyak data latih nilai *fitness* yang didapatkan akan semakin kecil. Nilai fitness yang besar tidak selalu menghasilkan MAPE yang kecil, hal ini dikarenakan nilai *fitness* diambil dari nilai komulatif *error* sedangkan MAPE didapat dari error rasio.

Semakin kecil nilai MAPE dari peramalan maka akan semakin besar pula tingkat akurasi dari jaringan syaraf tiruan untuk melakukan peramalan. Sehingga dapat disimpulkan bahwa semakin besar nilai *fitness*, maka nilai *error* permalan jaringan syaraf tiruan akan semakin kecil. Pada percobaan ini nilai MAPE rata-rata sebesar 12,728% sehingga dapat dikatakan sistem mampu melakukan peramalan dengan tingkat akurasi 87,272%.

5. Kesimpulan

Setelah melakukan penelitian maka dapat disimpulkan bahwa :

1. Algoritma Genetika dapat diterapkan pada pelatihan Jaringan Syaraf Tiruan untuk melakukan peramalan debit inflow Waduk Sengguruh. Model Jaringan Syaraf Tiruan yang digunakan adalah 5-5-1 yaitu 5 (lima) neuron input 5 (lima) neuron hidden dan 1(satu) neuron output. Pelatihan dengan algoritma genetika dilakukan dengan mengkodekan bobot dan bias kedalam kromosom, setiap bobot atau bias jaringan syaraf tiruan ditetapkan sebagai gen sehingga total terdapat 36 gen yang tersusun dari bobot dan bias baik dari input layer ke hidden layer maupun dari hidden layer ke output layer. Nilai fitness tiap kromosom didapatkan dari error akumulatif hasil proses feedforward. Kromosom terbaik dari proses pelatihan tersebut digunakan sebagai konfigurasi bobot dan bias Jaringan Syaraf Tiruan untuk proses peramalan debit inflow Waduk Sengguruh.
2. Pelatihan Jaringan Syaraf Tiruan menggunakan Algoritma Genetika dipengaruhi oleh beberapa parameter genetika. Perubahan probabilitas crossover menunjukkan bahwa semakin besar nilai probabilitas crossover maka nilai fitness yang dihasilkan juga semakin besar. Hal ini juga berlaku untuk parameter jumlah generasi, dimana penambahan jumlah generasi juga diikuti bertambahnya nilai fitness yang didapat. Untuk nilai probabilitas mutasi dan ukuran populasi perubahan nilainya tidak memberikan dampak yang signifikan terhadap nilai fitnesss yang dihasilkan, namun pada rentang tertentu nilai probabilitas mutasi dan ukuran populasi akan menghasilkan nilai fitness yang optimal.
3. Tingkat akurasi rata-rata sistem peramalan debit inflow Waduk Sengguruh yang dibuat mencapai 87,272%. Sistem yang dibuat menggunakan 515 data latih dan diuji menggunakan 215 data uji.

DAFTAR PUSTAKA

[1]. Nuraeni, Y. (2011). *Metode Memperkirakan Debit Air yang Masuk ke Waduk dengan Metode Stokhastik Chain Markov (Studi Kasus: Pengoperasian Waduk Sengguling)* , 14.

[2]. Susilowati, & Hastiningrum. (2005). *Peramalan Inflow Waduk Berdasarkan Outflow Menggunakan Persamaan Kontinuitas* , 6.

[3]. Setian, I. B., & Rudiyanto. (2004). *Aplikasi Neural Network untuk Peramalan Aliran Sungai* , 6.

[4]. Sarangi, P. K., Sigh, N., Cauhan, R., & Sigh, R. (2009). *Short Term Load Forecasting Using Artificial Neural Network: A Comparison With Genetic Algorithm Implementation* , 6.

[5]. Seiffert, U. (2001). *Multi Layer Perceptron Training Using Genetic Algorithms* , 6.

[6]. Kusumadewi. (2003). *Arificial Intelegence.* Jakarta: Erlangga.

[7]. Kania. (2012). *Penerpan Algortima Genetika pada Pelatihan Feedforward Network*.

[8]. Michalewicz, Z. (1999). *Genetic Algorithms + Data Structure = Evolution Programs.* New York: Springer Verlag Berlin Heidelberg.

LAMPIRAN

LAMPIRAN - 1
Skema pengkodean kromosom

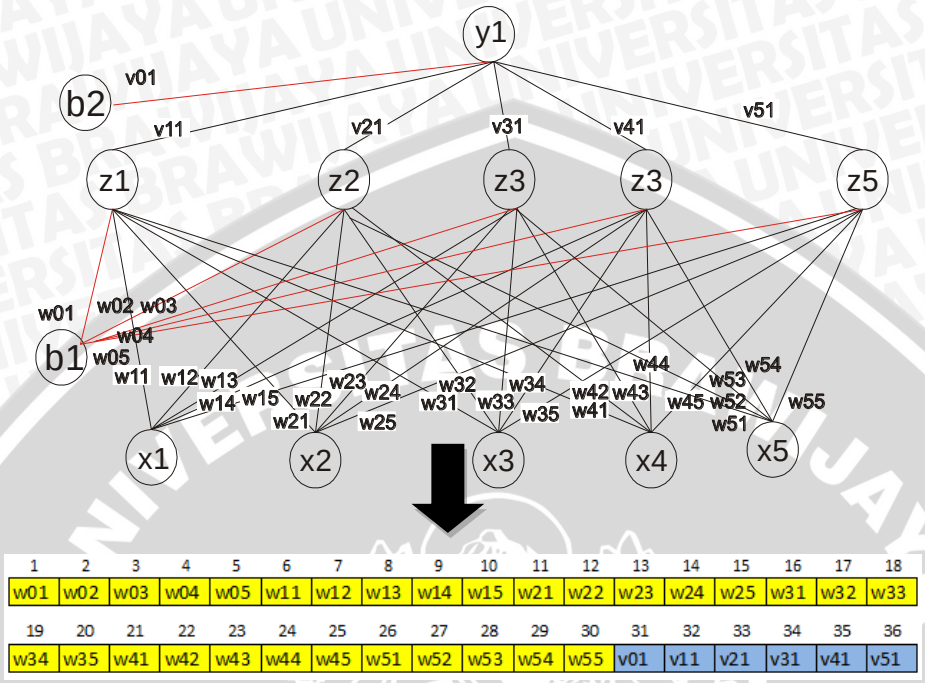

LAMPIRAN - 2
Grafik uji coba perbandingan nilai peluang crossover dan peluang mutasi dengan nilai *fitness*

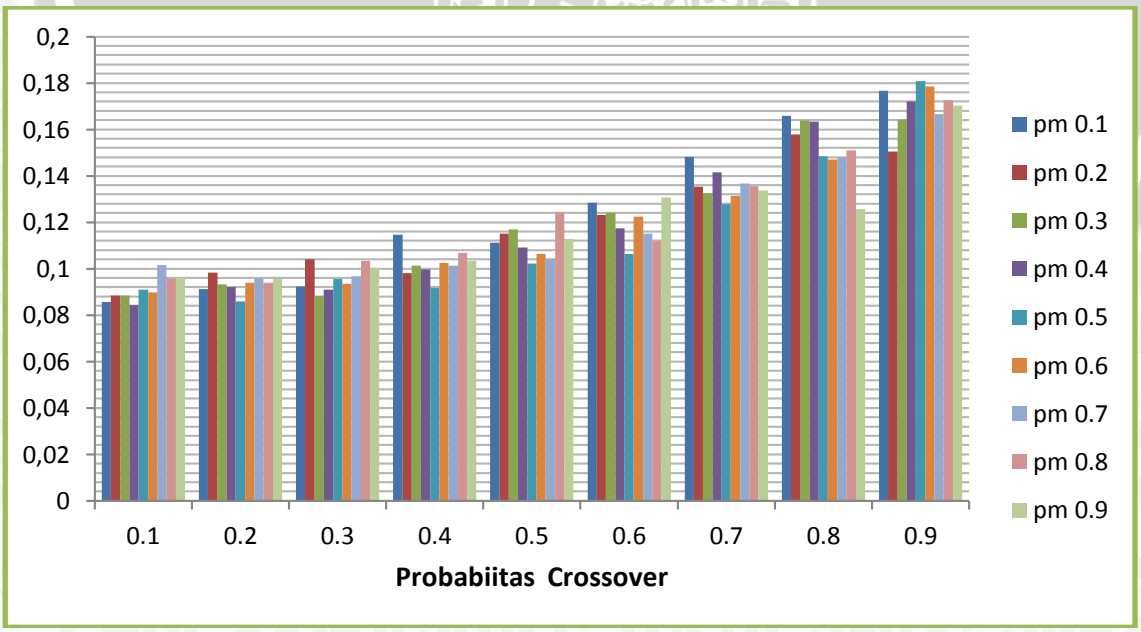

LAMPIRAN – 3

Grafik uji coba perbandingan ukuran populasi dan jumlah generasi dengan nilai *fitness*

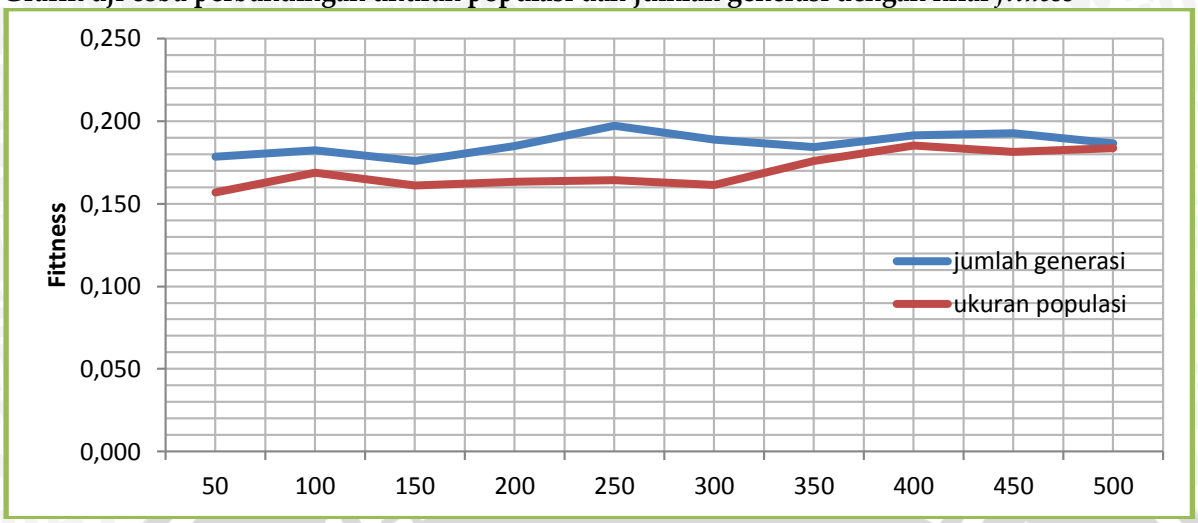

LAMPIRAN – 4
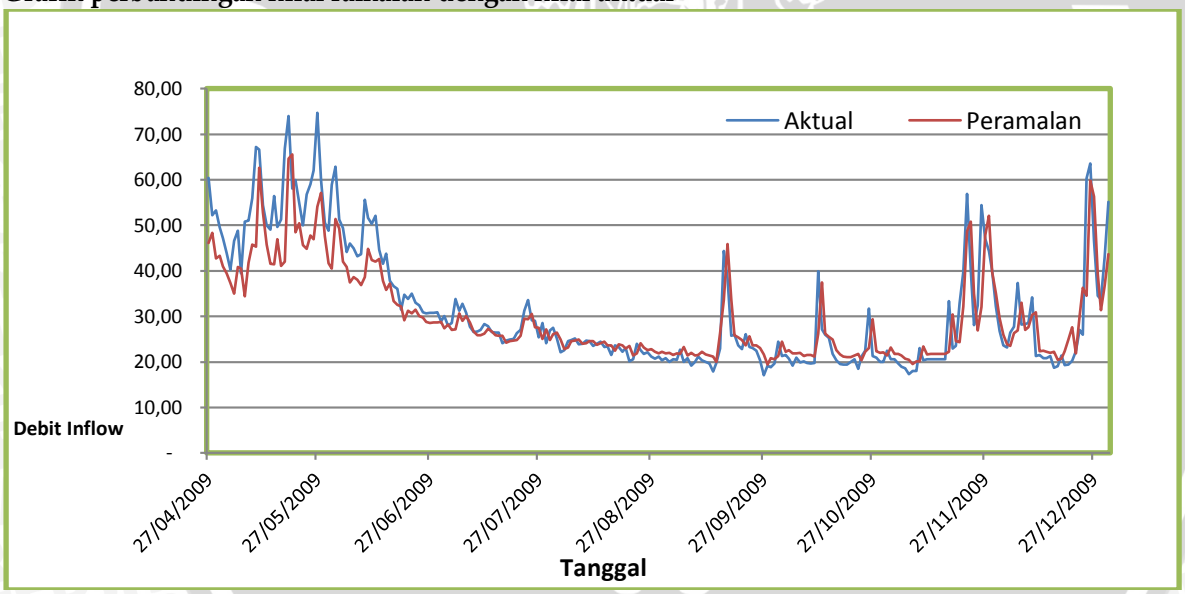
Grafik perbandingan nilai ramalan dengan nilai aktual