

OPTIMASI ARTIFICIAL NEURAL NETWORK DENGAN GENETIC ALGORITHM PADA PREDIKSI DEBIT INFLOW WADUK SENGGURUH

Yandria Elmasari¹⁾, Nurhadi²⁾

¹⁾Pendidikan Teknologi Informasi

STKIP PGRI Tulungagung Jalan Mayor Sujadi Timur No 7 Tulungagung, 66221

²⁾Fisika, Fakultas Ilmu Eksakta

Universitas Nahdlatul Ulama Blitar, Jalan Masjid No. 20, Kota Blitar, Jawa Tmur

e-mail: yandria@stkipgritlungagung.ac.id¹⁾, nur84hadi@gmail.com²⁾

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 feedforward. Pada penelitian ini dapat diketahui parameter genetika mampu mempengaruhi besar nilai fitness diantaranya probabilitas crossover dan jumlah generasi. Hasil dari pengujian didapatkan nilai fitness terkecil adalah 0,157

Kata Kunci: Algoritma Genetika, Jaringan Syaraf Tiruan, Kecerdasan Buatan

ABSTRACT

Reservoir is one of the resources that has many functions, including as a source of energy in the management of hydroelectric power plants (PLTA), irrigation of agricultural land, supply of water supply companies and functions as a flood prevention. With the vital role of the reservoir, a reservoir management strategy is needed in order to get optimal results in its operation, one of which is by predicting inflow discharge. In this study, Artificial Neural Networks are used as a model of forecasting inflow discharge with Genetic Algorithm training methods. Artificial Neural Network training using Genetic Algorithms is done by encoding tissue weights and biases into chromosomes and fitness values are obtained from feedforward process errors. In this study genetic parameters can be known to be able to influence the value of fitness including crossover probability and number of generations. The results of the test obtained the smallest fitness value is 0.157

Keywords: Genetic Algorithms, Artificial Neural Networks, Artificial Intelligence

I. PENDAHULUAN

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. Suatu waduk yang hanya memiliki satu fungsi misalnya untuk PLTA saja, akan berbeda strategi pengoperasiannya dengan waduk yang memiliki fungsi yang kompleks [1]. Kesalahan dalam pengoperasian tentunya sangat tidak diharapkan, kekurangan atau kelebihan tampungan air (storage) dan kesalahan pada saat pelepasan air (release) dapat merugikan. Terjadinya banjir akibat kesalahan dalam penentuan release waduk dapat terjadi. Ataupun storage yang tidak memadai dapat mengakibatkan suply untuk irigasi pertanian dan pengoperasian pembangkit listrik menjadi berkurang, hal ini dapat menurunkan produksi pertanian dan energi.

Secara umum sistem pengoperasian waduk haruslah mempertimbangkan keseimbangan debit air yang 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 [2][3]. 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.

Dari permasalahan yang telah dipaparkan, maka perlu dibangun suatu model yang mampu meramalkan debit inflow ke dalam suatu waduk. Dalam hal ini model hidrologi deterministik dapat digunakan, dimana model hidrologi deterministik berusaha menggambarkan proses-proses fisis hidrologi yang sesungguhnya terjadi, misalnya dengan mentransformasikan serangkaian masukan (input) curah hujan [4].

Jaringan Syaraf Tiruan (JST) telah diaplikasikan ke banyak bidang, salah satunya pada tahun 1990 mulai dikembangkan model Jaringan Syaraf Tiruan untuk model hidrologi. Studi yang dilakukan oleh [5] menyatakan bahwa Jaringan Syaraf Tiruan mampu menghubungkan input dan output simulasi dan model peramalan besar aliran sungai (rainfall-runoff) tanpa membutuhkan stuktur internal DAS. 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 pada proses pelatihan Jaringan Syaraf Tiruan adalah Algoritma Genetika [6][7].

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 [8]. Berdasarkan latar belakang yang dijelaskan tersebut, pada penelitian ini digunakan algoritma genetika pada pelatihan jaringan syaraf tiruan untuk peramalan debit inflow harian waduk.

II. LANDASAN TEORI

A. Jaringan Syaraf Tiruan

Jaringan syaraf tiruan terdiri dari beberapa neuron dan terdapat hubungan antara neuron-neuron tersebut yang dikenal dengan bobot. Neuron akan mentransformasikan informasi input yang ke lapisan berikutnya dengan melewatkannya nilai melalui fungsi perambatan yang akan menjumlahkan semua bobot yang akan datang[9][10]. Hasil dari fungsi perambatan ini selanjutnya akan dibandingkan dengan suatu nilai ambang batas (threshold) melalui fungsi aktivasi. Jika hasil dapat melewati ambang batas tersebut maka neuron tersebut akan diaktifkan dan dapat mengirimkan output melalui bobot-bobot outputnya ke semua neuron yang berhubungan dengannya[11][12].

B. Algoritma Genetika

Algoritma generika merupakan algoritma pencarian yang didasarkan atas mekanisme seleksi alam dan genetika alamiah. Dimana proses pencarian ini mengadopsi konsep genetika teori evolusi di bidang biologi. Algoritma genetika membentuk sekumpulan kemungkinan solusi yang disebut populasi, setiap bagian dari populasi disebut dengan individu yang nantinya akan bersaing dan berjuang menghadapi proses seleksi.

- Algoritma genetika memiliki beberapa elemen dasar adalah sebagai berikut:
- Representasi genetika untuk mengkodekan kemungkinan solusi dari permasalahan.
- Bagaimana membangkitkan populasi awal.
- Fungsi evaluasi untuk nilai kekuatan (fitness) dari masing-masing individu.
- Operator genetika untuk menghasilkan anak selama proses reproduksi.
- Nilai dari parameter algoritma genetika.

Algoritma genetika mengolah kumpulan individu yang disebut populasi $P(t)$ untuk setiap generasi t , dimana setiap individu merupakan kemungkinan solusi dari permasalahan. Setiap individu memiliki nilai fitness yang menunjukkan kualitas apakah suatu individu layak untuk dipertahankan. Secara stochastic beberapa individu akan dipilih sebagai parent untuk membentuk individu baru yang disebut offspring $C(t)$ melalui operator genetika, yang kemudin akan dievaluasi. Selanjutnya dibentuk populasi baru dengan mempertimbangkan fitness dari parent dan offspring. Setelah beberapa generasi t , algoritma genetika konvergen menuju solusi terbaik dan diharapkan memberika solusi yang optimal.

III. METODE

A. Model Penelitian

Model peramalan yang akan digunakan adalah model jaringan syaraf tiruan dengan algoritma pelatihan menggunakan algoritma genetika. JST memodelkan debit inflow harian Bendungan Sengguruh sebagai neuron tunggal pada lapisan output, dan curah hujan harian sebagai nilai dari neuron input pada lapisan input JST. Model input yang digunakan adalah curah hujan pada hari ke-t dan debit hari ke-t digunakan untuk menentukan besar dari debit inflow waduk pada hari ke-(t+1) sebagai target. Skema model JST yang digunakan dalam peramalan ditampilkan pada gambar 3.5.

Secara umum sistem yang dibangun terbagi menjadi dua proses, yaitu pelatihan (training) dan pengujian (testing). Proses pelatihan menggunakan algoritma genetika untuk mendapatkan komposisi bobot yang optimal pada JST dengan mengkodekan bobot dan bias dalam kromosom. Penentuan kromosom (konfigurasi bobot dan bias) yang baik didasarkan atas nilai fitness yang dihitung dengan melakukan proses feedforward menggunakan nilai dari kromosom tersebut. Nilai fitness merupakan tingkat error atau selisih dari hasil peramalan dengan nilai sebenarnya. Proses pelatihan JST menggunakan AG dilakukan dengan langkah-langkah di bawah ini:

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

IV. HASIL DAN PEMBAHASAN

1. Sistematika Uji Peluang Crossover dan Peluang Mutasi

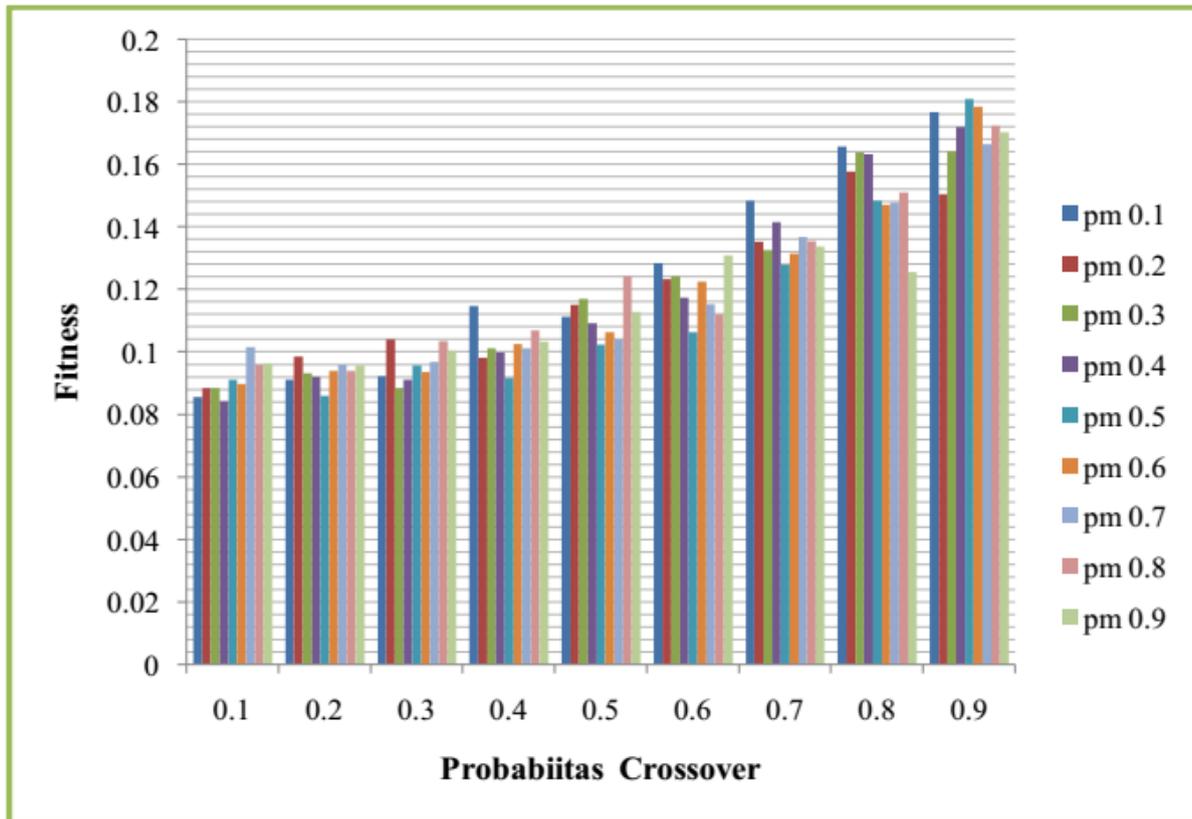
Sesuai dengan sistematika pengujian yang dijelaskan pada bab sebelumnya, adapun proses pengujian yaitu dengan dilakukan proses pelatihan JST menggunakan AG dengan mengkombinasikan 9 nilai peluang crossover dan 9 nilai peluang mutasi, dengan nilai antara 0.1 dan 0.9. Dilakukan sebanyak 5 kali uji coba untuk setiap satu kombinasi nilai peluang crossover dan nilai peluang mutasi, kemudian dirata-rata. Sehingga akan didapat nilai rata-rata dari maximum fitness setiap kombinasi peluang crossover dan peluang mutasi. Nilai fitness inilah yang akan dibandingkan dengan kombinasi peluang crossover dan mutasi.

Uji coba dilakukan dengan menggunakan Ukuran Populasi dan jumlah generasi yang sama, berurut-turut yaitu 100 individu pada populasi dan 500 generasi maksimal. Kecepatan pelatihan tidak dipertimbangkan sebagai nilai yang akan dianalisa. Hasil uji coba dapat dilihat pada tabel 1.

Tabel 1 Pengujian peluang crossover (pc) dan peluang mutasi (pm)

pm	Pc								
	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
0.1	0,0856	0,0911	0,0923	0,1146	0,1112	0,1285	0,1483	0,1658	0,1767
0.2	0,0885	0,0984	0,1040	0,0981	0,1150	0,1232	0,1353	0,1578	0,1504
0.3	0,0883	0,0932	0,0883	0,1012	0,1170	0,1241	0,1325	0,1638	0,1642
0.4	0,0842	0,0921	0,0910	0,0997	0,1091	0,1173	0,1416	0,1632	0,1721
0.5	0,0910	0,0858	0,0956	0,0917	0,1023	0,1064	0,1278	0,1484	0,1809
0.6	0,0898	0,0940	0,0936	0,1025	0,1063	0,1224	0,1314	0,1471	0,1785
0.7	0,1016	0,0958	0,0967	0,1012	0,1041	0,1152	0,1367	0,1479	0,1666
0.8	0,0959	0,0939	0,1034	0,1068	0,1242	0,1120	0,1355	0,1510	0,1724
0.9	0,0961	0,0956	0,1004	0,1033	0,1129	0,1308	0,1338	0,1256	0,1703

Pada tabel 1 dapat dilihat bahwa nilai fitness terbesar adalah 0,180858. Nilai terbesar ini didapat pada saat peluang crossover dan peluang mutasi berturut-turut 0,9 dan 0,5. Nilai yang dihasilkan pada peluang crossover 0,9 relatif mendekati nilai fitness terbesar yang didapat.



Gambar 1 Grafik Perbandingan pc dan pm dengan nilai fitness

Nilai fitness didapat dari error komulatif dari hasil penalaran maju (feedforward) satu kromosom. Setiap data latih dilakukan proses feedforward kemudian didapatkan nilai keluaran. Selisih nilai keluaran dengan nilai sebenarnya (target) merupakan error yang akan digunakan untuk menghitung nilai fitness. Sehingga apabila nilai fitness yang didapatkan nilainya besar, dapat dikatakan bahwa konfigurasi bobot JST dari kromosom tersebut memiliki akurasi yang baik untuk melakukan permalan.

Berdasarkan grafik perbandingan pc dan pm dengan nilai fitness diatas, dapat dilihat seiring perubahan nilai peluang crossover maka nilai fitness yang didapat cenderung semakin besar. Perubahan nilai fitness juga dipengaruhi juga 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 terbentuk. Dengan demikian peluang untuk didapatkan individu yang memiliki nilai fitness tinggi akan semakin besar.

Sedangkan untuk peluang mutasi dapat kita lihat pada grafik di atas bahwa setiap kenaikan nilai peluang mutasi tidak diikuti pula dengan kenaikan fitness. Misalkan pada 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 ketika 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 bilangan 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 masih mewariskan sifat buruknya kepada kromosom anak dan tidak mampu memperbaiki nilai fitness secara signifikan. Hal inilah yang menyebabkan nilai peluang mutasi tidak secara teratur mempengaruhi besar nilai fitness pada proses pelatihan.

V. KESIMPULAN

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 fitness yang dihasilkan, namun pada rentang tertentu nilai probabilitas mutasi dan ukuran populasi akan menghasilkan nilai fitness yang optimal. Nilai parameter genetika terbaik berdasarkan uji coba berturut-turut adalah 0.9 untuk probabilitas crossover, 0.5 untuk probabilitas mutasi, 100 untuk ukuran populasi dan 50 untuk jumlah generasi.

DAFTAR PUSTAKA

- [1] Xu, B., Zhong, P., Zhao, Y., Zhu, Y., & Zhang, G. (2014). Comparison between dynamic programming and genetic algorithm for hydro unit economic load dispatch. *Water Science and Engineering*, 7(4), 420–432. <http://doi.org/10.3882/j.issn.1674-2370.2014.04.007>
- [2] Tatar, A., Naseri, S., Sirach, N., Lee, M., & Bahadori, A. (2015). Prediction of reservoir brine properties using radial basis function (RBF) neural network. *Petroleum*, 1(4), 349–357. <http://doi.org/10.1016/j.petlm.2015.10.011>
- [3] Ji, H., & Qinglin, W. (2012). Douhe Reservoir Flood Forecasting Model Based on Data Mining Technology, 12, 93–98. <http://doi.org/10.1016/j.proenv.2012.01.252>
- [4] Heydari, H., Sajedi, S., & Goudarzi, V. (2018). Saturation exponent determination by using genetic algorithm in carbonate reservoirs : A case study in Sarvak Formation. *Egyptian Journal of Petroleum*, 27(2), 241–247. <http://doi.org/10.1016/j.ejpe.2017.07.013>
- [5] Zhong, S., Xie, X., Lin, L., & Wang, F. (2017). Genetic algorithm optimized double-reservoir echo state network for multi-regime time series prediction. *Neurocomputing*. <http://doi.org/10.1016/j.neucom.2017.01.053>
- [6] Sattari, M. T., Yurekli, K., & Pal, M. (2012). Performance evaluation of artificial neural network approaches in forecasting reservoir inflow. *Applied Mathematical Modelling*, 36(6), 2649–2657. <http://doi.org/10.1016/j.apm.2011.09.048>
- [7] Negash, B. M., Tufa, L. D., Marappagounder, R., & Bt, M. (2016). Conceptual Framework for Using System Identification in Reservoir Production Forecasting. *Procedia Engineering*, 148, 878–886. <http://doi.org/10.1016/j.proeng.2016.06.479>
- [8] You, L., Tan, Q., Kang, Y., Xu, C., & Lin, C. (2018). Reconstruction and prediction of capillary pressure curve based on Particle Swarm Optimization-Back Propagation Neural Network method. *Petroleum*, 4(3), 268–280. <http://doi.org/10.1016/j.petlm.2018.03.004>
- [9] F. Rozi and F. Sukmana, “Metode siklus dan adaptive neuro fuzzy inference system untuk peramalan cuaca,” *J. Ilm. Penelit. dan Pembelajaran Inform.*, vol. 1, no. 1, pp. 7–13, 2016.
- [10] F. Rozi and F. Sukmana, “Penggunaan moving average dengan metode hybrid artificial neural network dan fuzzy inference system untuk prediksi cuaca,” *J. Ilm. Penelit. dan Pembelajaran Inform.*, vol. 01, no. 02, pp. 38–42, 2016.
- [11] F. Rozi, C. Fatichah, and D. Purwitasari, “Inisialisasi Klaster Menggunakan Fuzzy Association,” vol. 13, no. Mcvm, pp. 190–197, 2015.
- [12] F. Sukmana, and F. Rozi, “Rekomendasi Solusi Pada Sistem Computer Maintenance Management System Menggunakan Association Rule, Fisher Exact Test One Side P-Value Dan Double One Side P-Value,” vol. 4, pp. 213–220, 2017.