

MODEL PREDIKSI *INFLOW* WADUK PLTA KOTOPANJANG MENGGUNAKAN PENDEKATAN ALGORITMA *ADAPTIVE NEURO FUZZY INFERENCE SYSTEM*

Imam Suprayogi*, Nurdin, Fakhri, Safridatul 'Audah, Ermiyati
Jurusan Teknik Sipil, Fakultas Teknik, Universitas Riau,
Kampus Bina Widya Simpang Baru Universitas Riau, Pekanbaru, Riau
*Email : drisuprayogi@yahoo.com

Abstrak

Prediksi aliran masuk (inflow) adalah kunci dalam komponen perencanaan, desain, pengoperasian, pengembangan, dan pemeliharaan sumber daya air yang tersedia. Model prediksi inflow mempunyai banyak manfaat dalam penerapan Sumber Daya Air seperti pengendalian banjir, mencegah kekeringan, dan mengoptimalkan pengoperasian waduk untuk keberlanjutan sistem pembangkit listrik tenaga air. Tujuan utama dari penelitian ini adalah untuk mengembangkan model untuk memprediksi aliran masuk waduk PLTA mengingat pentingnya informasi kondisi waduk setiap hari agar PLTA dapat terus beroperasi. Metode pendekatan penelitian yang digunakan adalah dengan menggunakan Adaptive Neuro Fuzzy Inferences System (ANFIS) melalui pengembangan sistem hybrid antara logika fuzzy dan ANN sebagai cabang dari softcomputing. Lokasi penelitian pada waduk PLTA Kotopanjang di Desa Merangin Kabupaten Kampar Provinsi Riau. Data yang digunakan dalam penelitian ini adalah data sekunder berupa data inflow waduk PLTA Kotopanjang yang dilakukan oleh PT PLN (Persero) KIT Sumbagut Sektor, KIT Pekanbaru dari tahun 2007-2012. Hasil utama penelitian membuktikan bahwa penerapan model prediksi inflow pada waduk tropis di Kabupaten Kampar dengan pendekatan metode ANFIS untuk prediksi inflow satu tahun ke depan ($t+1$) mempunyai klasifikasi sangat kuat yang diuji menggunakan parameter statistik koefisien korelasi dan RMSE.

Kata kunci: ANFIS, inflow, model, prediksi, reservoir

1. PENDAHULUAN

Prediksi *inflow* adalah kunci dalam komponen perencanaan, desain, pengoperasian, pengembangan, dan pemeliharaan sumber daya air yang tersedia. Model prediksi inflow mempunyai banyak manfaat dalam penerapan Sumber Daya Air seperti pengendalian banjir, mencegah kekeringan, dan mengoptimalkan pengoperasian waduk untuk keberlanjutan sistem pembangkit listrik tenaga air. Model prediksi aliran masuk memiliki banyak manfaat dalam penerapan sumber daya alam, seperti pengendalian banjir, mencegah kekeringan, dan mengoptimalkan pengoperasian waduk untuk keberlanjutan sistem pembangkit listrik tenaga air (Magar, 2012). Kesalahan data *inflow* dapat menyebabkan ketidakpastian dalam memprediksi sedimentasi waduk. Selanjutnya dalam perencanaan, diperlukan rangkaian data *inflow* waduk sebagai masukan pada pemodelan operasional waduk dan sedimentasi waduk, sehingga keakuratan data sangat diperlukan. Hasil model akan bias jika terjadi kesalahan masukan data (Salas dan Shin, 1999).

Perkiraan waktu dan lokasi yang akurat mengenai aliran sungai dan *inflow* waduk diperlukan untuk pengelolaan dan penjadwalan waduk pembangkit listrik tenaga air yang efektif. Dalam beberapa dekade terakhir, berbagai model

hidrologi telah diusulkan untuk tujuan ini. Di Indonesia, ada lima metode peramalan arus yang digunakan secara default yaitu metode peramalan sederhana, metode peramalan korelasi dan regresi, metode peramalan resesi, dan metode analisis deret waktu dengan menggunakan metode *Auto Regression* (AR) dan metode *Stochastic Thomas-Fiering* (Kementerian Perumahan dan Prasarana Wilayah, 2003).

Secara konvensional, metode analisis faktor dan analisis hidrologi seperti metode evolusi historis, analisis deret waktu, metode regresi linier berganda dan sebagainya, digunakan untuk meramalkan pembuangan jangka panjang. Saat ini, analisis deret waktu dan metode regresi linier berganda adalah dua metode yang paling umum digunakan. Analisis runtun waktu didasarkan pada penguraian berbagai faktor menjadi tren dan siklus. Setelah tahun 1970-an, model *Autoregressive Moving Average* (ARMA) yang diusulkan oleh Box et al. (1976) juga banyak digunakan. Kelemahan metode konvensional tersebut adalah kualitas peramalan dan perlunya banyak parameter tambahan lainnya seperti sifat fisik daerah tangkapan air, dan jaringan sungai (Firat dan Gungor, 2007).

Waduk di daerah tropis pada umumnya mempunyai permasalahan sedimentasi yang cukup cepat. Jarang sekali terdapat waduk yang

beroperasi yang menunjukkan adanya fenomena sedimentasi yang meningkat. Berdasarkan beberapa laporan dan penelitian, banyak waduk yang mengalami pendangkalan lebih cepat dari umur rencana. Antara lain tercatat pada bendungan Wonogiri, Sutami, Saguling, Wlingi di Indonesia, Bahkara di India, Magat di Filipina dan Kamburu di Kenya terjadi peningkatan laju sedimen dua atau tiga kali lipat dari desain awal setelah dilakukan pemantauan ulang (Sudjarwadi, 1995 ; Ilyas, 1995).

Waduk Kotopanjang merupakan waduk serba guna sebagai pembangkit listrik tenaga air yang memanfaatkan potensi air sungai Kampar Kanan. Alur sungai Kampar Kanan tersebut dibendung untuk menampung dan menaikkan tinggi muka air sehingga diperoleh tinggi muka air yang direncanakan dan besarnya debit yang dapat diambil sepanjang tahun yang diperlukan untuk memutar turbin PLTA Kotopanjang. Kondisi debit air PLTA Kotopanjang yang terus menurun memaksa PLN melakukan pemadaman sebagian pelanggan secara bergilir sejak akhir Mei hingga Agustus. Dari total kebutuhan listrik untuk wilayah daratan Riau sebesar 20 MW, PLTA Kotopanjang hanya mampu menghasilkan listrik sebesar 60 MW dari kapasitas maksimalnya sebesar 114 MW (Akbari, 2012). Karakter hujan di Pulau Sumatera bagian utara terbagi menjadi dua, yaitu terletak di Bukit Barisan Timur dan Bukit Barisan Barat. Curah hujan di sebelah timur Bukit Barisan mempunyai karakteristik curah hujan yang lebih rendah dibandingkan rata-rata seluruh wilayah Sumut. Dan curah hujan di sebelah barat Bukit Barisan mempunyai karakteristik curah hujan yang lebih tinggi dibandingkan rata-rata seluruh wilayah Sumatera Bagian Utara (Akbari, 2012).

Permasalahan yang paling penting dalam pengelolaan waduk PLTA Kotopanjang adalah besarnya inflow karena menentukan banyaknya air yang akan dibuang untuk menggerakkan turbin generator. Pertengahan Juni 2006 PT.PLN melakukan teknik modifikasi cuaca (TMC) melalui hujan buatan untuk meningkatkan debit air akibat rendahnya debit air di PLTA Kotopanjang dan saat itu dugaan ketinggian air di PLTA Kotopanjang mencapai dampak 73,8 mdpl Turbin pembangkit listrik tidak dapat menghasilkan tenaga listrik, yang hanya dapat dihasilkan ketika permukaan air mencapai 76,4 m dpl.

Pada dekade terakhir ini, model *softcomputing* sebagai cabang dari ilmu kecerdasan buatan (*artificial intelligence*) diperkenalkan sebagai alat peramalan seperti

sistem berbasis pengetahuan (*knowledge based system*), sistem pakar (*expert system*), logika fuzzy (*fuzzy logic*), jaringan syaraf tiruan (*artificial neural network*) dan algoritma genetika (genetic algorithm) (Purnomo, 2004). Masih menurut Purnomo (2004) dasar pemilihan model *softcomputing* sebagai *tool* dalam pemodelan sistem, pemodelan *softcomputing* sangat menguntungkan bekerja pada sistem tak linier yang cukup sulit model matematikanya, serta fleksibilitas parameter yang dipakai yang biasa merupakan kendala pada *tool* yang lain. Ada kalanya komponen utama *softcomputing* saling dipadupadankan untuk mendapatkan algoritma yang lebih sempurna. Pada tahun 1993, Roger Jang dari Departemen Ilmu Listrik dan Komputer, Universitas California, AS. mengembangkan sistem *hybrid* antara logika *fuzzy* dan jaringan saraf tiruan yang menghasilkan sistem *neuro fuzzy* struktur sistem inferensi *neuro fuzzy* adaptif atau lebih dikenal dengan algoritma ANFIS.

Saat ini, jaringan saraf (NN) dan sistem inferensi neuro-fuzzy adaptif (AN- Model FIS) adalah dua alat ML yang paling banyak digunakan. Model-model ini terutama digunakan untuk memprediksi, mengisi, dan mengklasifikasikan rangkaian data. Misalnya, mereka telah digunakan untuk memperkirakan air permintaan konsumsi di daerah perkotaan (Zubaidi, dkk, 2020), menentukan kualitas air tanah dan transportasi polutan (Azad, dkk, 2019), mengklasifikasikan dan mensimulasikan anak sungai (Nalavade, dkk, 2018), dan menghasilkan peringatan dini sistem (Hussain, dkk, 2018). Namun, aplikasi terus dikembangkan untuk memenuhi kebutuhan baru. Penerapan terkini mencakup pengelolaan bendungan, yang merupakan teknik sipil yang penting infrastruktur untuk berfungsinya masyarakat modern.

Pendekatan logika *fuzzy* dan ANN telah diterapkan pada berbagai masalah hidrologi, seperti peramalan aliran sungai (Chang dan Chen, 2001; Ponnambalan, dkk, 2003; Vernieuwe, dkk, 2005), pemodelan runtun waktu (Sisman-Yilmanz, dkk., 2004; Nayak, dkk., 2004b), prediksi ketinggian air waduk (Chang dan Chang, 2006), pengoperasian waduk (Ouenes, 2000), dievaluasi untuk meningkatkan keakuratan prediksi aliran sungai (Kisi, 2004; Firat, 2007). Lin et al., (2005) telah berhasil mengembangkan model ANFIS untuk memperkirakan debit jangka panjang pembangkit listrik tenaga air Manwan. Pembangkit listrik tenaga air Manwan menggunakan sungai Lancangjiang yang berhulu dari Dataran Tinggi Qinghai dan berakhir di Laut Cina Selatan sebagai sumber airnya. Penelitian

Lin menunjukkan bahwa model ANFIS memberikan kinerja prediksi yang baik dengan korelasi antara nilai prediksi dan nilai observasi masing-masing sebesar 0,89 dan 0,92. Penerapan fungsi keanggotaan yang berbeda untuk ANFIS menunjukkan bahwa TRAPMF berkinerja terbaik dalam prediksi debit jangka panjang di Pembangkit Listrik Tenaga Air Manwan yang terdiri dari tiga aliran masukan sebelumnya. Melalui perbandingan hasil dengan model ANN yang sesuai, ditemukan bahwa model ANFIS adalah mampu memberikan prediksi yang lebih akurat. Hal ini menunjukkan kemampuan dan keunggulannya dalam mengidentifikasi rangkaian waktu hidrologi yang terdiri dari karakteristik non-linier.

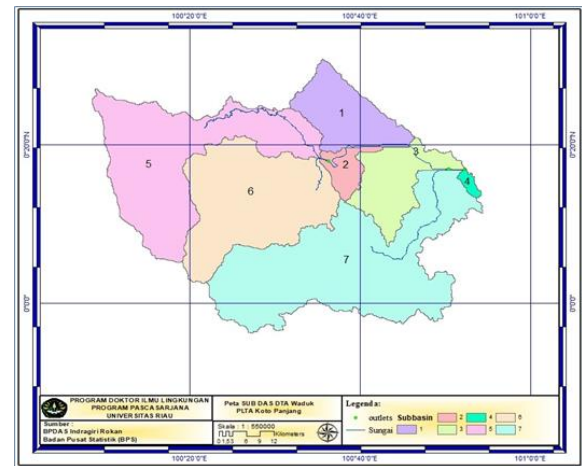
Model ANFIS belum digunakan untuk pengembangan model prediktif bendungan di Amerika Latin. Namun, mereka lebih populer di negara-negara Asia. Hamsyid dan kolaborator menggunakan ANFIS untuk menghasilkan prediksi ketinggian air harian di Chahnimeh bendungan di Zabol, memperoleh hasil kesalahan yang dapat diterima hingga periode jeda tiga hari (Piri, dkk, 2016). Demikian pula, pada tahun 2019, Üne,s dan kolaborator membandingkan kinerja ANFIS dengan lebih banyak model tradisional seperti *autoregressive* (AR), *autoregressive moving average* (ARMA), dan regresi multilinear (MLR), menyimpulkan bahwa hasil terbaik adalah yang menggunakan ANFIS (Unes, dkk, 2019). Mengacu pada keberhasilan penelitian penggunaan ANFIS sebagai model peramalan aliran masuk waduk, maka perlu dilakukan penerapan model ANFIS untuk memprediksi aliran masuk waduk PLTA Kotopanjang mengingat pentingnya informasi kecukupan di

waduk ini sehari-hari sehingga PLTA Kotopanjang dapat terus beroperasi.

2. METODOLOGI

2.1. Lokasi Penelitian

PLTA Koto Panjang terletak di desa Merangin, Kecamatan Bangkinang Barat, Kabupaten Kampar, Provinsi Riau; berjarak lebih kurang 20 km dari ibukota Kabupaten, Bangkinang atau 87 km dari ibukota Provinsi Riau, Pekanbaru.



Gambar 1. Lokasi PLTA Kotopanjang

2.2. Data Penelitian

Data yang digunakan dalam penelitian ini adalah data sekunder berupa data inflow waduk PLTA Kotopanjang yang telah dilakukan oleh PT PLN (Persero) KIT Sumbagut Sektor, KIT Pekanbaru dari tahun 2007-2012. Tahap analisis prediksi inflow pada reservoir dengan pendekatan metode ANFIS disajikan seperti pada Gambar 2 berikut ini:



Gambar 2. Tahapan analisis prediksi inflow menggunakan metode ANFIS

Tahapan analisis prediksi *inflow* waduk menggunakan metode ANFIS disajikan seperti terlihat pada Gambar 2 berikut ini:

- Penyusunan data berupa data *inflow* waduk PLTA Kotopanjang yang telah dilakukan oleh PT PLN (Persero) KIT Sumbagut Sektor, KIT Pekanbaru dari tahun 2007-2012,
- Tahap pengembangan model, 70% dari total data *inflow* tahun 2007-2010 digunakan sebagai data pelatihan dan 30% digunakan

sebagai data uji. Kemudian seluruh data tahun 2007-2010 dijadikan data simulasi untuk melihat hasil proses data pelatihan dan pengujian tahap pengembangan model secara keseluruhan.

- Data tahun 2007-2010 juga digunakan sebagai data validasi, dimana aturan model akan diterapkan untuk membangun model ANFIS dengan menggunakan data tahun 2011. Data tahun 2012 merupakan data yang akan

digunakan untuk kebutuhan prediksi *inflow reservoir* satu tahun ke depan. menggunakan model aturan ANFIS.

- Proses akhir dengan proses prediksi *inflow* pada *reservoir* setelah model ANFIS dilakukan setelah serangkaian proses pelatihan, pengujian dan simulasi model yang sudah jadi. Hasil prediksi model ANFIS (output) kemudian dibandingkan dengan nilai hasil pengukuran. Kesesuaian model ANFIS dan hasil pengukuran menggunakan uji parameter statistik MAPE, RMS dan koefisien korelasi (R) untuk mendapatkan hasil tingkat korelasi terbaik pada proses prediksi

2.3. Evaluasi Presisi Model

Kinerja masing-masing model dipelajari berdasarkan kriteria kinerja statistik koefisien korelasi (R), akar rata-rata kesalahan kuadrat (RMSE), dan persentase kesalahan absolut rata-rata (MAPE). Nilai masing-masing model dibandingkan dengan debit teramati (Q_{obs}). Evaluasi presisi model dilakukan dengan membandingkan aliran masuk simulasi model ANFIS dengan data hasil pengukuran yang tersedia. Model dapat dikatakan tepat jika terdapat nilai korelasi yang tinggi antara data hasil simulasi dan pengukuran. Salah satu parameter uji statistik adalah koefisien korelasi (R) yaitu harga yang menunjukkan besarnya hubungan antara nilai observasi dengan nilai simulasi. Uji presisi model dilakukan dengan menggunakan koefisien korelasi (R) yang mengikuti persamaan sebagai berikut:

$$R = \frac{\sum_{i=1}^{i=n} (Q_t^{obs} - \hat{Q}_t^{obs}) (Q_t^m - \hat{Q}_t^m)}{\left[\sum_{i=1}^{i=n} (Q_t^{obs} - \hat{Q}_t^{obs})^2 \sum_{i=1}^{i=n} (Q_t^m - \hat{Q}_t^m)^2 \right]^{1/2}} \dots\dots (1)$$

di mana Q_{obs} menyatakan debit teramati (m^3/dt) dan \hat{Q}_{obs} menyatakan debit rata-rata teramati pada waktu t (m^3/dt), Q_{mod} merupakan debit model (m^3/dt) dan \hat{Q}_{mod} merupakan debit rata-rata model (m^3/dt) dalam n jumlah sampel. R mengukur korelasi linier antara nilai yang diamati dan yang dimodelkan, dengan nilai optimal 1,0 (Nayak et al., 2005).

Klasifikasi kekuatan derajat hubungan berdasarkan hasil nilai koefisien korelasi antara data hasil simulasi model dan data hasil pengukuran. Untuk R sama dengan 0 mempunyai derajat hubungan tidak ada korelasi, $0 < R < 0.25$

mempunyai derajat hubungan sangat lemah, $0.25 < R < 0.50$ mempunyai derajat hubungan tidak cukup, $0.50 < R < 0.75$ mempunyai derajat korelasi kuat, $0.75 < R < 0,99$ derajat hubungan korelasi sangat kuat dan R sama dengan 1 derajat hubungan korelasi sempurna (De Farias dkk, 2010; Firat, 2007).

RMSE mewakili akar kuadrat momen sampel kedua dari perbedaan antara nilai prediksi dan nilai observasi atau rata-rata kuadrat dari perbedaan tersebut. RMSE merupakan tingkat kesalahan hasil prediksi, semakin kecil (mendekati 0) nilai RMSE maka hasil prediksi akan semakin akurat. Nilai RMSE dapat dihitung dengan persamaan di bawah ini (Firat, 2007) :

$$RMSE = \left[\frac{1}{n} \sum_i^n (Q_{model} - Q_{predicted}) \right]^{1/2} \dots (2)$$

dengan Q_{obs} yang diamati adalah debit aktual (m^3/dt), Q_{model} adalah debit prediksi (m^3/dt) dan N adalah jumlah debit data

MAPE adalah ukuran keakuratan prediksi suatu metode peramalan dalam statistik, misalnya dalam estimasi tren, juga digunakan sebagai fungsi kerugian untuk masalah regresi pada mesin. sedang belajar. Biasanya akurasi dinyatakan sebagai rasio yang ditentukan oleh rumus (Nayak, dkk, 2004a):

$$MAPE = \frac{\sum \left(\frac{Q_{obs} - Q_{model}}{Q_{obs}} \right)}{n} \times 100\% \dots (3)$$

dengan Q_{obs} adalah debit teramati (m^3/dt), Q_{model} adalah debit prediksi (m^3/dt) dan n adalah jumlah data debit.

3. HASIL DAN PEMBAHASAN

3.1. Pengembangan Model ANFIS

Perancangan arsitektur jaringan sistem neuro *fuzzy* dengan struktur ANFIS menggunakan pola *input-output* yang diambil dari data *inflow* waduk PLTA Kotopanjang dari tahun 2007 hingga tahun 2010. Selanjutnya skema model berbagai variasi besaran masukan yang diuji untuk membangun model ANFIS pada penelitian ini disajikan seperti pada Tabel 1:

Tabel 1
Skema Model ANFIS

Skema Model	Input Model	Output Model
1	Q_t	Q_{t+1}
2	Q_t, Q_{t-1}	Q_{t+1}
3	Q_t, Q_{t-1}, Q_{t-2}	Q_{t+1}
4	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-}$	Q_{t+1}

di mana Q_t adalah aliran masuk pada waktu t (m^3/dt), Q_{t-1} adalah aliran masuk pada waktu $t-1$ (m^3/dt), Q_{t-2} adalah aliran masuk pada waktu $t-2$ (m^3/dt), Q_{t-3} adalah aliran masuk pada waktu $t-3$ (m^3/dt) dan Q_{t+1} adalah aliran masuk pada waktu $t+1$ (m^3/dt).

Ada dua tahapan yang sangat penting dalam proses prediksi menggunakan algoritma ANFIS yaitu proses data latih dan proses data pengujian (Suprayogi, 2009). Aplikasi dengan struktur ANFIS memerlukan *training* data dan *testing* data. Keduanya berisi pola *input/output*. Jika data training digunakan untuk melatih struktur ANFIS, data testing digunakan untuk menilai kinerja struktur ANFIS. Terdapat tiga tahapan dalam membangun model peramalan berdasarkan data *inflow* waduk PLTA Kotopanjang tahun 2007 sampai dengan tahun 2010 dengan menggunakan algoritma ANFIS yaitu tahapan proses *training* data, proses *testing* data, dan proses simulasi data.

Tabel 2

Nilai parameter terbaik Model ANFIS pada Tahap Proses *Training*

Skema	Input	Output	ROI	R	RMSE
1	Q_t	Q_{t+1}	0.00005	1.00	2.89
2	Q_t, Q_{t-1}	Q_{t+1}	0.0004	1.00	0.000118
3	Q_t, Q_{t-1}, Q_{t-2}	Q_{t+1}	0.080	1.00	0.000006
4	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	Q_{t+1}	0.09	1.00	0.000008

Mengacu pada Tabel 2 di atas maka akan diperoleh nilai uji parameter statistik pada proses data training antara model ANFIS dan data observasi mempunyai klasifikasi sangat kuat dengan nilai koefisien korelasi (R) dan RMSE sebesar 0.937246 dan 0.000006 dengan nilai ROI 0.08 (Skema 3).

3.3. *Testing* Data

Setelah proses data training yang bertujuan untuk melatih struktur ANFIS maka langkah selanjutnya dilakukan proses testing data menggunakan arsitektur model ANFIS yang terdiri dari tiga lapisan masukan dan satu keluaran, yang digunakan untuk menilai kinerja ANFIS. struktur. Hasil analisis testing data dengan input data 21 September 2009 sampai 31 Desember 2010 (30% data selain data yang digunakan proses *training*). Dari proses pengujian data dengan menggunakan program bantu MATLAB 7.0 menggunakan skema 3 diperoleh nilai koefisien korelasi (R) dan RMSE masing-masing sebesar 0,57 dan 90,31 dengan klasifikasi kuat.

3.2. *Training* Data

Proses training data digunakan untuk melatih struktur ANFIS. Pada tahap training menggunakan metode aANFIS terlebih dahulu dilakukan proses testing parameter statistik koefisien korelasi (R) dan RMSE untuk mendapatkan nilai R dan RMSE terbaik dari salah satu parameter model ANFIS yaitu range of influence (ROI). Data training yang digunakan untuk melatih struktur ANFIS adalah 70% dari tanggal 1 Januari 2007 sampai dengan 20 Sep 2009 dari data inflow reservoir PLTA Kotopanjang yang telah dilakukan oleh PT PLN (Persero) KIT Sumbagut. Hasil lengkap proses training data pada berbagai skema menggunakan program bantu MATLAB 7.0 disajikan pada Tabel 2.

3.4. *Simulasi* Data

Tahap simulasi model merupakan proses terakhir setelah proses pelatihan dan tahap pengujian. Hasil analisis simulasi data dengan input data 1 Januari 2007 sampai dengan 31 Desember 2010 menggunakan program bantuan MATLAB 7.0 menggunakan skema 3 diperoleh nilai koefisien korelasi (R) dan RMSE masing-masing sebesar 0,85 dan 154,81 dengan klasifikasi kuat.

3.5. *Prediksi Inflow* Waduk

Terdapat dua skema model untuk melakukan prediksi *inflow* Waduk PLTA Kotopanjang tahun 2012 dengan menggunakan ANFIS berdasarkan informasi data debit tahun 2011 yang bersumber dari PT PLN (Persero) KIT Sumbagut Sektor, KIT Pekanbaru dengan menerapkan Skema 1 tanpa validasi silang (*non cross validation*) dan Skema 2 dengan validasi silang (*cross validation*). Tujuan utama penggunaan metode *cross validation* adalah untuk menguji kualitas data yang digunakan untuk peramalan dengan melakukan komposisi

proses pelatihan dan pengujian pada data *input* ANFIS. Untuk komposisi data *training*, data *testing* dan data simulasi untuk prediksi *inflow*

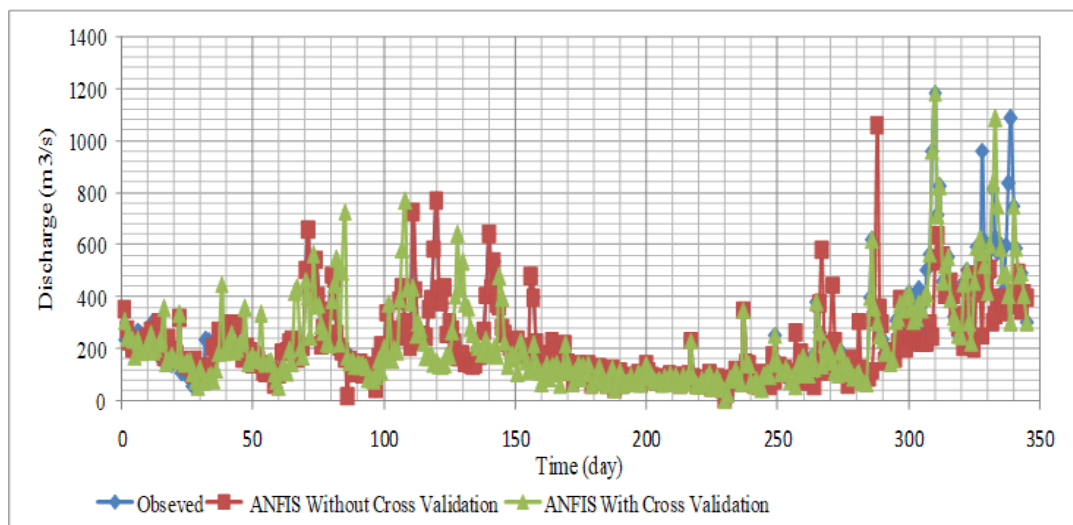
Waduk PLTA Kotopanjang tahun 2012 yang disajikan pada Tabel 3.

Tabel 3
Komposisi Training, Testing dan Simulasi Data

Skema	Input Training	Input Testing	Input Simulasi Data
1	256 data (70%) (1 Jan -13 Sep 2011)	109 data (30%) (14 Sept-21 Des 2011)	365 data (100%) (1 Jan -31 Des 2011)
2	109 data (30%) (14 Sept-31 Des 2011)	256 data (70%) (1 Jan -29 Maret 2011)	365 data (100%) (14 Spt-31 Des2011) dan Jan – 29 Maret 2011)

Merujuk pada Tabel 3 di atas, langkah selanjutnya dilakukan tahapan proses training data, testing data dan simulasi data menggunakan Model ANFIS berdasarkan Skema 1 dan Skema 2 untuk komposisi *input* data *training*, data *testing*, dan data simulasi. Hasil simulasi membuktikan bahwa penerapan model ANFIS tanpa metode *cross validation* (skema 1) dan dengan metode *cross validation* (skema 2) diuji menggunakan nilai uji MAPE memiliki tingkat *error* rata-rata

13,71% dan 12,92% yang mempunyai akurasi masing-masing -masing-masing sebesar 86,39% dan 87,08%. Selanjutnya hasil prediksi PLTA Koto Panjang menggunakan data pada tahun 2012, maka deskripsi performa model ANFIS (*cross validation*) dan ANFIS (*non cross validation*) dibandingkan menggunakan data pengukuran selengkapnya disajikan seperti pada Gambar 3.



Gambar 3. Performa Model ANFIS (*cross validation*) dan ANFIS (*non cross validation*) dengan *observed data* untuk tahun 2012

Mengacu pada Gambar 3 di atas, hasil penelitian membuktikan penggunaan model algoritma ANFIS memiliki keunggulan pada data pola yang dikenali menghasilkan akurasi prediksi aliran masuk yang tinggi di PLTA Kotopanjang Waduk Kabupaten Kampar satu tahun ke depan (Q_{t+1}) mempunyai derajat hubungan sangat kuat dengan nilai koefisien korelasi (R) sebesar 0,94 dan nilai MAPE sebesar 12,86% dengan

klasifikasi hubungan sangat kuat, sehingga model ANFIS dapat digunakan sebagai prediksi kebutuhan untuk memantau dinamika fluktuasi inflow, terutama perlunya menjaga pentingnya informasi kecukupan di waduk sehari-hari agar PLTA Kotopanjang dapat terus beroperasi.

4. KESIMPULAN

Berdasarkan analisa dan pembahasan di atas, maka dapat diambil kesimpulan sebagai

berikut untuk penerapan model ANFIS dengan input data menggunakan metode *cross validation* untuk kebutuhan praktek inflow Waduk PLTA Kotopanjang terbukti memiliki nilai rata-rata hasil prediksi lebih kecil kesalahan dibandingkan dengan model ANFIS untuk input data tanpa menggunakan metode *cross validation* dengan uji parameter statistik nilai MAPE masing-masing dengan nilai 12,86% dan 19,46% serta didukung nilai koefisien korelasi (R) sebesar 0,94 dan 0,90 dengan klasifikasi korelasi sangat kuat.

5. UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada PT. PLN (Persero) KIT Sumbagut Sektor, KIT Pekanbaru, Provinsi Riau yang telah menghibahkan penggunaan data *inflow* pada Waduk PLTA Kotopanjang dan Ria Utami, ST atas bantuan analisis statistik dan pengoperasian Program MATLAB 7.0 Toolbox untuk mendukung penelitian ini.

DAFTAR PUSTAKA

- Akbari, D. The role of rainfall against decreased discharge reservoir of Kotopanjang hydro electric power plant reservoir PLTA [online]. Department of Meteorologist Faculty of Earth Sciences and Technology : Institut Teknologi Bandung (ITB) Bandung, 2012. URL:<http://www.meteo.itb.ac.id/wpcontent/uploads/2013/05/1280803-sec.pdf> [Accessed 1 Agustus 2013]
- Box, G. E. P., Jenkins, G. M. Time Series Analysis Forecasting and Control. Holden - Day, San Francisco, 1976.
- Chang, L. C., Chang, F. J. Intelligent control for modeling of real-time reservoir operation. *Hydrology Processes* 15, 2001, pp.1621–1634.
- Chang, F. J., Chen, Y. C. A counterpropagation fuzzy-neural network modeling approach to real time streamflow prediction. *Journal of Hydrology*. 245, 2001, pp.153–164.
- De Farias, C. A. S., Alves, L. M., Santos, C. A. G., Suzuki, K. An ANN based approach to modeling sediment yield : A case study semi arid area of Brazil : Proceeding of the ICCE Symposium Held at Warsaw Poland in Life Science –SGGW Poland, 14 – 18 June 2010 IAHS Publish 557, 2010.
- Department of Housing and Regional Infrastructure. River flow discharge forecasting, Research Centre and Water Resources Development, Research and Development of Agency, Department of Housing and Regional Infrastructure, Ministry of Housing and Regional Infrastructure Republic of Indonesia, 2003.
- Firat, M. Artificial intelligence techniques for river flow forecasting in the Seyhan river catchment, Turkey, *Hydrology and Earth System Discussions* 4, 2007, pp. 1369–1406.
- Firat, M., Gungor, M. River flow estimation using adaptive neuro fuzzy inference system, *Journal of Mathematic and Computer in Simulation* 75, 2007, pp. 87–98
- Hussain, W.; Ruhana, K.; Norwawi, N.M. Neural network application in reservoir water level forecasting and release decision. *Int. J. New Comput. Archit. Appl.* 2011, 1, 256–274.
- Ilyas, M. A. Prediction of sedimentation rate in the Kotopanjang hydropower reservoir plan in Riau, Annual Scientific Meeting (PIT) XII, Indonesian Hydraulic Engineering Association (HATHI), Surabaya, 1995, pp. 207-216.
- Jang, J. S. R. ANFIS: adaptive network-based fuzzy inference system. *IEEE Transaction System, Man and Cybernetics* 23(3), pp. 665–685, 1993.
- Jang, J. S. R., Sun, C. T., Mizutani, E. *Neuro-fuzzy and Softcomputing : A Computational Approach to Learning and Machine Intelligence*. Prentice Hall, Englewood Cliffs, New Jersey, USA, 1996.
- Lin, J.Y., Cheng, C. T., Sun, Y. G., Chau, K. Long-term prediction of discharges in Manwan Hydropower using adaptive-network-based fuzzy inference systems models. *Journal of Lecture Notes in Computer Science*. 3612, 2005, pp. 1152–1161.
- Kisi, O. River flow prediction using artificial neural network. *Journal of Hydrologic Engineering* . 9(1), 2004, pp. 60–63.
- Magar, R.B . 2011. Intermittent reservoir daily inflow prediction using lumped and distributed data multi-linear regression model. *Journal of Earth System Science*. 120(6), 2011, pp. 1067-1084.
- Nalavade, J.E.; Murugan, T.S. HRNeuro-fuzzy: Adapting neuro-fuzzy classifier for recurring concept drift of evolving data streams using rough set theory and holoentropy. *J. King Saud Univ. Comput. Inf. Sci.* 2018, 30, 498–509. [CrossRef]
- Nayak, P. C., Sudheer, K. P., Rangan, D. M., Ramasastry, K. S. A neuro-fuzzy computing technique for modeling

- hydrological time series. *Journal of Hydrology* 291, 2004, pp. 52–66.
- Ouenes A. Practical application of fuzzy logic and neural networks to fractured reservoir characterization. *Computer Geosciene* 26, 2000, pp. 953–962
- Piri, J.; Rezaei, M. Prediction of water level fluctuations of chahnimeh reservoirs in zabol using ANN, ANFIS and Cuckoo Optimization Algorithm. *Iran. J. Health Saf. Environ.* 2016, 4, 706–715
- Ponnambalan, K., Karry, F., and Musavi, S.,J. Minimizing variance of reservoir systems benefits using softcomputing tools. *Fuzzy Sets System* 139, 2003, pp. 451–461.
- Purnomo, M.H. (2004), *Teknologi Soft Computing : Prospek dan Implementasinya Pada Rekayasa Medika dan Elektrik*, Pidato Pengukuhan Untuk Jabatan Guru Besar Dalam Ilmu Artificial Intelligent Pada Fakultas Teknologi Industri (TI) Institut Teknologi Sepuluh Nopember, Surabaya
- Rantala, J., Koivisto, H. (2002) Optimised subtractive clustering for neuro-fuzzy models. In: *Third WSES (World Scientific and Engineering Society) International Conference on Fuzzy Sets and Fuzzy Systems (Interlaken, Switzerland)*, 2002.
- Refsgaard, J. C. Towards a Formal approach to calibration and validation of models using spatial data, in R. Grayson and G. Blöschl. *Spatial Patterns in Catchment Hydrology : Observations and Modelling*, Britain : Cambridge University Press, 2000, pp. 329 – 354.
- Salas, J.D., Shin, H.S. Uncertainty analysis of reservoir sedimentation. *Journal of Hydraulic Engineering*,, 125(4), pp.339-350.
- Sudjarwadi. Difficulty prediction of reservoir sedimentation rates based on Echo Sounding data, Annual Scientific Meeting (PIT) XII, Indonesian Hydraulic Engineering Association (HATHI), Surabaya, 1995, pp. 199-206.
- Üne,s, F.; Demirci, M.; Ta,sar, B.; Kaya, Y.Z.; Varçin, H. Estimating Dam Reservoir Level Fluctuations Using Data-Driven Techniques. *Pol. J. Environ. Stud.* 2019, 28, 3451–3462. [CrossRef]
- Suprayogi, I. Model of Salt Intrusion Forecasting in Estuary Using Softcomputing, Dissertation, Surabaya : Management and Water Resource Engineering, Department of Civil Engineering, Faculty of Civil Engineering, Environmental and Earthquake, Sepuluh November Institute of Technology (ITS), 2009.
- Verniuwe, H., Georgiva, O., de Baets, B., Pauwels, V. R. N., Verhoest, N. E. C., de Trouch, F. P. Comparison of data driven Takagi-Sugeno models of rainfall-discharge dynamics. *Journal of Hydrology* 302, 2005, pp. 173-186.
- Zubaidi, S.; Al-Bugharbee, H.; Ortega-Martorell, S.; Gharghan, S.; Olier, I.; Hashim, K.; Al-Bdairi, N.; Kot, P. A Novel Methodology for Prediction Urban Water Demand by Wavelet Denoising and Adaptive Neuro-Fuzzy Inference System Approach. *Water* 2020, 12, 1628. [CrossRef]