



JURNAL RONA TEKNIK PERTANIAN

ISSN : 2085-2614; e-ISSN 2528 2654

JOURNAL HOMEPAGE : <http://www.jurnal.unsyiah.ac.id/RTP>



**Aplikasi Teknik Data Driven untuk Prediksi Debit Sungai Bulanan
Studi Kasus Bendung Loning, Magelang**

Joko Suryanto^{1*)}

¹⁾Program Studi Teknik Pertanian, STIPER Kutai Timur
Jl. Soekarno-Hatta No. 01 Sangatta Kutai Timur Kalimantan Timur 75387
*E-mail: djakasoerya@yahoo.co.id

Abstrak

Model prediksi debit sungai sangat penting dalam perencanaan, desain dan manajemen sumberdaya air. Penelitian ini bertujuan untuk membandingkan akurasi prediksi debit bulanan sungai Loning di DAS Loning Magelang menggunakan pendekatan model data driven. Pembentukan model didasarkan pada model deret waktu debit bulanan menggunakan data debit bulanan antara Januari 1990 hingga Desember 2015. Tiga model data driven yaitu ARIMA, ANFIS dan FFNN digunakan untuk prediksi debit bulanan sungai Loning periode 2014 - 2015. Indeks error (RMSE dan MAPE) dan koefisien Nash-Sutcliffe efficiency (NS) digunakan untuk mengevaluasi akurasi prediksi model. Hasil penelitian diperoleh nilai RMSE, MAPE dan NS model FFNN adalah 8,422 lt/ dt, 22.79 % dan 0.709, untuk model ANFIS 9,465 lt/dt, 25.62 % dan 0.633, sedangkan model ARIMA diperoleh 9,710 lt/dt, 27. 32 % dan 0.614. Nilai indeks error tersebut mengindikasikan bahwa model FFNN lebih sesuai untuk simulasi dan prediksi debit bulanan sungai Loning dibandingkan model ANFIS dan ARIMA.

Kata kunci: ANFIS, ARIMA, Debit bulanan, FFNN, Model data driven, Sungai Loning

**Application Data Driven Technique for Monthly Runoff Forecasting: A Case Study of
Loning Dam, Magelang**

Joko Suryanto^{1*)}

¹⁾Department of Agricultural Engineering, STIPER Kutai Timur
Jl. Soekarno-Hatta No. 01 Sangatta Kutai Timur Kalimantan Timur 75387
*E-mail: djakasoerya@yahoo.co.id

Abstract

The development of runoff forecasting model is one of the most important aspects in water resources planning, design and management. This study aimed to compare the accuracy data driven models for simulation and forecasting the monthly runoff data of Loning river, Loning Watershed Magelang. The models were developed based on time series model, and monthly data collected over 26 year period from January 1990 to December 2015. Three data driven models, ARIMA, ANFIS and FFNN models, were used for forecasting monthly runoff for period 2014 -2015. The index error, root mean square error (RMSE), mean absolute percentage error (MAPE) and Nash-Sutcliffe efficiency coefficient (NS) were employed to evaluate the performances of model

developed. The RMSE, MAPE and NS indices were obtained as 8,422 lt/s, 22.79 % and 0.709 for FFNN model, as 9,465 lt/s, 25.62 % and 0.633 for ANFIS and as 9,710 lt/s, 27.32 % and 0.614 for ARIMA model. The result indicated that FFNN model appear to be better than ARIMA and ANFIS model for simulation and forecasting the monthly runoff Loning river.

Keywords : ANFIS, ARIMA, Data driven model, FFNN, Loning River, Monthly run off

PENDAHULUAN

Prediksi debit aliran sungai sangat dibutuhkan dalam penerapan hidrologi diantaranya manajemen dan perencanaan sumberdaya air (Gaume dan Gosset, 2003), baik dalam jangka menengah maupun panjang, mingguan, bulanan, musiman maupun tahunan yang sering digunakan dalam operasional waduk dan manajemen irigasi (Abudu, dkk., 2010). Dalam bidang pertanian, penentuan ketersediaan air sungai yang akurat dibutuhkan dalam operasi jaringan irigasi untuk menunjang proses produksi pertanian. Perencanaan pengelolaan sistem irigasi membutuhkan data dan informasi yang memberikan gambaran tentang kondisi ketersediaan air beberapa waktu yang akan datang. Untuk memperoleh gambaran tersebut dapat diperoleh dari teknik prediksi (*fore casting*).

Salah satu model hidrologi yang dapat digunakan untuk prediksi adalah model yang termasuk dalam jenis data driven. Model data driven ini dapat dikelompokkan ke dalam model klasik dan sistem cerdas (Bardzadeh, 2014), termasuk model klasik adalah ARIMA dan regresi ganda, termasuk dalam sistem cerdas yaitu model jaringan saraf tiruan (ANN), adaptive neuro fuzzy inference system (ANFIS), teori chaos dan sistem dinamik, algoritma genetik, model hibrid wavelet dan support vector machine (SVM).

Dari beberapa model data driven yang ada, penentuan model prediksi debit sungai dengan kinerja yang memuaskan menjadi kunci utama keberhasilan perencanaan sistem irigasi. Dengan diketahuinya model prediksi yang sesuai untuk karakteristik data debit sungai Loning, diharapkan dapat membantu perencanaan sistem irigasi dalam pemanfaatan air tersedia secara efektif dan efisien.

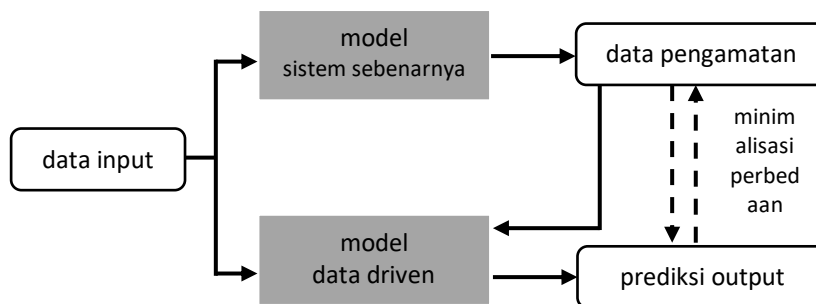
Tujuan Penelitian

Tujuan penelitian ini adalah untuk menentukan jenis model prediksi dengan pendekatan data driven yang sesuai dengan karakteristik data debit bulanan sungai Loning. Penelitian dilakukan dengan melakukan prediksi debit bulanan menggunakan model ARIMA, ANFIS dan FFNN kemudian membandingkan kinerja ketiga model tersebut. Hasil prediksi yang tepat diharapkan dapat membantu dalam pengambilan keputusan berkaitan dengan perencanaan dan operasi manajemen sumberdaya air di DAS Loning Magelang terutama dalam pemanfaatan debit sungai untuk irigasi.

Model Prediksi Limpasan (Runoff) DAS

Salah satu fungsi Daerah Aliran Sungai (DAS) adalah melepaskan air dalam bentuk limpasan atau runoff. Limpasan adalah semua air yang mengalir melalui sungai karena gaya gravitasi dan bergerak meninggalkan DAS tanpa memperhatikan asal/jalan yang ditempuh sebelum mencapai saluran. Limpasan atau runoff ini terdiri dari komponen aliran permukaan (*surface run off, direct run off*), aliran antara (*inter flow, sub surface run off*) dan aliran air tanah (*base flow*).

Metode prediksi debit sungai oleh Wang (2000) dikelompokkan ke dalam metode proses driven dan data driven. Metode proses driven merupakan model konseptual, model data driven merupakan jenis model black-box, dimana input dan output dihubungkan dengan persamaan matematis tanpa memperhitungkan mekanisme fisik dalam sistem yang ditinjau (Gambar 1). Kelemahan pendekatan proses driven antara lain data sulit diperoleh atau relatif mahal, dan membutuhkan waktu yang lama. Sedangkan keuntungan penggunaan model data driven sehingga model jenis ini semakin sering digunakan diantaranya: sangat sesuai untuk prediksi real-time, perhatian hanya difokuskan pada data input-output tanpa melihat proses fisik yang berlangsung (Veiga dkk., 2015).



Gambar 1. Sistem pembelajaran black box pada pendekatan data driven (Bardzadeh, 2014).

Model ARIMA

Auto Regressive Integrated Moving Average (ARIMA) adalah model deret waktu yang diperkenalkan oleh Box dan Jenkins (1976). Model ini merupakan kombinasi antara model *Auto Regressive Moving Average* (ARMA) dan proses pembedaan (*differencing*). Hasil proses pembedaan data deret waktu adalah model stasioner dengan bentuk umum proses ARMA.

Apabila prosedur ARIMA Box-Jenkins melibatkan komponen musiman, maka model ARIMA disebut sebagai model ARIMA musiman (seasonal ARIMA). Secara umum bentuk model ARIMA musiman $(P,d,q)^S$ dapat dituliskan (Wei, 2006):

$$\phi_p(B)\Phi_P(1-B)^d(1-B^s)^D X_t = \Theta_q(B)\Theta_Q(B^s)a_t \dots \quad (1)$$

dimana:

$\phi(B)$ = koefisien komponen AR orde p

$\Theta(B)$ = koefisien komponen MA orde q

$\Phi(B^s)$ = koefisien komponen AR musiman s orde P

$\Theta(B^s)$ = koefisien komponen MA musiman s orde Q

B = operator *backshift*

a_t = *white noise* ($a_t \sim WN(0, \sigma^2)$)

Model ARIMA mengandalkan data deret waktu dengan asumsi data lampau dari suatu deret waktu dan nilai error sebelumnya mengandung informasi untuk tujuan prediksi (Melyer dkk., 1998). Keuntungan lainnya adalah pembentukan model sangat memperhitungkan nilai autokorelasi data pengamatan yang sering ditemukan pada data deret waktu (Yurekli dan Kurunc, 2004; Parviz dkk., 2010).

Model ANFIS

ANFIS (*Adaptive Neuro Fuzzy Inference Systems*) merupakan penggabungan mekanisme fuzzy inference system yang digambarkan dalam jaringan saraf tiruan. Sistem inferensi fuzzy merupakan sekumpulan aturan dan suatu metode inferensi yang dikombinasikan dalam suatu struktur terhubung kemudian dilakukan pelatihan dan adaptasi (Kasabov, 2002., dalam Kusumadewi dan Hartati, 2006). Sedangkan proses pembelajaran pada jaringan saraf tiruan digunakan untuk mengoptimasi aturan-aturan fuzzy.

Dua metode dalam sistem inferensi fuzzy yaitu metode Tsukamoto dan metode Sugeno. Dalam metode Tsukamoto, himpunan fuzzy pada konsekuennya harus bersifat monoton (monoton naik ataupun turun). Pada metode Sugeno, konsekuen bukan merupakan himpunan fuzzy, namun merupakan persamaan linier dengan variabel-variabel sesuai dengan variabel inputnya. Beberapa keuntungan penggunaan metode inferensi fuzzy metode Sugeno antara lain (Sivanandam, dkk., 2007): sangat efisien dalam penghitungan, bekerja dengan baik dengan persamaan linier, bekerja baik dengan teknik adaptif dan optimasi, dan sangat sesuai untuk analisis matematis. Metode Sugeno dapat dibagi menjadi dua orde, yaitu orde-0 dan orde-1. Bentuk model fuzzy Sugeno orde-0 dan orde-1 (Kusumadewi dan Hartati, 2006) :

orde-0; IF $(x_1 \text{ is } A_1)^\circ (x_2 \text{ is } A_2)^\circ (x_3 \text{ is } A_3)^\circ \dots (x_N \text{ is } A_N)^\circ$ THEN $z = k$

orde-1; IF $(x_1 \text{ is } A_1)^\circ \dots^\circ x_N \text{ is } A_N$ THEN $z = p_1 \cdot x_1 + \dots + p_N \cdot x_N + q$

dengan A_i adalah himpunan fuzzy ke- i sebagai antesenden, \circ adalah operator fuzzy (AND, OR), p_i adalah suatu konstanta (tegas) ke- i dan q konstanta dalam konsekuen.

Apabila terdapat 2 input x_1, x_2 dan satu output y . Terdapat 2 aturan pada basis aturan model Sugeno:

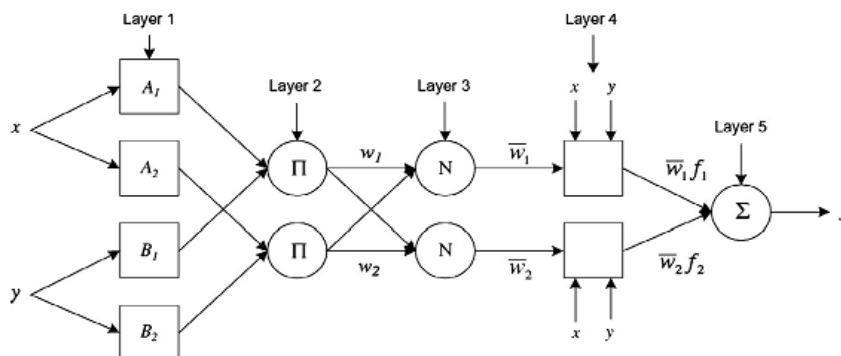
If x_1 is A_1 and x_1 is B_1 then $y_1 = c_{11}x_1 + c_{12}x_2 + c_{10}$

If x_1 is A_2 and x_2 is B_2 then $y_2 = c_{21}x_1 + c_{22}x_2 + c_{20}$

Jika a adalah predikat aturan kedua aturan w_1 dan w_2 , maka dapat dihitung rata-rata terbobot:

$$y = \frac{w_1 y_1 + w_2 y_2}{w_1 + w_2} = \bar{w}_1 y_1 + \bar{w}_2 y_2 \quad \dots \quad (2)$$

Jaringan ANFIS (Gambar 2) terdiri dari lima lapisan sebagai berikut (Kusumadewi dan Hartati, 2006):

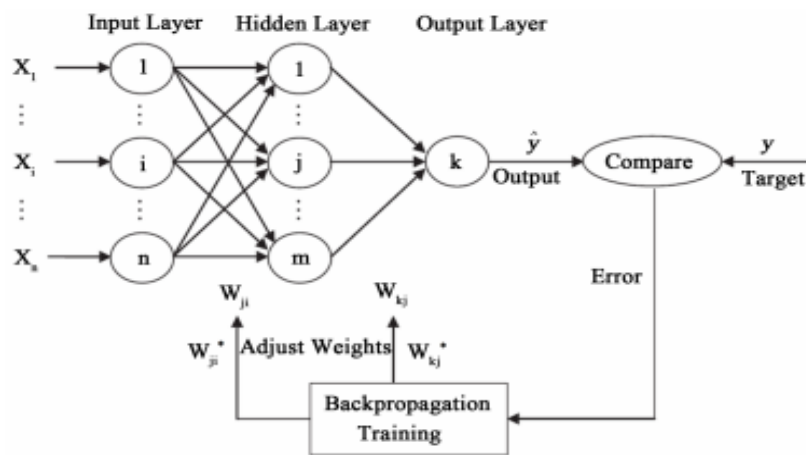


Gambar 2. Arsitektur ANFIS (Kusumadewi dan Hartati, 2006).

- Lapisan 1, fuzzifikasi. Setiap neuron i pada lapisan pertama adaptif terhadap parameter suatu fungsi aktivasi. Output dari setiap neuron berupa derajat keanggotaan yang diberikan oleh fungsi keanggotaan input (parameter premis).
- Lapisan 2, operasi logika. Setiap neuron pada lapisan 2 berupa neuron tetap dengan outputnya hasil perkalian dari masukan lapisan 1. Setiap node merepresentasikan α predikat (firing strenght) dari aturan ke- i .
- Lapisan 3, normalisasi. Setiap neuron pada lapisan ketiga berupa node tetap, output pada node ini disebut juga *normalised firing strenght* merupakan rasio dari *firing strenght* aturan ke- i terhadap jumlah dari *keseluruhan firing strenght*.
- Lapisan 4, defuzzifikasi. Setiap neuron pada lapisan keempat merupakan node adaptif terhadap suatu ouput dengan parameter linier (parameter konsekuen).
- Lapisan 5, total output. Setiap neuron pada lapisan kelima adalah neuron tetap dan merupakan penjumlahan seluruh output dari lapisan ke-4.

Model Feedforward Neural Network (FFNN)

Siang (2004) membagi arsitektur *artificial neural network* (ANN) ke dalam: jaringan layar tunggal, jaringan layar jamak dan jaringan reccurent. Salah satu bentuk jaringan layar jamak adalah *feed forward neural network* (FFNN). FFNN dengan 3 lapisan yaitu input, satu lapisan tersembunyi dan satu lapisan *output* sangat umum digunakan untuk pemodelan (prediksi dan peramalan) variabel hidrologi (Gaume dan Gosset, 2003; Maier dan Dandy, 2000). Pada arsitektur jaringan FFNN arus informasi mengalir ke satu arah dari layer input ke layer berikutnya hingga ke *layer output*, tanpa ada penambahan neuron output yang memberikan sinyal pada input (*feedback loop*).



Gambar 3. FFNN backpropagation 3 layer (Amirhossien, *dkk.*, 2015).

Arsitektur jaringan FFNN pada Gambar 3 dapat dituliskan sebagai ANN (j,k,l) yaitu j neuron input, k neuron lapisan tersembunyi dan l neuron output. Apabila bobot yang menghubungkan neuron input dan lapisan tersembunyi adalah w_{kj} , bobot antara neuron lapisan tersembunyi dengan *output* adalah w_{lk} , parameter b_k dan b_l merupakan bias pada lapisan tersembunyi dan output. Jika x_j variabel input dan y_l variabel output, dengan fungsi aktivasi tan-sigmoid (f_2) pada lapisan tersembunyi dan fungsi linier (f_1) pada lapisan output, maka input ditransformasikan menjadi output menggunakan persamaan berikut :

$$y_l = f_1 \left[\sum_{k=1}^k w_{lk} f_2 \left(\sum_{j=1}^j w_{kj} x_j + b_k \right) + b_l \right] \quad \dots \quad (3)$$

$$f_2(p) = \frac{2}{(1 + e^{-2p})} - 1 \quad \dots \quad (4)$$

METODE PENELITIAN

Waktu dan Tempat Penelitian

Penelitian dilaksanakan pada bulan Desember 2015. Lokasi penelitian adalah Daerah Aliran Sungai (DAS) Loning yang merupakan sub-DAS Tangsi dan berada di wilayah Kabupaten Magelang, Propinsi Jawa Tengah.

Alat dan Bahan

Bahan yang digunakan adalah data non-spasial terdiri dari data debit sungai yang diperoleh dari Dinas Pekerjaan Umum, Energi dan Sumberdaya Mineral (UPT DPU ESDM) bidang pengairan Kabupaten Magelang, Jawa Tengah. Data sekunder berupa data debit harian sungai Loning periode 1990 – 2015. Alat yang digunakan berupa *software* komputer program Microsoft Office, Minitab 16, SAS 9.1. dan MATLAB R2014.

Analisa Data

1. Prediksi debit sungai Loning dilakukan dengan membagi data debit bulanan antara tahun 1990 – 2013 digunakan dalam pembentukan model (*in-sample*), sedangkan data tahun 2014 – 2015 untuk validasi model (*out-sampel*). Tahapan pembentukan model ARIMA mengikuti prosedur Box dan Jenkins (1976) yaitu : ¹)identifikasi model, ²)estimasi parameter, dan ³)uji kesesuaian model. Pada tahap identifikasi model, untuk memperoleh data yang stasioner dalam mean dan varian menggunakan teknik differencing dan transformasi data. Analisis stasioneritas data dalam varian menggunakan plot Box-Cox, stasioneritas mean menggunakan analisa plot *auto corelation function* (ACF) dan *partial auto corelation function* (PACF). Orde model AR dan MA, baik reguler maupun musiman ditentukan menggunakan plot ACF dan PACF data yang telah stasioner. Estimasi parameter model menggunakan metode *conditional least square* (CLS) dengan bantuan program SAS. Tahapan *diagnostic checking* untuk menilai kecukupan model ARIMA melalui uji asumsi residual model. Uji Ljung-Box untuk menguji sifat *white noise* dan metode Kolmogorov-Smirnov untuk uji residual model berdistribusi normal. Penentuan model terbaik menggunakan kriteria minimum nilai AIC, SBC pada data pembentukan model.
2. Prediksi debit sungai Loning menggunakan model ANFIS menggunakan sistem inferensi fuzzy model sugeno orde satu pada MATLAB R2014. Tahapan pertama adalah pembagian data, yaitu data antara 1990 – 2013 sebagai data training (*in-sample*) dan 2014 – 2015 sebagai data checking (*out-sample*). Variabel input model ANFIS ditentukan

berdasarkan model AR dalam model ARIMA. Bentuk fungsi keanggotaan pada proses pembelajaran ditentukan berdasarkan nilai RMSE, MAPE, dan SMAPE terkecil pada penggunaan fungsi keanggotaan *Gaussian*, *Trapezoidal* dan *Generalized Bell*. Tahap selanjutnya adalah menggunakan model ANFIS untuk memprediksi debit bulanan sungai Loning periode 2014-2015.

3. Prediksi debit bulanan sungai Loning menggunakan model ANN dilakukan menggunakan jaringan feedforward neural network (FFNN) dengan pembelajaran Levenberg-Marquardt (*trainlm*). Prediksi debit bulanan menggunakan model FFNN dengan variabel input x_t yang digunakan model autoregressive (AR) dalam model ARIMA yaitu x_{t-1} dan x_{t-3} . Tahapan dalam prediksi menggunakan ANN adalah pembagian data. Data debit bulanan tahun 1990 – 2013 digunakan untuk training dan testing dengan pembagian data 75 % dan 25 %, sedangkan data tahun 2014 - 2015 digunakan untuk validasi. Sebelum melakukan training, terlebih dahulu dilakukan normalisasi data menggunakan fungsi *mapminmax* yang sudah tersedia dalam MATLAB. Normalisasi data tersebut akan diperoleh nilai dengan range -1 dan 1 yaitu merupakan fungsi aktivasi sigmoid bipolar (*tansig*). Penentuan jumlah neuron pada lapisan tersembunyi dilakukan dengan cara trial and error dengan jumlah neuron 2 – 10, 15, dan 20. Jumlah neuron yang menghasilkan *mse* terendah dipilih sebagai arsitektur jaringan untuk prediksi debit bulanan periode 2014-2015.
4. Perbandingan hasil prediksi debit model ARIMA, ANFIS dan FFNN menggunakan kriteria akurasi antara lain *root mean square error* (RMSE), *symmetric mean absolute percentage error* (SMAPE), *mean absolute percentage error* (MAPE) dan koefisien efisiensi Nash-Sutcliffe (NS).

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n \{y_{o(t)} - y_{f(t)}\}^2} \quad \dots \quad (5)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_{o(t)} - y_{f(t)}}{y_{o(t)}} \right| \cdot 100 \quad \dots \quad (6)$$

$$SMAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_{o(t)} - y_{f(t)}}{y_{o(t)}} \right| \cdot 100 \quad \dots \quad (7)$$

$$NS = 1 - \frac{\sum_{t=1}^n (y_{o(t)} - y_{f(t)})^2}{\sum_{t=1}^n (y_{o(t)} - \bar{y}_o)^2} \quad \dots \quad (8)$$

dimana:

$y_{o(i)}$ = nilai debit observasi (lt/dt) untuk $i = 1, 2, 3, \dots n$

\bar{y}_o = rerata debit observasi (lt/dt)

$y_{f(i)}$ = nilai debit prediksi model (lt/dt) untuk $i = 1, 2, 3, \dots n$

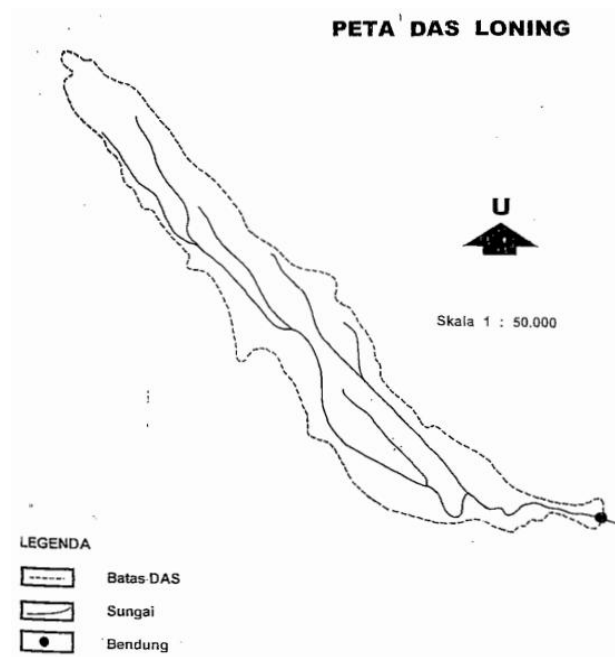
HASIL DAN PEMBAHASAN

Deskripsi Lokasi Penelitian

Daerah Aliran Sungai (DAS) Loning terletak di Kecamatan Kaliangkrik, Kabupaten Magelang Propinsi Jawa Tengah dengan luas 933 Ha. DAS Loning merupakan daerah tangkapan (*catchment area*) dari DI Loning melalui Bendung Loning. Peta DAS Loning disajikan pada Gambar 4.

Penentuan keadaan iklim wilayah mencakup pensifatan karakteristik hujan DAS Loning. Data curah hujan diperoleh dari stasiun hujan yang berada di kawasan DAS Loning yaitu stasiun Kalegen dan stasiun hujan Kaliloro dengan panjang data antara tahun 1990 sampai 2012.

Jumlah curah hujan tahunan rata-rata sebesar 3,166 mm/tahun dengan curah hujan rerata terendah 40 mm pada bulan Juli dan curah hujan tertinggi mencapai 505 mm pada bulan Januari. Rata-rata curah hujan 0 mm terjadi pada bulan Juni – Oktober. Perbedaan curah hujan pada musim hujan dan musim kemarau sangat tegas dengan nilai koefisien variansi antara 0.25 – 1.78.



Gambar 4. Peta DAS Loning (Sumiyati, 2002).

Klasifikasi iklim di DAS Loning berdasarkan klasifikasi Oldeman termasuk daerah agroklimat subzona B2 dengan 7 bulan basah berturut-turut yaitu bulan Oktober, November, Desember, Januari, Februari, Maret dan April, dan 4 bulan kering berturut-turut yaitu bulan Juni, Juli, Agustus dan September.

Karakteristik Data Debit Bulanan

Tabel 1. adalah karakteristik data debit bulanan digunakan pada data training (1990 – 2006) dan testing (2007-2013). Semua nilai statistik diskriptif pada data training lebih tinggi dibandingkan data testing, kecuali pada nilai debit minimum. Data debit bulanan baik untuk training maupun testing mempunyai bentuk distribusi menceng ke kanan (*positively skewed distribution*), maka nilai ekstrim terjadi pada nilai lebih besar dari nilai rerata.

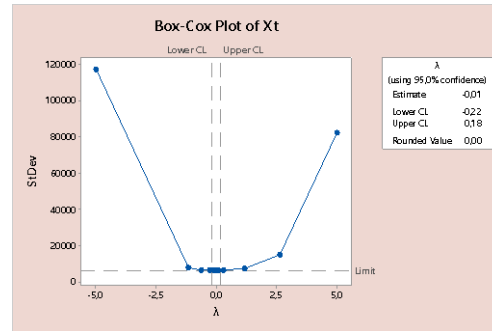
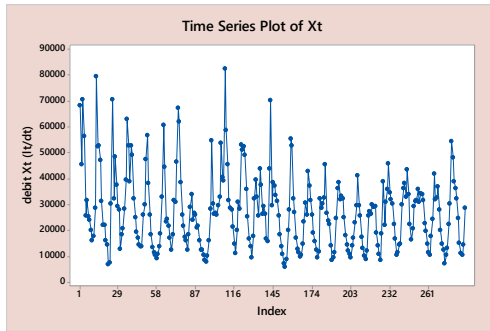
Tabel 1. Karakteristik data debit bulanan training dan testing.

Data	Qave (lt/dt)	Qmax (lt/dt)	Qmin (lt/dt)	Qstd	Cv	Qskew
Training	28,396	82,707	5,609	15,796	0.556	1.008
Testing	24,931	54,411	7,056	10,734	0.431	0.266

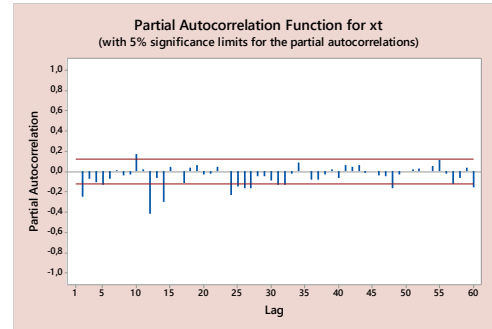

Prediksi Debit Bulanan Model ARIMA

Hasil uji stasioneritas varian data debit bulanan 1990 – 2013 menggunakan plot Box-Cox (Gambar 5.b), dengan nilai $\lambda = -0.01$ maka data debit belum stasioner dalam varian. Transformasi Box-Cox dengan bentuk $x_t = \ln X_t$ digunakan untuk memperoleh data baru yang stasioner dalam varian.

Hasil uji stasioneritas dalam mean menggunakan plot ACF dan PACF hingga lag 60 diketahui bahwa data belum stasioner dalam mean yang ditunjukkan adanya pola turun perlahan (*dies down very slowly*), sehingga harus dilakukan *differencing* musiman (D=1, S=12) maupun reguler (d=1) menggunakan persamaan $\nabla \nabla^{12} x_t = \nabla(x_t - x_{t-12}) = x_t - x_{t-1} - x_{t-12} + x_{t-13}$. Plot ACF dan PACF setelah *differencing* data pada lag 12 dan 1 data series diperlihatkan pada Gambar 6.a dan 6.b.



Gambar 5.a. *Time sereis plot* data debit (X_t) Gambar 5.b. *Plot Box-Cox* data debit (X_t)



Gambar 6.a. *Plot ACF* x_t


Gambar 6.b. *Plot PACF* x_t

Identifikasi model potensial menggunakan plot ACF dan PACF data yang telah stasioner. Pada Gambar 6.a dan 6.b. terlihat plot ACF nonmusiman *cut off* pada lag 1 dan 10, sedangkan lag musiman pada lag 12. Plot PACF pada Gambar 6.b. menunjukkan bahwa lag nonmusiman signifikan pada lag 1, 5, dan 10, sedangkan pada lag musiman signifikan pada lag 12 dan 24. Berdasarkan sifat ACF/PACF teoritis lag musiman, maka model dugaan data debit $\nabla \nabla^{12} z_t$ adalah moving average pola musiman untuk 12 lag. Berdasarkan Gambar 6.a dan 6.b, maka model ARIMA yang dapat digunakan untuk meramalkan debit sungai Loning adalah Model ARIMA $([1,3],1,[2,3]) (0,1,1)^{12}$.


$$\begin{aligned}
 x_t = & (1 + \phi_1) x_{t-1} - \phi_1 x_{t-2} + \phi_3 x_{t-3} - \phi_3 x_{t-4} + x_{t-12} - (1 + \phi_1) x_{t-13} \\
 & + \phi_1 x_{t-14} - \phi_3 x_{t-15} + \phi_3 x_{t-16} + a_t - \theta_2 a_{t-2} - \theta_3 a_{t-3} - \theta_1 a_{t-12} + \\
 & \theta_2 \theta_1 a_{t-14} + \theta_3 \theta_1 a_{t-15} \dots \dots \quad (9)
 \end{aligned}$$

Persamaan model ARIMA (Persamaan 9) di atas memperlihatkan bahwa debit saat bulan sekarang (x_t) ditentukan oleh debit 4 bulan sebelumnya ($x_{t-1}, x_{t-2}, x_{t-3}, x_{t-4}$), pengaruh musiman (x_{t-12}) dan debit 4 bulan pada tahun sebelumnya ($x_{t-13}, x_{t-14}, x_{t-15}, x_{t-16}$), ditambah dengan kesalahan acak.


Hasil uji signifikansi parameter model dengan nilai $\alpha = 0.05$ menunjukkan bahwa parameter berbeda nyata dengan 0 (signifikan) ditunjukkan dengan nilai $p\text{-value} < \alpha$. Hasil uji *Ljung-Box* terhadap asumsi residual bersifat *white noise* diperoleh bahwa residual model telah memenuhi asumsi *white noise* hingga lag 48 dengan nilai $p\text{-value} > \alpha$. Hasil pengujian distribusi normal residual model diperoleh bahwa residual model telah mengikuti distribusi normal dengan nilai $p\text{-value} = 0.0784$ dan lebih besar dari taraf nyata 0.05. Sehingga dapat disimpulkan bahwa model ARIMA $([1,3],1,[2,3]) (0,1,1)^{12}$ dapat digunakan untuk memprediksi debit bulanan sungai Loning. Hasil prediksi debit bulanan berdasarkan data *in-sample* pada Gambar 7. terlihat pola data observasi dan prediksi diperoleh hampir sama, namun akurasi prediksi masih rendah yang ditunjukkan dengan nilai RMSE prediksi masih sangat besar yaitu 10,254 lt/dt. Nilai maksimum debit data *in-sample* 82,707 lt/dt, sedangkan hasil prediksi diperoleh 127,379 lt/dt, hal ini menunjukkan bahwa model ARIMA mampu memprediksi debit-debit puncak bendung Loning. Hasil prediksi debit bulanan periode 2014 – 2015 menggunakan model ARIMA $([1,3],1,[2,3]) (0,1,1)^{12}$ secara grafis diperlihatkan pada Gambar 8.a. dan Gambar 8.b.



Gambar 7. Debit prediksi model ARIMA dan observasi periode 1991 – 2013.



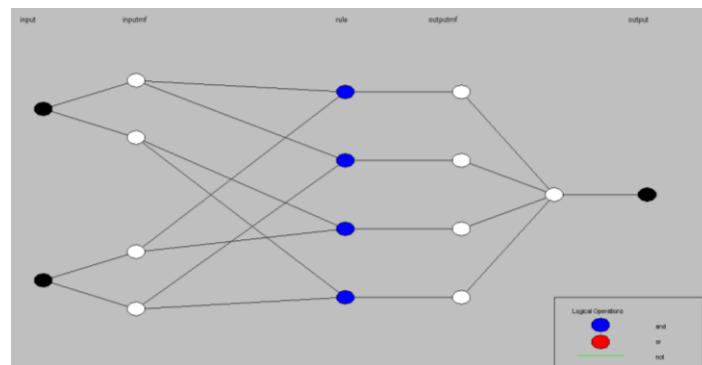
Gambar 8.a. Grafik prediksi model ARIMA dan observasi periode 2014-2015.



Gambar 8.b. Diagram pencar debit prediksi ARIMA dan obsev 2014-2015.

Prediksi Debit Bulanan Model ANFIS

Prediksi debit bulanan model ANFIS menggunakan variabel input x_{t-1} dan x_{t-3} , merupakan model autogresif dalam model ARIMA. Arsitektur ANFIS yang terbentuk adalah 2 variabel input dan 2 fungsi keanggotaan, sehingga diperoleh jumlah aturan (rule) sebanyak 4 buah. Arsitektur ANFIS pada Gambar 9. terdapat parameter model sebanyak 8, dimana 4 parameter merupakan parameter linier atau konsekuen yang digunakan pada lapisan 4, dan 4 parameter nonlinier pada lapisan satu. Setelah menentukan variabel input, tahapan berikutnya adalah menentukan *number of membership function* dan *membership function type*. Jumlah fungsi keanggotaan sebanyak 2 dengan 3 jenis fungsi keanggotaan yaitu *Gaussian*, *Trapezoidal* dan *Generalized Bell*.




Gambar 9. Arsitektur ANFIS dengan 2 variabel input.

Kriteria RMSE, SMAPE dan MAPE pada proses training digunakan untuk menentukan fungsi keanggotaan yang menghasilkan prediksi terbaik. Berdasarkan kriteria keakuratan RMSE, SMAPE dan MAPE pada Tabel 2. maka dipilih fungsi keanggotaan Generalized Bell yang memberikan nilai indeks error minimum pada data outsample.

Tabel 2. Perbandingan Keakuratan Prediksi in sample dan out sample model ANFIS.


kriteria		Fungsi keanggotaan		
		Gaussian	Generalized Bell	<i>Trapezoidal</i>
RMSE	<i>In sample</i>	0,2738	0,2737	0,2702*
	<i>Out sample</i>	0,3196	0,3058*	0,3704
SMAPE	<i>In sample</i>	2,0436	2,0428	2,0112*
	<i>Out sample</i>	2,5681	2,4796*	2,9068
MAPE	<i>In sample</i>	2,0494	2,0486	2,0170*
	<i>Out sample</i>	2,08	2,25*	2,41

Hasil prediksi model ANFIS dengan fungsi keanggotaan Generalized Bell pada data training dan testing diperlihatkan pada Gambar. 10. Secara grafis dapat dilihat bahwa prediksi ANFIS tidak mampu memprediksi debit-debit puncak bulanan sungai Loning. Nilai maksimum prediksi diperoleh 58,716 lt/dt, sedangkan nilai maksimum observasi 82,707 lt/dt. RMSE prediksi diperoleh 8,526 lt/dt, menunjukkan akurasi model ANFIS cukup tinggi. Rata-rata error prediksi terbesar terjadi pada data debit bulanan sebelum tahun 2000, dimana model ANFIS menghasilkan debit prediksi yang lebih kecil dari debit observasi, terutama pada periode-periode debit puncak.




Gambar 10. Debit prediksi model ANFIS dan observasi periode 1990 – 2013.

Hasil prediksi debit bulanan periode 2014 – 2015 secara grafis ditampilkan pada Gambar 11.a. dan 11.b. Pola debit prediksi mampu mengikuti pola debit observasi dengan nilai $R^2 = 0.683$. Prediksi periode 2014 lebih mendekati nilai debit observasi apabila dibandingkan hasil prediksi pada debit bulanan periode 2015, hal ini disebabkan oleh panjang langkah prediksi (I) yang semakin besar.



Gambar 11.a. Grafik prediksi model ANFIS dan observasi 2014-2015.



Gambar 11.b. Diagram pencar debit prediksi model ANFIS dan observasi 2014-2015.

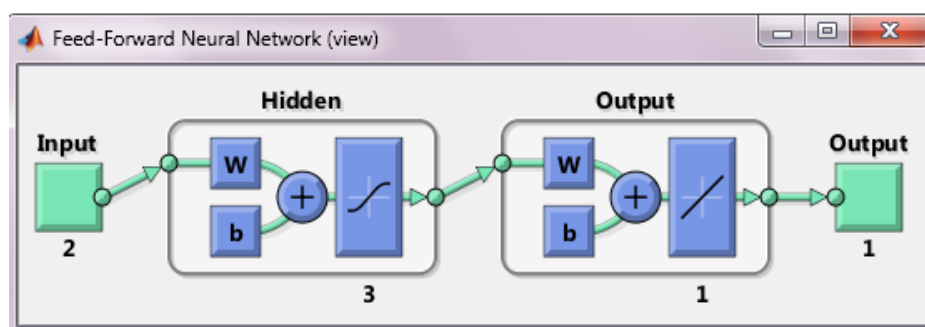
Prediksi Debit Bulanan Model ANN

Jumlah neuron pada lapisan tersembunyi pada arsitektur FFNN ditentukan berdasar nilai minimum *mse* pada proses training dan testing. Nilai *mse* pada jumlah neuron yang berbeda diperlihatkan pada Tabel 3.

Tabel 3. Nilai MSE hasil pembelajaran Levenberg-Marquardt Backpropagation.


Jumlah neuron tersembunyi	MSE training	MSE testing
2	0.0737	0.1099
3*	0.0831	0.0606
4	0.0858	0.0809
5	0.0887	0.0869
6	0.0871	0.0806
7	0.0675	0.1144
8	0.0678	0.0776
9	0.0739	0.0905
10	0.0524	0.1264
15	0.0679	0.1267
20	0.0679	0.1092

Nilai *mse* pada Tabel 3. *mse* training cenderung turun dengan penambahan neuron, sedangkan *mse* testing cenderung naik sebanding banyaknya neuron pada lapisan tersembunyi. Nilai *mse* testing terendah yaitu dengan jumlah neuron lapisan tersembunyi 3, maka arsitektur jaringan yang dipilih adalah 2 input yaitu x_{t-1} dan x_{t-3} , jumlah neuron lapisan tersembunyi 3 dan output 1 diperlihatkan pada Gambar 12.




Gambar 12. Arsitektur FFNN 3 layer dengan 3 neuron pada lapisan tersembunyi.

Jaringan yang terbentuk (2,3,1) digunakan untuk memprediksi debit bulanan periode 2014-2015. Hasil prediksi menggunakan data training dan testing secara grafis dapat dilihat pada Gambar 13. Hasil prediksi FFNN tidak mampu memprediksi debit puncak sungai Loning, terutama yang terjadi sebelum tahun 2000. Hal ini disebabkan oleh perbedaan karakteristik data antara data training dan testing. Selain itu, data yang tidak stabil dengan nilai rerata dan maksimum lebih tinggi pada data training juga menyebabkan hasil prediksi jauh berbeda terutama pada debit puncak. Nilai maksimum prediksi diperoleh 59,243 lt/dt, sedangkan nilai maksimum observasi 82,707 lt/dt. RMSE prediksi diperoleh 8,640 lt/dt, menunjukkan akurasi model FFNN cukup tinggi.




Gambar 13. Debit prediksi model FFNN dan observasi periode 1990 – 2013.

Hasil prediksi debit bulanan periode 2014-2015 secara grafis diperlihatkan pada Gambar 14.a, sedangkan diagram pencar debit observasi dan prediksi diperlihatkan Gambar 14.b. Hasil prediksi tersebut mendekati observasi dengan nilai $R^2 = 0.717$.



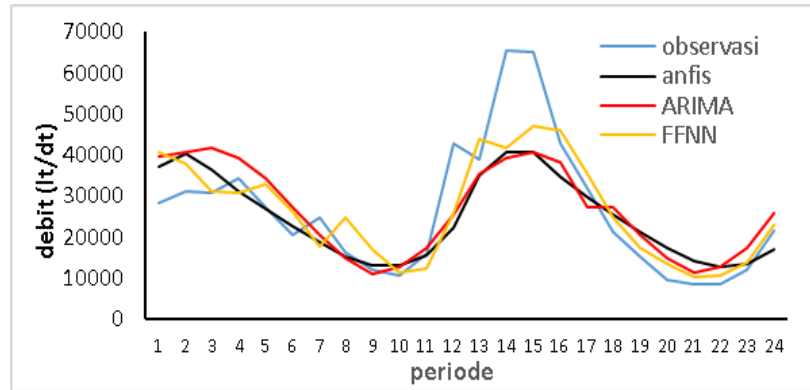
Gambar 14.a. Grafik prediksi model FFNN dan observasi periode 2014-2015.



Gambar 14.b. Diagram pencar debit prediksi model FFNN dan observasi 2014-2015.

Perbandingan Kinerja Model Prediksi

Berdasarkan Gambar 15. terlihat prediksi model FFNN dan ANFIS pada periode hujan tahun 2014 lebih mendekati debit observasi dibandingkan model ARIMA, sedangkan pada debit puncak baik model FFNN, ANFIS maupun ARIMA tidak mampu mengikuti pola puncak debit bulanan sungai Loning. Perbandingan akurasi prediksi dari ketiga model tersebut dapat dilihat pada Tabel 4.



Gambar 15. Debit observasi dan prediksi model ARIMA, ANFIS dan FFNN periode 2014 – 2015.

Tabel 4. Akurasi ARIMA, ANFIS dan FFNN prediksi debit periode 2014 – 2015.

Kriteria	Observasi	Model ARIMA	Model ANFIS	Model FFNN
rerata (lt/dt)	26,415	26,424	25,527	26,417
max (lt/dt)	65,265	41,810	44,117	46,900
min (lt/dt)	8,492	11,070	9,480	10,230
RMSE (lt/dt)	-	9,710	9,465	8,422
MAPE (%)	-	27.23	25.62	22.79
NS	-	0.614	0.633	0.709
korelasi (r)	-	0.79	0.83	0.85

Berdasarkan Tabel 4. koefisien efisiensi Nash-Sutcliffe (NS) hasil prediksi model FFNN mempunyai kinerja baik dengan nilai NS = 0.709 terletak antara 0.65 – 0.75 (Chen, *dkk.*, 2011), kinerja model ANFIS maupun ARIMA cukup dengan nilai koefisien NS 0.633 dan 0.614. Nilai indeks error RMSE dan MAPE model FFNN diperoleh 8,422 lt/dt dan 22.79 % lebih kecil dibandingkan dengan model ARIMA maupun ANFIS, sehingga model FFNN lebih sesuai untuk mensimulasi debit bulanan sungai Loning. Nilai MAPE prediksi model

FFNN diperoleh 22.79 % lebih kecil 25 % sehingga hasil prediksi FFNN tersebut sangat memuaskan (Makridakis, *dkk.*, 1995).

KESIMPULAN

Prediksi debit bulanan sangat penting untuk pengambilan keputusan dalam manajemen sumberdaya air. Penelitian ini difokuskan pada perbandingan akurasi hasil prediksi model ARIMA, ANFIS dan FFNN terhadap debit sungai Loning periode 2014 – 2015 menggunakan kriteria indeks error RMSE, MAPE, dan koefisien efisiensi Nash-Sutcliffe (NS). Berdasarkan nilai NS, prediksi model FFNN mempunyai kinerja baik, sedangkan model ANFIS dan ARIMA cukup. Nilai RMSE dan MAPE model FFNN lebih kecil dibandingkan model ANFIS dan ARIMA. Maka model FFNN dengan variabel bebas debit satu bulan sebelum (x_{t-1}) dan 3 bulan sebelumnya (x_{t-3}) lebih handal untuk mensimulasi debit bulanan sungai Loning dibandingkan model ANFIS maupun ARIMA.

DAFTAR PUSTAKA

- Abudu, S., Cui.,C., King, J.P., dan Abudukadeer, K. 2010. *Comparison of Performance of Statistical Models in Forecasting Monthly Streamflow of Kizil River, China*. Water Science and Engineering, 3(3): 269–281.
- Amirhossien, F., Alireza., F., Kazem, J., dan Mohammadbaher, S. 2015. *A Comparison of ANN and HSPF Models for Runoff Simulation in Balkhichai River Watershed, Iran*. American Journal of Climate Change, 4, 203–216.
- Badrzadeh, Honey. 2014. *River Flow Forecasting Using an Integrated Approach of Wavelet Multi-Resolution Analysis and Computational Intelligence Technique*. Thesis Ph. D. Department of Civil Engineering. Curtin University.
- Box, G.E.P, dan Jenkins G.M. 1970. *Time Series Analysis: Forecasting and Control*. Edisi Pertama. Holden-Day. San Fransisco.
- Chen, F., Wade.T.C., Patrick, J.S., dan Daniel, N.M. 2011. *Improving Hydrologic of a Catchment Model Via Assimilation of Surface Soil Moisture*. Advances in Water Resources, 34, 526-536.
- Gaume, E., dan Gosset, R. 2003. *Over-parameterisation, a Major Obstacle to the Use of Artificial Neural Network in Hydrology*. Hydrology and Earth System Science, 7(5): 693–706.
- Kusumadewi, S. dan Hartati, S. 2006. *Neuro-Fuzzy: Integrasi Sistem Fuzzy dan Jaringan Syaraf*. Graha Ilmu. Yogyakarta.

- Maier, H., dan Dandy, G. 2000. *Neural Network for the Prediction and Forecasting of Water Resources Variables: A Review of Modeling Issues and Applications*. Journal Environment Modeling & Software, 15, 101 -124.
- Makridakis, S.,S, Wheelwright dan V. Mcgee. 1995. *Metode dan Aplikasi Peramalan*. Jilid 1, Edisi Kedua. Erlangga. Jakarta.
- Melyer, A., Kenny, G., dan Quinn, T. 1998. *Forecasting Irish Inflation Using ARIMA Models*. Technical Paper.
- Parvis, L.,Kholghi, M., dan Hoorfar, A. 2010. *A Comparison of the Efficiency of Parameter Estimation Methods in the Context of Streamflow Forecasting*. Journal of Agricultural Science and Technology, JAST, 12, 47-60.
- Siang, J.J. 2009. *Jaringan Syaraf Tiruan dan Pemogramannya Menggunakan MATLAB*. Penerbit Andi. Yogyakarta.
- Sivanandam, S.N., Sumathi, S., dan Deepa, S.N. 2007. *Introduction to Fuzzy Logic Using MATLAB*. Springer BerlinHeidelberg. New York.
- Sumiyati. 2002. *Prediksi Ketersediaan Air Sebuah DAS Menggunakan Model NAM (Nedbor Afstromnings Model): Studi Kasus di DAS Lonng, Magelang Jawa Tengah*. Tesis S2. UGM. Yogyakarta.
- Wang, W. 2006. *Stochasticity, Nonlinearity and Forecasting of Streamflow Processes*. IOS Press: Amsterdam. Netherlands.
- Veiga, B.V., Hasan, Q.K., dan Jianun, H. 2015. *Development of Flow Forecasting Models in the River Algary Alberta, Canada*. Journal Water, 7, 99 -115.
- Wei, W.W.S. 2006. *Time Series Analysis, Univariate and Multivariate Methods*. Second Edition. Addison Wesley Publishing Company. Canada.
- Yurekli, Kadri dan Kurunc, Ahmet. *Performances of Stochastic Approaches in Generating Data for Drought Analysis*. Journal of Spacial Hydrology, 5(1): 20–32.