



Prediksi Tinggi Permukaan Air Waduk Menggunakan Artificial Neural Network Berbasis Sliding Window

Dwi Kartini¹, Friska Abadi², Triando Hamonangan Saragih³

^{1,2,3}Program Studi Ilmu Komputer, Fakultas MIPA, Universitas Lambung Mangkurat

¹dwikartini@ulm.ac.id, ²friska.abadi@ulm.ac.id, ³triando.saragih@ulm.ac.id

Abstract

The water level in the reservoir is an important factor in the operation of a hydroelectric turbine to control water overflow so that there is no excessive degradation. This water control has an influence on the performance and production of hydroelectric energy. The daily reservoir water level (tpaw) recording of PLTA Riam Kanan is carried out through a daily direct measurement and observation process on the reservoir measuring board which is recapitulated every month in excel form. This time series historical data continues to grow every day to become a data warehouse that is still useless if only stored. Extracting knowledge from the data warehouse can be done using one of the artificial neural network data mining techniques, namely backpropagation to predict the next day's tpaw. Historical data for the tpaw time series is presented with a sliding window concept based on the window sizes used, namely 7, 14, 21 and 28. The window size represents the number of days as an input layer variable in the backpropagation network architecture to predict the next day's tpaw. Some backpropagation network testing is carried out using a combination of the number of window sizes against the comparison of the amount of training data and test data on the network. The prediction results obtained with the smallest mean squared error (mse) in network testing is 0.000577 as a high accuracy value of the prediction results. The network architecture with the smallest mse using 28 input layers, 10 hidden layers and 1 output layer can be a knowledge that can help the hydropower plant as an alternative in making turbine operation decisions based on the predicted results of reservoir water level.

Keywords: artificial neural network, sliding window, backpropagation, network architecture, mse

Abstrak

Tinggi permukaan air waduk merupakan salah satu faktor penting dalam proses pengoperasian turbin Pembangkitan Listrik Tenaga Air (PLTA) untuk mengontrol luapan air sehingga tidak terjadi degradasi yang berlebihan. Pengontrolan air ini memiliki pengaruh terhadap kinerja dan hasil produksi energi listrik PLTA. Pencatatan tinggi permukaan air waduk (tpaw) harian PLTA Riam Kanan dilakukan melalui proses pengukuran dan pengamatan langsung setiap hari pada papan ukur waduk yang direkap setiap bulan dalam bentuk excel. Data historis deret waktu ini terus bertambah setiap harinya menjadi gudang data yang masih belum bermanfaat jika hanya disimpan saja. Penggalian pengetahuan dari gudang data tersebut dapat dilakukan dengan menggunakan salah satu teknik data mining artificial neural network yaitu *backpropagation* untuk memprediksi tpaw hari berikutnya. Data historis deret waktu tpaw ini disajikan dengan pendekatan konsep sliding window berdasarkan ukuran jendela yang digunakan yaitu 7, 14, 21 dan 28. Ukuran jendela tersebut merepresentasikan jumlah hari sebagai variabel lapisan input pada arsitektur jaringan *backpropagation* untuk memprediksi tpaw hari berikutnya. Beberapa pengujian jaringan *backpropagation* dilakukan dengan menggunakan kombinasi jumlah ukuran jendela terhadap perbandingan jumlah data latih dan data uji pada jaringan. Hasil prediksi yang diperoleh dengan nilai mean squared error (mse) terkecil pada pengujian jaringan ialah 0,000577 sebagai nilai akurasi hasil prediksi yang tinggi. Arsitektur jaringan dengan mse terkecil menggunakan 28 lapisan input, 10 lapisan tersembunyi dan 1 lapisan output dapat menjadi sebuah pengetahuan yang dapat membantu pihak PLTA sebagai alternatif pengambilan keputusan pengoperasian turbin berdasarkan hasil prediksi tinggi permukaan air waduk.

Kata kunci: artificial neural network, sliding window, backpropagation, arsitektur jaringan, mse.

1. Pendahuluan

Waduk Riam Kanan merupakan waduk terbesar yang terletak di kabupaten Banjar yang mempunyai peran sebagai irigasi dan sumber air Pembangkit Listrik Tenaga Air (PLTA) satu-satunya yang ada di Provinsi

Kalimantan Selatan. Tinggi permukaan air waduk merupakan salah satu faktor penting dalam proses operasional pemutar turbin (PLTA) [1] yang sangat mempengaruhi ketersediaan air di waduk (reservoir) [2]. Pengontrolan tinggi permukaan air waduk sangat

diperlukan untuk menghindari terjadinya luapan dan degradasi berlebihan yang dapat mempengaruhi kinerja dan hasil produksi energi listrik PLTA [3].

Pencatatan tinggi permukaan air waduk harian selama ini dilakukan dengan proses pengamatan langsung tinggi permukaan air waduk setiap hari yang terdapat pada papan tiang yang ada di waduk kemudian direkapitulasi setiap bulannya dalam bentuk excel. Data historis deret waktu harian tpaw yang terus bertambah setiap hari menjadi sebuah gudang data yang dapat digali menjadi sebuah pengetahuan baru dengan menggunakan salah satu teknik data mining artificial neural network yaitu backpropagation untuk memprediksi tpaw hari berikutnya. Hasil prediksi ini dapat menjadi pengetahuan bagi pihak PLTA sebagai alternatif dalam mengambil keputusan proses pengoperasian turbin.

Data historis deret waktu akan disajikan menggunakan konsep sliding window dengan melakukan segmentasi data tersebut [4] untuk memprediksi tinggi permukaan air waduk hari berikutnya yang direpresentasikan sebagai prediksi sementara terhadap nilai sebenarnya [5]. Proses penentuan segmentasi pertama berdasarkan ukuran jendela kemudian dilanjutkan ke segmentasi berikutnya dengan menggeser jendela 1 hari ke kanan sesuai ukuran jendela [6]. Proses ini dilakukan secara berulang sampai semua data deret waktu tersegmentasi (pola data).

Kinerja jaringan saraf tiruan (JST) dalam mengolah data menjadi informasi memiliki karakteristik yang hampir sama dengan jaringan saraf biologi [7]. Kemampuan JST memetakan sampel data input-output yang non linier tidak seperti model regresi statistik lainnya menjadikannya cukup populer dikalangan peneliti [8]. Pengembangan model prediksi teknik JST dilakukan pada preprocessing data baik itu penghalusan data, pengekstraksian atribut dan penyeleksian atribut dalam menentukan prediksi saham [9].

Backpropagation merupakan salah satu metode JST yang sering digunakan untuk prediksi data deret waktu yang proses kerja berulang pada setiap tahapan pelatihan untuk mendapatkan model yang terbaik [10]. Jaringan ini menggunakan parameter awal dalam melatih penelusuran jaringan multi lapisan untuk menentukan jaringan yang tepat dengan unit non linear [11]. Backpropagation mampu menganalisis dan memprediksi apa yang akan terjadi di masa depan berdasarkan pola data yang dipelajari [12]. Klasifikasi penyakit hipertensi dengan melakukan perbandingan metode klasifikasi Naïve Bayes, Decision Tree, dan backpropagation ternyata backpropagation memiliki nilai akurasi tertinggi [12].

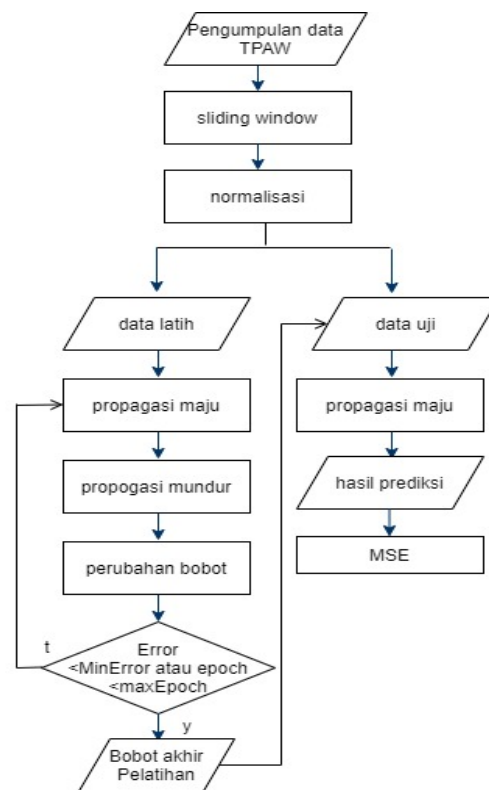
Arsitektur jaringan backpropagation terdiri dari beberapa unit lapisan, seperti unit input, unit tersembunyi dan unit output. Proses pembelajaran data deret waktu pada backpropagation dilakukan proses secara supervised dan berulang sehingga jaringan dapat

mengenal output yang diharapkan [13]. Hasil prediksi pengujian menggunakan MSE untuk menilai selisih output jaringan dengan target yang diharapkan [14]. Kombinasi arsitektur jaringan dan parameter dilakukan untuk membandingkan nilai mse yang paling kecil sebagai nilai akurasi yang tinggi [15].

Berdasarkan penelitian terdahulu maka peneliti akan melakukan prediksi tinggi permukaan air waduk hari berikutnya menggunakan pendekatan konsep *sliding window* untuk membentuk pola data sebagai variabel lapisan input, dan variabel target dengan menerapkan metode *backpropagation*. Kombinasi ukuran jendela terhadap perbandingan jumlah data latih dan data uji dilakukan untuk mendapatkan hasil prediksi yang tinggi dengan nilai mse yang paling kecil. Hasil prediksi yang tinggi dapat membantu pihak PLTA sebagai salah satu alternatif pengambilan keputusan pengoperasian turbin berdasarkan tinggi permukaan air waduk.

2. Metode Penelitian

Tahapan yang dilakukan dalam penelitian dapat dilihat pada Gambar 1.



Gambar 1. Tahapan prediksi tinggi permukaan air waduk


Data yang digunakan dalam penelitian ialah data harian tpaw PLTA P.M. Ir. Noor Kalimantan Selatan dari tahun 2010 sampai dengan tahun 2017 yang dapat dilihat pada tabel 1. Data historis deret waktu tpaw ini berjumlah 2922 hari yang akan dilakukan transformasi data dengan pendekatan konsep sliding window/jendela geser. Ukuran jendela yang digunakan ialah 7, 14, 21, dan 28

yang merepresentasikan data selama 1 minggu, 2 minggu, 3 minggu dan 4 minggu untuk memprediksi tpaw hari berikutnya. Setiap angka (1, 2, 3,2922) mewakili data harian deret waktu [8]. Pembentukan jumlah segmentasi data atau pola data deret waktu dipengaruhi oleh ukuran jendela.

Tabel 1. Data Historis Tpaw

Tanggal	Tpaw (m)
01/01/2010	55,625
02/01/2010	55,760
03/01/2010	55,840
04/01/2010	55,8600
.....
.....
.....
28/12/2017	56,630
29/12/2017	56,620
30/12/2017	56,600
31/12/2017	56,560

Gambar 2 merupakan proses konsep *sliding window* dengan ukuran jendela = 28. Setiap angka yang ada pada jendela mewakili masing-masing deret data waktu harian yaitu hari ke-1, 2, 3, 2922. Pola data ke- 1 dari jendela 1 sampai dengan 28 merepresentasikan bahwa data deret waktu selama 28 hari digunakan untuk prediksi tpaw hari berikutnya, kemudian jendela bergeser ke kanan satu hari untuk mencapai 28 hari berikutnya (2 sampai dengan 29) sebagai pola data ke-2 untuk prediksi tpaw hari berikutnya. Proses tersebut dilanjutkan untuk keseluruhan data historis yang telah dikumpulkan dan proses yang sama juga dilakukan untuk ukuran jendela 7, 14, dan 21. Banyaknya pola data yang terbentuk untuk setiap ukuran jendela tidak sama meskipun menggunakan data deret waktu yang sama.



Gambar 2. Tahapan Sliding Window

Tahap *sliding window* membentuk segmentasi data pola mingguan untuk memprediksi data hari berikutnya. Segmentasi pola data tersebut dilakukan normalisasi data sebagai salah satu teknik preprocessing data sehingga semua data memiliki nilai diantara skala 0 sampai 1 [8] dengan menggunakan persamaan 1.

$$x' = \frac{0,8*(x-x_{min})}{(x_{max} - x_{min})} + 0,1 \quad (1)$$

Dimana x' merupakan nilai x yang telah dinormalisasikan, sedangkan x merupakan nilai x yang akan dinormalisasikan, dengan mencari nilai x tertinggi dan x terendah dari data yang akan digunakan pada penelitian ini. Data akan dibagi menjadi data latih dan data uji dimana variabel yang akan digunakan ialah x_1

sampai dengan x_7 merupakan variabel input dan x_8 merupakan variabel target yang akan diprediksi.

Beberapa parameter awal yang ditentukan pada tahap pelatihan data latih yaitu nilai bobot dan bias pada setiap unit lapisan, epoch maksimum, *learning rate*, nilai faktor momentum, dan arsitektur jaringan. Arsitektur jaringan yang akan digunakan dapat dilihat pada tabel 2. Setelah parameter awal dan arsitektur jaringan ditentukan maka dilanjutkan ke proses pelatihan data latih. Pelatihan *backpropagation* terdiri dari tiga fase yaitu fase propagasi maju, propagasi mundur dan perubahan bobot yang dilakukan secara berulang hingga batas toleransi penghentian terpenuhi [7]. Model yang diperoleh pada tahap pelatihan akan diuji ke tahap pengujian dengan menggunakan data uji. Hasil output jaringan akan dievaluasi menggunakan MSE [8] persamaan 2 dimana n ialah banyak data, y_a merupakan Target Uji dan Y_0 output dari jaringan. Nilai mse yang terkecil dari kombinasi parameter dan arsitektur jaringan terhadap perbandingan data jumlah data latih dan data uji yang digunakan merupakan rekomendasi prediksi yang optimal.

$$MSE = \frac{\sum_{i=1}^n |y_a - y_0|^2}{n} \quad (2)$$

3. Hasil dan Pembahasan

Data deret waktu harian tinggi permukaan air waduk PLTA P.M. Ir. Noor selama tahun 8 tahun yang digunakan berjumlah 2922 hari yang dapat dilihat pada tabel 2.

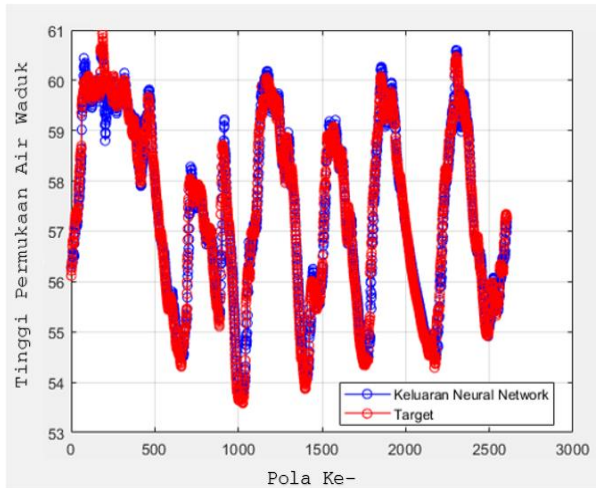
Tabel 2. Data Harian Tpaw

hari	Tpaw (m)
1	55,625
2	55,760
3	55,840
4	55,8600
.....
.....
.....
.....
.....
2919	56,630
2920	56,620
2921	56,600
2922	56,560

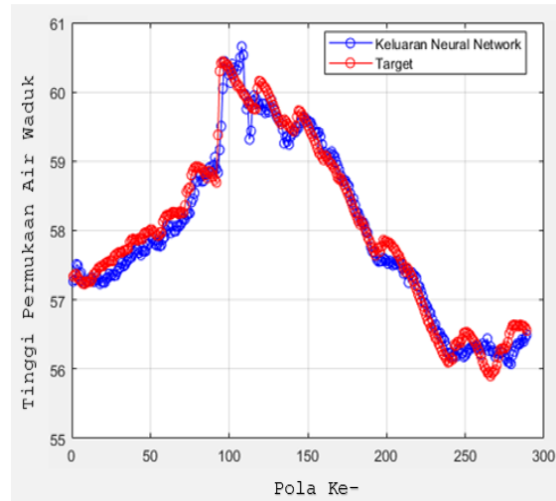
Setiap angka ukuran jendela direpresentasikan sebagai variabel x ($x_1, x_2, x_3, \dots, x_{28}$) untuk lapisan input yang digunakan untuk memprediksi tpaw hari berikutnya (x_{29}) yang dapat dilihat pada tabel 3.

Normalisasi data dilakukan untuk setiap nilai data tabel 3 sehingga nilai data memiliki skala antara 0 sampai 1 yang dapat dilihat pada tabel 4. Nilai terbesar dari keseluruhan data ialah 60,940 dan nilai terkecil 53,585 dengan memasukan nilai data x berdasarkan persamaan 1.

$$x' = \frac{0,8*(55,625-53,585)}{(60,940-53,585)} + 0,1 = 0,3222$$



Gambar 5. Grafik output jaringan vs pelatihan target data latih



Gambar 6. Grafik output jaringan vs pengujian target data uji

Bobot akhir dan model jaringan pelatihan data latih dapat digunakan untuk melakukan proses pengujian data uji. Pengujian hasil prediksi dihitung dengan menggunakan mse yaitu membandingkan selisih output jaringan dengan target data uji setiap kombinasi perbandingan data latih dan data uji terhadap jumlah ukuran jendela yang digunakan.

Nilai mse terkecil untuk setiap ukuran jendela yang digunakan dengan perbandingan jumlah data latih dan data uji diperoleh ketika menggunakan 70% data latih dan 30 % data uji dengan nilai mse 0,000737, 0,000703, 0,000647, 0,000621, dan 0,000621 sedangkan nilai mse terkecil untuk setiap perbandingan jumlah data latih dan data uji dengan setiap ukuran jendela diperoleh dengan menggunakan ukuran jendela= 28 dengan nilai mse 0,000577, 0,000670, dan 0,000621. Perbandingan nilai mse untuk setiap kombinasi dapat kita lihat pada tabel 7.


Tabel 7. Perbandingan Mse Pengujian Data Uji

Data Latih: data Uji (%)	MSE data Uji berdasarkan ukuran jendela			
	7	14	21	28
90 : 10	0,001116	0,000906	0,001082	0,000577
80 : 20	0,000898	0,000815	0,000725	0,000670
70 : 30	0,000737	0,000703	0,000647	0,000621

Gambar 6 menyajikan grafik perbandingan output jaringan dengan target data uji pada tahapan pengujian dengan nilai mse 0,000577.

Pengujian jaringan tersebut diperoleh koefisien korelasi sebesar 0,98563 yang dapat dilihat pada gambar 7.

Nilai mse terkecil dari keseluruhan pengujian yang dilakukan ialah 0,000577 dengan menggunakan arsitektur jaringan *backpropagation* 28-10-1, ukuran jendela =28 serta perbandingan 90% data latih dan 10% data uji.



Gambar 7. Grafik koefisien korelasi pengujian data uji

4. Kesimpulan

Penelitian ini dilakukan dengan menggunakan data historis deret waktu tinggi permukaan air waduk dengan pendekatan sliding window dimana ukuran jendela akan mewakili jumlah variabel lapisan input pada jaringan *backpropagation*. Ukuran jendela dan perbandingan data latih dan data uji sangat mempengaruhi hasil prediksi jaringan *backpropagation* dan nilai mse. Beberapa kombinasi ukuran jendela dengan perbandingan data yang digunakan diperoleh nilai mse terkecil yaitu 0,000577 sebagai nilai akurasi hasil prediksi yang tinggi dengan arsitektur jaringan 28 lapisan input, 10 lapisan tersembunyi dan 1 lapisan output dengan perbandingan 90% data latih dan 10% data uji. Model jaringan dengan nilai mse terkecil merupakan hasil prediksi yang tinggi dan diharapkan dapat membantu pihak PLTA sebagai salah satu alternatif pengambilan keputusan untuk pengoperasian turbin berdasarkan tinggi permukaan air waduk.

Daftar Rujukan

- [1] D. Kartini, H. Rusdiani, dan A. Farmadi, "Analisis Pengaruh Banyak Orde pada Metode Multivariate High-Order Fuzzy Time Series untuk Prediksi Duga Muka Air Waduk," *J. Edukasi dan Penelit. Inform.*, vol. 5, no. 1, hal. 9, 2019.
- [2] Winasis, H. Prasetyo, dan G. A. Setia, "Optimasi Operasi Pembangkit Listrik Tenaga Air (PLTA) Menggunakan Linear Programming Dengan Batasan Ketersediaan Air Optimization of Hydro Power Plant Operation Using Linear Programming With Constraint of Water Availability," *Din. Rekayasa*, vol. 9, no. 2, hal. 1–6, 2013.
- [3] A. Purnama, "Studi Kelayakan Pembangunan Pembangkit Listrik Tenaga Mikrohidro Studi Kasus: PLTMH Minggir Pada Saluran Irigasi Minggir Di Padukuhan Klagaran Desa Sendangrejo Kecamatan Minggir Kabupaten Sleman," *UNSA Prog.*, vol. 10, no. 15, hal. 93–111, 2011.
- [4] Y. Yu, Y. Zhu, S. Li, dan D. Wan, "Time series outlier detection based on sliding window prediction," *Math. Probl. Eng.*, vol. 2014, 2014, doi: 10.1155/2014/879736.
- [5] Y. BenYahmed, A. Abu Bakar, A. RazakHamdan, A. Ahmed, dan S. M. S. Abdullah, "Adaptive sliding window algorithm for weather data segmentation," *J. Theor. Appl. Inf. Technol.*, vol. 80, no. 2, hal. 322–333, 2015.
- [6] M. Vafaiepour, O. Rahbari, M. A. Rosen, F. Fazelpour, dan P. Ansarirad, "Application of sliding window technique for prediction of wind velocity time series," *Int. J. Energy Environ. Eng.*, vol. 5, no. 2–3, hal. 1–7, 2014, doi: 10.1007/s40095-014-0105-5.
- [7] J. J. Siang, *Jaringan Syaraf Tiruan Dan Pemrogramannya Dengan Matlab*. Yogyakarta: Andi, 2005.
- [8] H. S. Hota, R. Handa, dan A. K. Shrivastava, "Time Series Data Prediction Using Sliding Window Based RBF Neural Network," *Int. J. Comput. Intell. Res.*, vol. 13, no. 5, hal. 1145–1156, 2017, [Daring]. Tersedia pada: <http://www.ripublication.com>.
- [9] R. Handa, H. S. Hota, dan S. R. Tandan, "Stock Market Prediction with Various Technical," vol. 3, no. 1, hal. 604–608, 2015.
- [10] A. Mulyani, "Analisis Neural Network Struktur Backpropagation Sebagai Metode Peramalan Pada Perhitungan Tingkat Kemiskinan Di Indonesia," vol. XIII, no. 1, hal. 9–15, 2016.
- [11] M. Yanto, M. Liga, dan M. Hafizh, "Neural Network Backpropagation Identifikasi Pola Harga Saham Jakarta Islamic Index (JII)," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 4, no. 1, hal. 90–94, 2020.
- [12] N. Chamidah, M. M. Santoni, dan N. Matondang, "Pengaruh Oversampling pada Klasifikasi Hipertensi dengan Algoritma," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 4, no. 4, hal. 635–641, 2020.
- [13] I. M. D. U. Putra dan L. P. I. Gandhiadi, G. K. Harini, "Implementasi Backpropagation Neural Network Dalam Prakiraan Cuaca Di Daerah Bali Selatan," *E-Jurnal Mat.*, vol. 5, no. 4, hal. 126, 2016, doi: 10.24843/mtk.2016.v05.i04.p131.
- [14] S. Ibrahim, C. Choe Eam, dan A. El-Shafie, "Sensitivity analysis of artificial neural networks for just-suspension speed prediction in solid-liquid mixing systems: Performance comparison of MLPNN and RBFNN," *Adv. Eng. Informatics*, vol. 39, hal. 278–291, Jan 2019, doi: 10.1016/j.aei.2019.02.004.
- [15] S. P. Siregar dan A. Wanto, "Analysis of Artificial Neural Network Accuracy Using Backpropagation Algorithm In Predicting Process (Forecasting)," *IJISTECH (International J. Inf. Syst. Technol.)*, vol. 1, no. 1, hal. 34, 2017, doi: 10.30645/ijistech.v1i1.4.