

Prediksi Ketersediaan Air Embung Kolong Kebintik Sebagai Sumber Air Baku Menggunakan Jaringan Syaraf Tiruan

Prediction of Water Availability of Kebintik Reservoir as a Source of Raw Water Using Artificial Neural Networks

Adriyansyah¹, Saprizal²

¹Jurusan Teknik Sipil, Fakultas Sains dan Teknik, Universitas Bangka Belitung, Balunijuk, Kabupaten Bangka.

²Balai Wilayah Sungai Bangka Belitung, Direktorat Jenderal Sumber Daya Air, Kementerian PUPR.

Email : adriyan_ubb@yahoo.com

Abstrak

Jaringan syaraf tiruan merupakan salah satu metode *deep learning* yang proses kerjanya terinspirasi dari cara kerja otak manusia. Pada proses pelatihan, metode jaringan syaraf tiruan akan memperbaharui nilai bobot sehingga nilai bobot tersebut terlatih untuk mengetahui pola data. Sedangkan pada proses pengujian, jaringan syaraf tiruan melakukan prediksi data yang menjadi target dalam pengujian. Penelitian ini menggunakan data ketersediaan air Embung Kolong Kebintik dari bulan Januari 2009 hingga Desember 2022. Data tersebut kemudian dibagi menjadi 90% data pelatihan dan 10% data pengujian. Metode *feed-forward* yang digunakan pada proses pelatihan yaitu Levenberg Marquardt (LM) dan *Adaption learning function* menggunakan LearnGDM. Arsitektur jaringan yang digunakan yaitu arsitektur (12,144,1). Ketika dilakukan simulasi, diperlukan beberapa kali uji coba untuk mendapatkan arsitektur jaringan yang menghasilkan nilai MSE kecil. Hasil simulasi pada *epoch* 154 iterasi, menghasilkan nilai MSE = 0.0071 untuk pelatihan dan MSE = 0.010 untuk pengujian. Akan tetapi, jika dilihat dari hasil prediksi ketersediaan air Embung Kolong Kebintik dari bulan Januari 2023 hingga Desember 2026, maka hasil prediksi cenderung menghasilkan nilai yang sama untuk prediksi dalam rentang waktu yang panjang. Nilai MSE yang kecil pada proses pelatihan dan pengujian, tidak menjamin bahwa hasil prediksi akan menghasilkan prediksi yang baik.

Kata Kunci: Air baku; Jaringan syaraf tiruan; Ketersediaan air; Kolong kebintik

Abstract

An artificial neural network is a deep learning method whose work process is inspired by how the human brain works. In the training process, the neural network method will update the weight values so that the weight values are trained to find out data patterns. While in the testing process, the artificial neural network makes predictions on the test data that is the target of the test. The data used in this study is data on the availability of Kolong Kebintik from January 2009 to December 2022. The data is then divided into 90% training data and 10% testing data. The feed-forward method used in the training process is Levenberg Marquardt (LM), and the adaptation learning function uses LearnGDM. The network architecture used is (12,144,1). When simulating, several trials are required to obtain a network architecture that produces a small MSE value. In the simulation result at epoch 154 iterations, it was found that the value of MSE was 0.0071 for training and MSE was 0.010 for testing. However, if we look at the prediction results for the water availability of Embung Kolong Kebintik from January 2023 to December 2026, then the prediction results tend to produce the same values for predictions over a long period of time. A small MSE value in the training and testing process does not guarantee that the prediction results will produce good predictions.

Keywords: Raw water; Artificial neural networks; Water availability; Kolong kebintik

1. PENDAHULUAN

Pengelolaan sumber daya air merupakan kegiatan perencanaan, pelaksanaan, pengawasan, konservasi, dan pemanfaatan sumber daya air, serta pengendalian terhadap menurunnya kualitas air (UU SDA No.17, 2019). Pengelolaan sumber daya air harus dilakukan secara optimal sehingga mampu menjadi solusi dalam menghadapi tantangan berupa perubahan iklim yang terjadi secara global. Beberapa tantangan yang dihadapi pada pengelolaan sumber daya air yaitu kekeringan, pencemaran air, dampak pemanfaatan pola ruang terhadap ketersediaan air, keberlanjutan daya dukung sumber daya air, dan imbalan antara pasokan dan kebutuhan air.

Perubahan iklim yang sekarang ini menjadi isu global juga berdampak pada sumber daya air yang tersedia di alam. Perubahan iklim yang mempengaruhi suhu udara dan curah hujan mempunyai pengaruh terhadap siklus hidrologi dan ketersediaan air. Dampak perubahan iklim terhadap sumber daya air yaitu meningkatkan intensitas curah hujan pada musim basah sehingga menyebabkan banjir (Wasko and Nathan, 2019; Tabari, 2020; Wasko *et al.*, 2021). Perubahan iklim juga berdampak pada peningkatan temperatur suhu yang ekstrim sehingga menyebabkan lamanya musim kering (Alizadeh-Choobari and Najafi, 2018; Fraga *et al.*, 2021). Hal ini menyebabkan kecilnya intensitas curah hujan yang berakibat keringnya sumber air seperti embung dan sungai. Perubahan iklim yang menyebabkan kekeringan dan banjir akan mengakibatkan krisis air bersih.

Usaha yang dapat dilakukan untuk mitigasi dari dampak perubahan iklim adalah melakukan inventarisasi sumber air yang mempunyai potensi ketersediaan dan keberlanjutan sumber air tersebut. Salah satu bentuk inventarisasi sumber air yaitu dengan melakukan prediksi ketersediaan sumber air baku. Prediksi ketersediaan air merupakan acuan untuk mengetahui debit air yang tersedia pada suatu sumber air. Jika ketersediaan air pada sumber air baku diketahui maka air tersebut dapat dikelola secara optimal (Shiklomanov, 2000; Gorelick and Zheng, 2015; Sulaiman *et al.*, 2019). Sumber daya air yang dapat dimanfaatkan seperti sungai, danau, air tanah, waduk, akuifer, dan lain-lain (Qadir *et al.*,

2007; Wisser *et al.*, 2010; Hassanzadeh, Zarghami and Hassanzadeh, 2012).

Bidang hidrologi mempunyai hubungan yang kuat terhadap prediksi suatu data. Hidrologi di bidang teknik sipil cenderung bermain pada ruang lingkup data primer dan data sekunder sebagai data pendukung. Beberapa metode yang umumnya digunakan dalam memprediksi data hidrologi yaitu Holt-Winter's, *exponential smoothing*, dan ARIMA (Hong, 2011; Puaah *et al.*, 2016; Yang *et al.*, 2017; Katimon, Shahid and Mohsenipour, 2018). Selain itu metode rantai Markov dan Monte Carlo juga sering diterapkan dalam permalan data hidrologi (Smith and Marshall, 2008; Hassan, Bekhit and Chapman, 2009; Schoups *et al.*, 2010). Baru-baru ini prediksi data hidrologi yang awalnya menggunakan metode konvensional beralih menggunakan metode kecerdasan buatan. Metode kecerdasan buatan yang digunakan untuk meramalkan data antara lain *adaptive neural-based fuzzy inference system* (ANFIS), *genetic programming* (GP), *support vector machine* (SVM), dan *artificial neural network* (ANN) (Wang *et al.*, 2009; Buyukyildiz, Tezel and Yilmaz, 2014; Meshram *et al.*, 2022).

Jaringan syaraf tiruan merupakan algoritma *deep learning* yang proses kerjanya terinspirasi dari cara kerja otak manusia ('Building brain-inspired computing', 2019; Mehonic *et al.*, 2020; Zebari *et al.*, 2021; Schmidgall *et al.*, 2023). Jaringan syaraf tiruan merupakan teknik yang dapat memodelkan, memetakan dan menunjukkan hubungan nonlinear dari permasalahan kompleks. Jaringan syaraf tiruan memiliki kemampuan mengenali pola tertentu dengan menggunakan algoritma pembelajaran dan pelatihan (Kim, 2010; Reddy, 2013; Yu *et al.*, 2014). Proses pelatihan jaringan syaraf tiruan *backpropagation* terdiri dari tiga fase yaitu fase maju, fase mundur, dan fase perubahan bobot. Algoritma *backpropagation* menggunakan perambatan maju untuk mendapatkan nilai *error* dari suatu prediksi. Kemudian nilai *error* tersebut digunakan untuk *update* nilai bobot pada arah mundur.

Penelitian ini bertujuan untuk mengetahui kinerja metode jaringan syaraf tiruan dalam memprediksi ketersediaan air sumber air baku yaitu

Embung Kolong Kebintik di Kabupaten Bangka Tengah. Kinerja metode jaringan syaraf tiruan dilihat dari nilai MSE yang dihasilkan pada proses pelatihan dan pengujian. Penelitian ini juga akan melihat pengaruh nilai MSE pada proses pelatihan dan pengujian terhadap hasil prediksi yang dihasilkan. Input data yang digunakan yaitu data debit air Embung Kolong Kebintik bulan Januari 2009 hingga Desember 2022. Data tersebut akan digunakan untuk memprediksi debit ketersediaan air selama empat tahun kedepan yaitu Januari 2023 hingga Desember 2026.

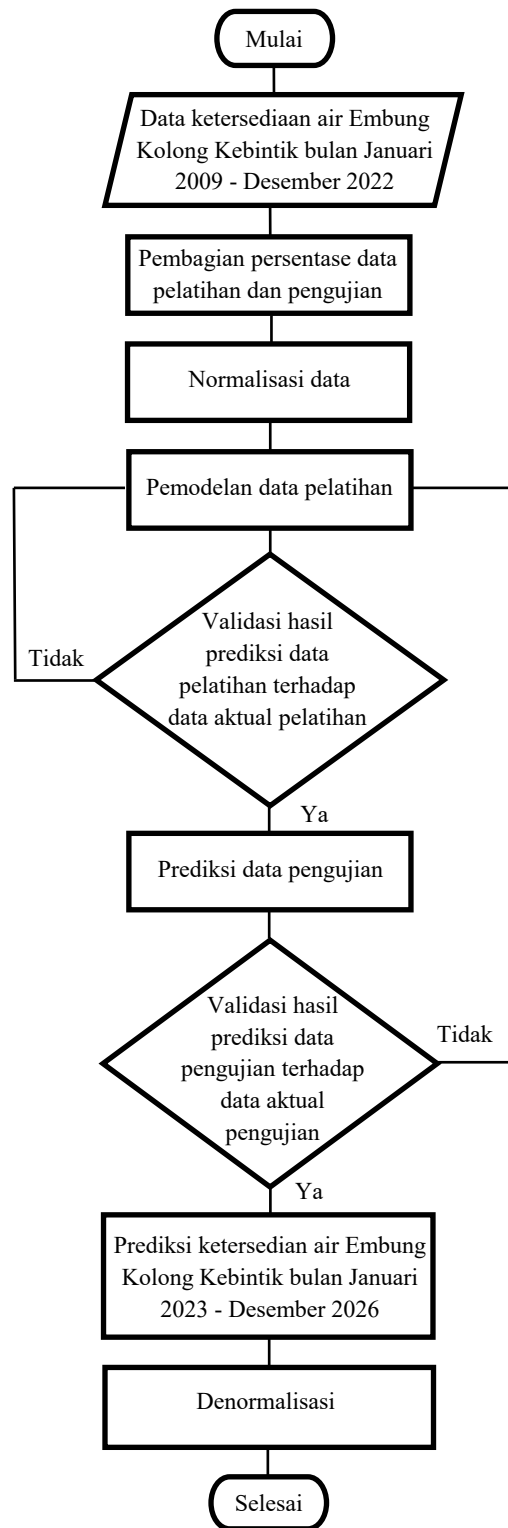
2. METODE PENELITIAN

2.1 Data Penelitian


Penelitian ini menggunakan data ketersediaan air Embung Kolong Kebintik di Kabupaten Bangka Tengah dari bulan Januari 2009 hingga Desember 2022 (Sabri and Adriyansyah, 2020). Penelitian sebelumnya menggunakan metode rantai markov dalam memprediksi ketersediaan air Embung Kolong Kebintik. Penelitian saat ini akan menggunakan metode jaringan syaraf tiruan untuk memprediksi ketersediaan air Embung Kolong Kebintik dari bulan Januari 2023 hingga Desember 2026. Diagram alir penelitian ditampilkan pada Gambar 1.

2.2 Jaringan Syaraf Tiruan

Jaringan syaraf tiruan dibedakan menjadi dua yaitu *single layer* dan *multi-layer*. *Single layer* hanya mempunyai satu lapisan bobot atau tidak memiliki *hidden layer*. Sedangkan *multilayer* mempunyai *hidden layer* yang terletak diantara *input layer* dan *output layer*. *Hidden layer* akan menjadi *input* bagi lapisan berikutnya yang dihubungkan oleh pembobotan (*weight*). Jaringan syaraf tiruan memproses informasi dengan dua tahap yaitu tahap pelatihan dan tahap pengujian. Proses pelatihan dimulai dengan memasukkan data pelatihan kedalam jaringan. Pola data pelatihan akan mengupdate nilai bobot untuk mendapatkan nilai bobot terbaik. Kemudian bobot pada pelatihan digunakan kembali untuk memprediksi pola data pengujian. Arsitektur jaringan syaraf tiruan dapat dilihat pada Gambar 2 .



Gambar 1. Diagram Alir Prediksi Ketersediaan Air Embung Kolong Kebintik



Gambar 2. Arsitektur Jaringan Syaraf Tiruan (Abraham, 2005)

2.3 Input Data

Penelitian ini menggunakan data ketersediaan air Embung Kolong Kebintik dimulai dari Januari 2009 hingga Desember 2022. Data tersebut kemudian dibagi menjadi 90% data pelatihan dan 10% data pengujian.

2.4 Arsitektur Jaringan

Arsitektur pada jaringan syaraf tiruan terdiri dari *input layer*, *hidden layer*, dan *output layer*. Penelitian ini menggunakan Arsitektur (12,144,1) yaitu *input layer* = 12, *hidden layer* = 144 dan *output layer* = 1.

2.5 Arsitektur Jaringan

Normalisasi data merupakan suatu proses merubah data aktual kedalam suatu rentang tertentu. Besaran rentang pada normalisasi data tergantung dengan fungsi aktivasi yang digunakan. Jika fungsi aktivasi yang digunakan adalah fungsi sigmoid biner maka data memiliki rentang (0,1). Sedangkan jika menggunakan fungsi sigmoid bipolar maka data memiliki rentang (-1,1). Normalisasi data dilakukan dengan persamaan berikut ini:

$$x' = \frac{0.8(x - a)}{b - a} + 0.1 \quad (1)$$

dengan x' merupakan data yang ditransformasi, x merupakan data aktual, a merupakan data minimum, dan b merupakan data maksimum.

2.6 Proses Pelatihan dan Pengujian

Proses pelatihan merupakan proses jaringan syaraf tiruan melakukan pembelajaran terhadap pola data. Pola suatu data dipelajari oleh jaringan syaraf tiruan menggunakan nilai bobot yang di *update*. Untuk mendapatkan bobot yang tepat, jaringan syaraf tiruan menggunakan perambatan maju dan

perambatan mundur. Proses pelatihan memerlukan perhitungan berulang-ulang sampai mendapatkan *output* yang mempunyai *error* kecil terhadap target yang diinginkan. Terdapat beberapa model *backpropagation* yang dapat digunakan untuk pelatihan yaitu *Scaled Conjugate Gradient* (*traincsg*), *Fletcher-Reeves Update* (*traincgrf*), *Polak-Ribie're* (*traincgp*), *Powel-Beale Restars* (*traincgb*), *Broyden Fletcher Goldfarb Shanno* (*trainbfg*), *One Step Secant* (*trainoss*), *Gradient Descent with Adaptive Learning Rate* (*trainгда*), *Gradien Descent with Momentum and Adaptive Learning Rate* (*trainгдаx*), *Resilent Backpropagation* (*trainrp*), dan *Levenberg-Marquardt* (*trainlm*).

Proses pelatihan pada penelitian ini menggunakan metode Lavenberg-Marquardt (LM). Metode LM dipilih karena cepat dalam mencapai target sehingga jumlah iterasi sedikit dan menghasilkan *output* dengan *error* kecil. Hal yang dilakukan pada proses pengujian yaitu melakukan prediksi terhadap target pengujian. Tahap pengujian pada metode *backpropagation* hanya melakukan proses perambatan maju.

2.7 Fungsi Aktivasi

Terdapat beberapa jenis fungsi aktivasi yang dapat digunakan pada jaringan syaraf tiruan yaitu fungsi identitas, fungsi biner dengan *threshold* 0, fungsi biner sigmoid, fungsi bipolar sigmoid, regresi linear, regresi logistik, tangen hiperbolik, hiperbolik sigmoid, dan ReLu. Dalam penelitian ini fungsi aktivasi yang digunakan yaitu fungsi tangen sigmoid (*tansig*). Fungsi *tansig* merupakan fungsi yang mempunyai rentang (-1,1). Jika data memiliki rentang yang lebih besar dari 1 maka data tersebut harus ditransformasi agar memiliki rentang yang sama dengan fungsi aktivasi yang digunakan. Fungsi *tansig* dirumuskan sebagai berikut:

$$f(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (2)$$

2.8 Evaluasi Kinerja Model

Evaluasi kinerja model merupakan pengujian tingkat akurasi antara hasil prediksi terhadap data aktual. Evaluasi kinerja merupakan ukuran bahwa penentuan jumlah *hidden layer* pada arsitektur jaringan sudah baik atau tidak. Penentuan jumlah *hidden layer* akan berpengaruh pada nilai bobot

dalam mempelajari pola suatu data. Akurasi terbaik mempunyai *error* yang paling kecil atau nilai *error* mendekati 0. Hasil kinerja dari simulasi jaringan syaraf tiruan akan di evaluasi menggunakan *mean squared error* (MSE). MSE dihitung menggunakan persamaan berikut :

$$MSE = \frac{1}{N} \sum_{n=1}^N (y_n - \hat{y}_n)^2 \quad (3)$$

dengan N merupakan Jumlah sampel data, y_n merupakan nilai data sebenarnya untuk data ke- n , dan \hat{y}_n merupakan nilai prediksi untuk data ke- n .

2.9 Denormalisasi Data

Denormalisasi merupakan proses mengembalikan data yang telah di normalisasi ke bentuk awal. Denormalisasi dilakukan menggunakan persamaan berikut :


$$x = \frac{(x' - 0.1)(b - a)}{0.8} + a \quad (4)$$

3. HASIL DAN PEMBAHASAN

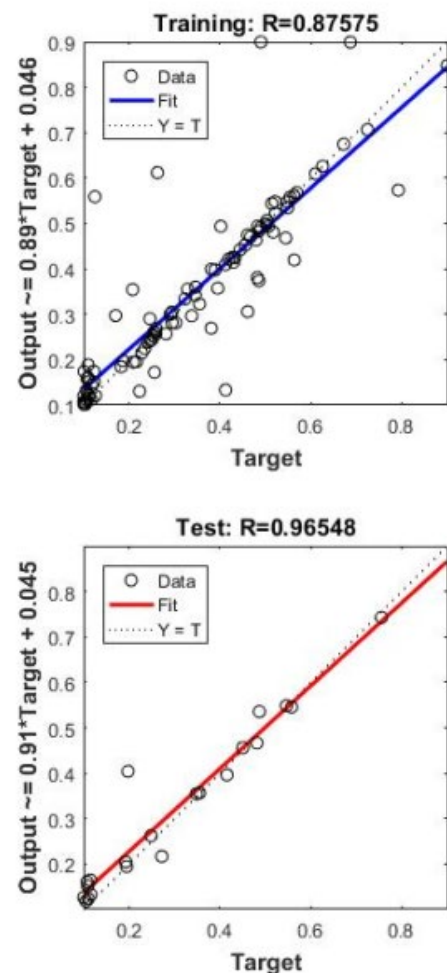
Prediksi ketersediaan air Embung Kolong Kebintik disimulasikan menggunakan nntool yang terdapat dalam MATLAB dengan meninjau *fitting* data. Metode *feed forward* yang digunakan pada proses pelatihan yaitu menggunakan Levenberg Marquardt (LM) dan *Adaption learning function* menggunakan LearnGDM. Simulasi dilakukan dengan jumlah maksimum *epoch* sebanyak 200 iterasi dengan parameter *learning rate* (lr) = 0.01



Gambar 3 menunjukkan evaluasi kinerja jaringan syaraf tiruan menggunakan 144 neuron *hidden layer*. Hasil validasi kinerja pada *epoch* 154 iterasi menunjukkan bahwa MSE = 0.0071 untuk pelatihan dan MSE = 0.010 untuk pengujian. Hasil tersebut menunjukkan bahwa kinerja jaringan syaraf tiruan menggunakan 144 neuron *hidden layer* memiliki akurasi yang baik karena nilai MSE mendekati 0.

Gambar 4 menunjukkan regresi dengan menggunakan 144 neuron *hidden layer*. Hasil analisis regresi menghasilkan nilai $R = 0.89416$. Hal ini menunjukkan bahwa hasil data prediksi terhadap data target memiliki keakuratan yang tinggi.




Gambar 3. Validasi Kinerja Menggunakan 144 Neuron *Hidden Layer*

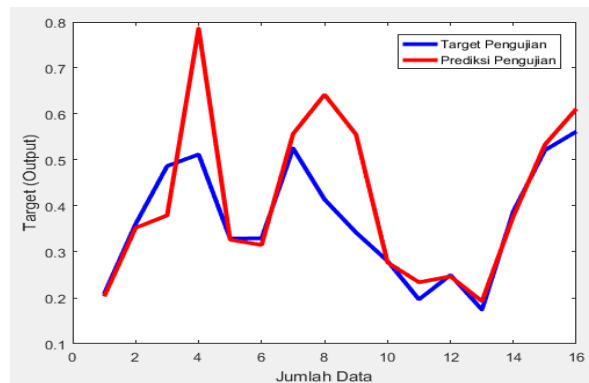




Gambar 4. Hasil Regresi Menggunakan 144 Neuron *Hidden Layer*



Gambar 5. Perbandingan Prediksi Pelatihan dan Target Pelatihan




Gambar 6. Perbandingan Prediksi Pengujian dan Target Pengujian

Setelah melakukan simulasi pelatihan dan pengujian, proses berikutnya yaitu melakukan prediksi data tiga tahun yang akan datang. Prediksi data dilakukan dengan cara membuat *syntax* di *command window* di MATLAB dengan *syntax* Prediksi = sim(net,input). Hasil prediksi data menggunakan *syntax* sim(net,input) kemudian dilakukan denormalisasi agar data kembali dalam bentuk data asli. Hasil prediksi ketersediaan air Embung Kolong Kebintik selama empat tahun kedepan yang telah dilakukan denormalisasi ditampilkan pada Tabel 1.

Tabel 1. Hasil Prediksi Ketersediaan Air Embung Kolong Kebintik Bulan Januari 2023 - Desember 2026

| Bulan | Debit (l/s) | | | |
|-----------|-------------|--------|--------|--------|
| | 2023 | 2024 | 2025 | 2026 |
| Januari | 115.12 | 67.56 | 120.30 | 419.31 |
| Februari | 150.19 | 61.41 | 66.34 | 434.49 |
| Maret | 293.85 | 110.19 | 57.65 | 438.55 |
| April | 329.5 | 194.87 | 122.40 | 434.84 |
| Mei | 193.94 | 327.35 | 322.47 | 435.86 |
| Juni | 185.83 | 371.79 | 406.90 | 423.21 |
| Juli | 186.47 | 175.48 | 184.56 | 439.04 |
| Agustus | 288.24 | 176.70 | 178.85 | 439.18 |
| September | 189.89 | 107.60 | 244.78 | 439.67 |
| Oktober | 116.1 | 133.39 | 144.67 | 439.13 |
| November | 77.18 | 127.43 | 206.30 | 439.67 |
| Desember | 58.13 | 173.14 | 233.06 | 439.48 |



Gambar 7. Grafik Hasil Prediksi Ketersediaan Air Embung Kolong Kebintik Bulan Januari 2023 – Desember 2026

4. KESIMPULAN

Berdasarkan hasil simulasi dapat disimpulkan bahwa metode jaringan syaraf tiruan mampu memprediksi ketersediaan air Embung Kolong Kebintik dan memiliki nilai MSE yang kecil. Ketika simulasi diperlukan beberapa kali uji coba untuk mendapatkan arsitektur jaringan syaraf tiruan agar mendapatkan nilai MSE yang kecil. Hasil analisis pada *epoch* 154 iterasi menghasilkan nilai MSE = 0.0071 untuk pelatihan dan MSE = 0.010 untuk pengujian. Akan tetapi jika dilihat dari hasil prediksi ketersediaan air Kolong Kebintik dari bulan Januari 2023 hingga Desember 2026, maka hasil prediksi cenderung menghasilkan nilai yang sama untuk prediksi dalam rentang waktu yang panjang. Nilai MSE yang kecil pada proses pelatihan dan pengujian, tidak menjamin bahwa hasil prediksi akan menghasilkan prediksi yang baik.

REFERENSI

- Abraham, A. 2005. "Artificial Neural Networks", in Handbook of Measuring System Design. Wiley.
<https://doi.org/10.1002/0471497398.mm421>.
- Alizadeh, C.O. and Najafi, M.S. 2018. Extreme weather events in Iran under a changing climate, *Climate Dynamics*, 50(1–2), pp.249–260.
<https://doi.org/10.1007/s00382-017-3602-4>.

- Strukov, D., Indiveri, G., Grollier, J. and Fusi, S. 2019 Building brain-inspired computing, *Nature Communications. Nature Research*.
<https://doi.org/10.1038/s41467-019-12521-x>.
- Buyukyildiz, M., Tezel, G. and Yilmaz, V. 2014 Estimation of the Change in Lake Water Level by Artificial Intelligence Methods, *Water Resources Management*, 28(13), pp.4747–4763.
<https://doi.org/10.1007/s11269-014-0773-1>.
- Fraga, H. *et al.* (2021) Mediterranean olive orchards under climate change: A review of future impacts and adaptation strategies, *Agronomy*. MDPI AG.
<https://doi.org/10.3390/agronomy11010056>.
- Gorelick, S.M. and Zheng, C. 2015 Global change and the groundwater management challenge, *Water Resources Research*, pp. 3031–3051.
<https://doi.org/10.1002/2014WR016825>.
- Hassan, A.E., Bekhit, H.M. and Chapman, J.B. 2009. Using Markov Chain Monte Carlo to quantify parameter uncertainty and its effect on predictions of a groundwater flow model, *Environmental Modelling and Software*, 24(6), pp. 749–763.
<https://doi.org/10.1016/j.envsoft.2008.11.002>.
- Hassanzadeh, E., Zarghami, M. and Hassanzadeh, Y. 2012. Determining the Main Factors in Declining the Urmia Lake Level by Using System Dynamics Modeling, *Water Resources Management*, 26(1), pp. 129–145.
<https://doi.org/10.1007/s11269-011-9909-8>.
- Katimon, A., Shahid, S. And Mohsenipour, M. 2018. Modeling water quality and hydrological variables using ARIMA: a case study of Johor River, Malaysia, *Sustainable Water Resources Management*, 4(4), pp. 991–998.
<https://doi.org/10.1007/s40899-017-0202-8>.
- Undang- Undang Republik Indonesia Nomor 17 .2019. Tentang Sumber Daya Air.
- Mehonic, A. *et al.* 2020 .Memristors—From In-Memory Computing, Deep Learning Acceleration, and Spiking Neural Networks to the Future of Neuromorphic and

- Bio-Inspired Computing, *Advanced Intelligent Systems*, 2(11).
<https://doi.org/10.1002/aisy.202000085>.
- Meshram, S.G. *et al.* 2022. Streamflow Prediction Based on Artificial Intelligence Techniques”, *Iranian Journal of Science and Technology - Transactions of Civil Engineering*,46(3), pp.2393-2403.
<https://doi.org/10.1007/s40996-021-00696-7>.
- Puah, Y.J. *et al.* 2016. River catchment rainfall series analysis using additive holt–Winters method, *Journal of Earth System Science*, 125(2), pp. 269–283.
<https://doi.org/10.1007/s12040-016-0661-6>.
- Reddy, E.K. 2013. Neural networks for intrusion detection and its applications, in *Proceedings of the World Congress on Engineering*, pp. 3–5.
- Rosytha, A., & Cristiyana, A. 2022. Perencanaan Sistem Distribusi Air Bersih Kecamatan Maduran Kabupaten Lamongan. *Publikasi Riset Orientasi Teknik Sipil (Proteksi)*, 4(1), 48-58.
- Sabri, F. and Adriyansyah .2020. Reliability analysis of the Kolong Kebintik as water resources for special economic zone in Tanjung Gunung, Pangkalan Baru District, Central Bangka Regency, in *IOP Conference Series: Earth and Environmental Science*. IOP Publishing Ltd.
<https://doi.org/10.1088/1755-1315/599/1/012045>.
- Schoups, G. *et al.* 2010. Corruption of accuracy and efficiency of Markov chain Monte Carlo simulation by inaccurate numerical implementation of conceptual hydrologic models, *Water Resources Research*,46(10).
<http://doi.org/10.1029/2009WR008648>.
- Sulaiman, S.O. *et al.* 2019. Water resources management and sustainability over the Western desert of Iraq, *Environmental Earth Sciences*, 78(16).
<https://doi.org/10.1007/s12665-019-8510-y>.
- Tabari, H. 2020. Climate change impact on flood and extreme precipitation increases with water availability, *Scientific Reports*, 10(1).
<https://doi.org/10.1038/s41598-020-70816-2>.
- Wasko, C. *et al.* 2021. Evidence of shorter more extreme rainfalls and increased flood variability under climate change, *Journal of Hydrology*, 603, p. 126994.
- Wasko, C. and Nathan, R. 2019. Influence of changes in rainfall and soil moisture on trends in flooding, *Journal of Hydrology*, 575, pp. 432–441.
<https://doi.org/10.1016/j.jhydrol.2019.05.054>.
- Wisser, D. *et al.* 2010. The significance of local water resources captured in small reservoirs for crop production - A global-scale analysis, *Journal of Hydrology*, 384(3–4), pp. 264–275.
<https://doi.org/10.1016/j.jhydrol.2009.07.032>.
- Yang, Q. *et al.* 2017. A comparative study of shallow groundwater level simulation with three time series models in a coastal aquifer of South China, *Applied Water Science*, 7(2), pp. 689–698.
<https://doi.org/10.1007/s13201-015-0282-2>.
- Yu, Q. *et al.* 2014. A brain-inspired spiking neural network model with temporal encoding and learning, *Neurocomputing*, 138, pp. 3–13.
<https://doi.org/10.1016/j.neucom.2013.06.052>
- Zebari, R.R. *et al.* 2021. A Review on Automation Artificial Neural Networks based on Evolutionary Algorithms, in *2021 14th International Conference on Developments in eSystems Engineering (DeSE)*. IEEE, pp. 235–240.