

PENERAPAN ALGORITMA *MULTILAYER PERCEPTRON* (MLP) UNTUK MEMREDIKSI DEBIT DI SUNGAI CITARUM BAGIAN HULU (POS PENGUKURAN MAJALAYA), KAB.BANDUNG, JAWA BARAT

Enung*, Heri Kasyanto, Risna Rismiana Sari

Jurusan Teknik Sipil, Politeknik Negeri Bandung, Bandung 40012

*E-mail penulis, korespondensi: enung@polban.ac.id

ABSTRAK

Banjir merupakan salah satu bencana hidrometeorologi yang paling sering terjadi di Indonesia, salah satunya di daerah Majalaya. Banjir Majalaya diakibatkan oleh luapan sungai Citarum. Pengendalian banjir dengan pendekatan non struktural melalui pengembangan sistem peringatan dini banjir menjadi penting untuk mengurangi dampak risiko banjir. Prediksi debit sebagai salah satu komponen dalam peringatan dini memerlukan analisis yang akurat, sederhana, cepat dan menggunakan sumber daya yang seminimal mungkin. Dalam penelitian ini metode Jaringan Syaraf Tiruan (JST) dengan menggunakan algoritma Multilayer Perceptron (MLP) dikembangkan untuk memprediksi debit di pos duga air Majalaya. Input data yang digunakan yaitu berupa data hujan jam-jam an dari 4 (empat) stasiun hujan yang berpengaruh dan data debit di lokasi yang ditinjau. Tiga skenario struktur model dikembangkan berdasarkan jumlah *hidden layer* dan *neuron*. Evaluasi model dilakukan dengan pengukuran statistik RMSE, R^2 dan NSE. Hasil penelitian menunjukkan bahwa model MLP dengan 1 *hidden layer* yang dikembangkan cukup baik dalam memprediksi debit satu jam mendatang di pos duga air Majalaya, meskipun masih terdapat kesenjangan nilai debit maksimum hasil prediksi. Debit hasil prediksi cenderung *underestimate* dibandingkan debit aktual.

Kata Kunci: *Multilayer Perceptron* (MLP), Prediksi Debit, Majalaya, Jaringan Syaraf Tiruan (JST).

ABSTRACT

Flood is one of the most frequent hydrometeorological disasters in Indonesia, one of which is in the Majalaya area. The Majalaya flood was caused by the overflow of the Citarum River. Flood control with a non-structural approach through the development of a flood early warning system is important to reduce the impact of flood risk. Discharge prediction as one of the components in early warning requires an analysis that is accurate, simple, fast, and uses minimal resources. In this study, the Artificial Neural Network (ANN) method using the Multilayer Perceptron (MLP) algorithm was developed to predict the discharge at the Majalaya water station. The input data used is in the form of hourly rainfall data from four influential rain gauge stations and discharge data at the location being reviewed. Three scenarios of the model structure were developed based on the number of hidden layers and neurons. Model evaluation was carried out by statistical measurements of RMSE, R^2 , and NSE. The results showed that the MLP model with 1 hidden layer that was developed was quite good at predicting the flow of the next hour at the Majalaya water level gauge, although there was still a gap in the maximum discharge value in the prediction results. The predicted discharge tends to underestimate compared to the actual debit.

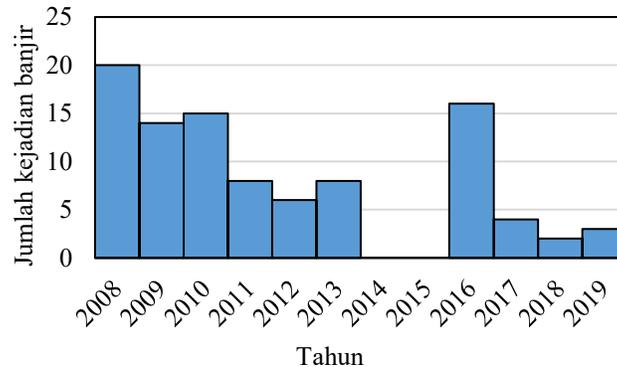
Keywords: *Multilayer Perceptron* (MLP), Discharge Prediction, Majalaya, Artificial Neural Network (ANN)

1. PENDAHULUAN

Majalaya merupakan salah satu lokasi titik banjir di aliran sungai Citarum yang sering terjadi. banjir di Majalaya hampir terjadi setiap tahun sejak tahun 2008, dan banjir terjadi beberapa kali dalam setiap tahunnya, data kejadian banjir tahun 2008 sampai dengan 2019 seperti pada Gambar 1 [1]. Banjir yang terjadi di Majalaya diakibatkan oleh luapan sungai Citarum dan buruknya sistem saluran drainase yang ada. Desa Majalaya yang berada di daerah hulu sungai Citarum memiliki kontur topografi yang cenderung curam sehingga karakteristik banjir yang terjadi di daerah Majalaya cenderung terjadi secara tiba-tiba dan dalam waktu yang singkat (banjir bandang). Banjir dengan karakteristik seperti ini lebih berisiko dikarenakan masyarakat di daerah tersebut tidak memiliki waktu yang cukup untuk menyelamatkan diri dan harta bendanya. Selain itu, banjir yang terjadi di Majalaya dapat menjadi pemicu terjadinya banjir di bagian hilirnya, dalam hal ini banjir di sektor tengah (Kec.Bojongsoang dan Dayeuh kolot).

Penanganan banjir di Majalaya sudah dilakukan secara struktural maupun non struktural oleh pemerintah. Penanganan banjir secara struktural dilakukan dengan normalisasi sungai Citarum melalui pengerukan dan juga perbaikan saluran drainase. Sedangkan upaya

non struktural dilakukan melalui penataan kawasan hulu Citarum dengan melakukan reboisasi, mengatur regulasi tata guna lahan, dan pengembangan sistem informasi peringatan dini banjir. Komponen sistem peringatan dini meliputi tahapan *detection* dan *monitoring*, *forecasting* dan *simulation*, *warning*, dan *response* [2]. Pada tahap *detection* dilakukan upaya untuk dapat mengakses berbagai data yang akan digunakan pada tahap peramalan (*forecasting*) dan simulasi .



Gambar 1 Data kejadian banjir di Majalaya tahun 2008-2019 [1] (diolah)

Peramalan banjir atau prediksi debit merupakan salah satu proses dalam analisis hidrologi yang sangat penting. Prediksi debit yang akurat menjadi hal yang penting terutama sebagai acuan dalam peringatan dini banjir, dan merupakan tantangan karena analisis debit banjir merupakan proses yang dinamis dengan fluktuasi spasial dan temporal. Aliran sungai juga pada umumnya bersifat nonlinier dan dipengaruhi oleh beberapa faktor antara lain karakteristik DAS, curah hujan, topografi dasar sungai dan kondisi iklim [3].

Pendekatan peramalan banjir diklasifikasikan berdasarkan pendekatan berbasis fisik dan berbasis data. Model berbasis fisik yang kompleks membutuhkan banyak parameter yang berkaitan dengan karakteristik DAS. Membuat model yang rumit membutuhkan pengetahuan khusus dan memakan waktu, sehingga membatasi penggunaannya dalam sistem peringatan banjir. Model berbasis data hanya bergantung pada data historis dari variabel sumber daya banjir yang relevan, seperti data hujan, debit, iklim, dan volume limpasan. Jenis pemodelan ini berusaha untuk membangun model matematis yang mengikat faktor *input* ke variabel *output* yang dapat digunakan untuk memperkirakan luas banjir [4]. Model Jaringan Syaraf Tiruan (JST) adalah salah satu pendekatan berbasis data yang populer. Model jaringan syaraf tiruan (JST) adalah sistem pemrosesan informasi yang meniru struktur dan fungsi otak manusia. Ini dapat mensimulasikan sistem non-linier dan rumit tanpa penjelasan fisik tertentu [5].

Penggunaan model JST khususnya metode MLP sudah banyak diaplikasikan dalam bidang sumber daya air khususnya hidrologi, seperti untuk memodelkan hujan limpasan [6–8], untuk memprediksi elevasi muka air dan debit sungai [9–11], dan juga sudah banyak diaplikasikan dalam bidang hidrologi lainnya. Tujuan dari penelitian ini yaitu untuk mengembangkan model prediksi debit aliran sungai Citarum bagian hulu khususnya di pos duga air Majalaya. Dengan dikembangkannya metode ini, dapat menjadi alternatif dalam memprediksi aliran dengan lebih cepat dan akurat sehingga dapat dimanfaatkan untuk peringatan dini banjir.

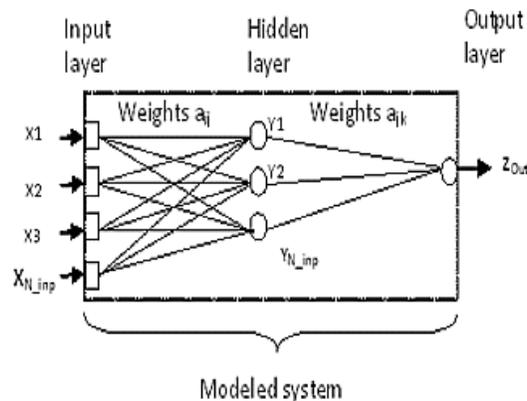
2. METODOLOGI

2.1 Multilayer Perceptron (MLP)

MLP adalah salah satu arsitektur JST yang paling populer digunakan untuk pemodelan hidrologi. Rumelhart dkk. dianggap sebagai yang pertama memperkenalkan MLP dengan algoritma *training back propagation* [6]. Jaringan multilayer biasanya menggunakan fungsi aktivasi sigmoid di lapisan tersembunyi. Fungsi-fungsi ini sering disebut fungsi "*squashing*", karena memampatkan rentang input tak terbatas menjadi rentang output terbatas. Fungsi sigmoid dicirikan sedemikian rupa sehingga kemiringannya harus mendekati nol saat input menjadi besar. Hal ini menyebabkan masalah saat menggunakan penurunan paling curam untuk melatih jaringan multilayer dengan fungsi sigmoid, karena gradien dapat memiliki magnitudo yang sangat kecil dan oleh karena itu menyebabkan perubahan kecil pada bobot dan bias, yang jauh dari nilai optimalnya [12].

Arsitektur MLP-ANN terdiri dari sejumlah node yang saling berhubungan terdiri dari tiga jenis lapisan: *input*, *hidden layer*, dan *output*. Skema dari berbagai komponen MLP dengan satu lapisan tersembunyi seperti pada Gambar 2. Lapisan *input* hanya mengirimkan nilai *input* x_i ke unit di *hidden layer*, tetapi tidak melakukan operasi apapun pada sinyal *input*. *Hidden layer* menerima

sinyal dari *node* lapisan *input* dan mengubahnya menjadi sinyal yang dikirim ke semua *node output* dan mengubahnya menjadi output. Bobot pada koneksi, dari input ke *node hidden layer* dan dari *hidden layer* ke lapisan *output*, dikalibrasi menggunakan algoritma *steepest descent*. Algoritma ini digunakan untuk menyelesaikan masalah non-linier [13].



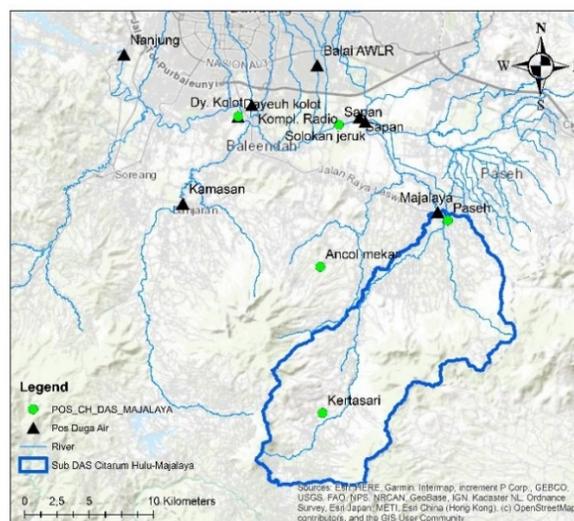
Gambar 2 Arsitektur Model MLP 1 layer [13]

2.2 Lokasi Studi

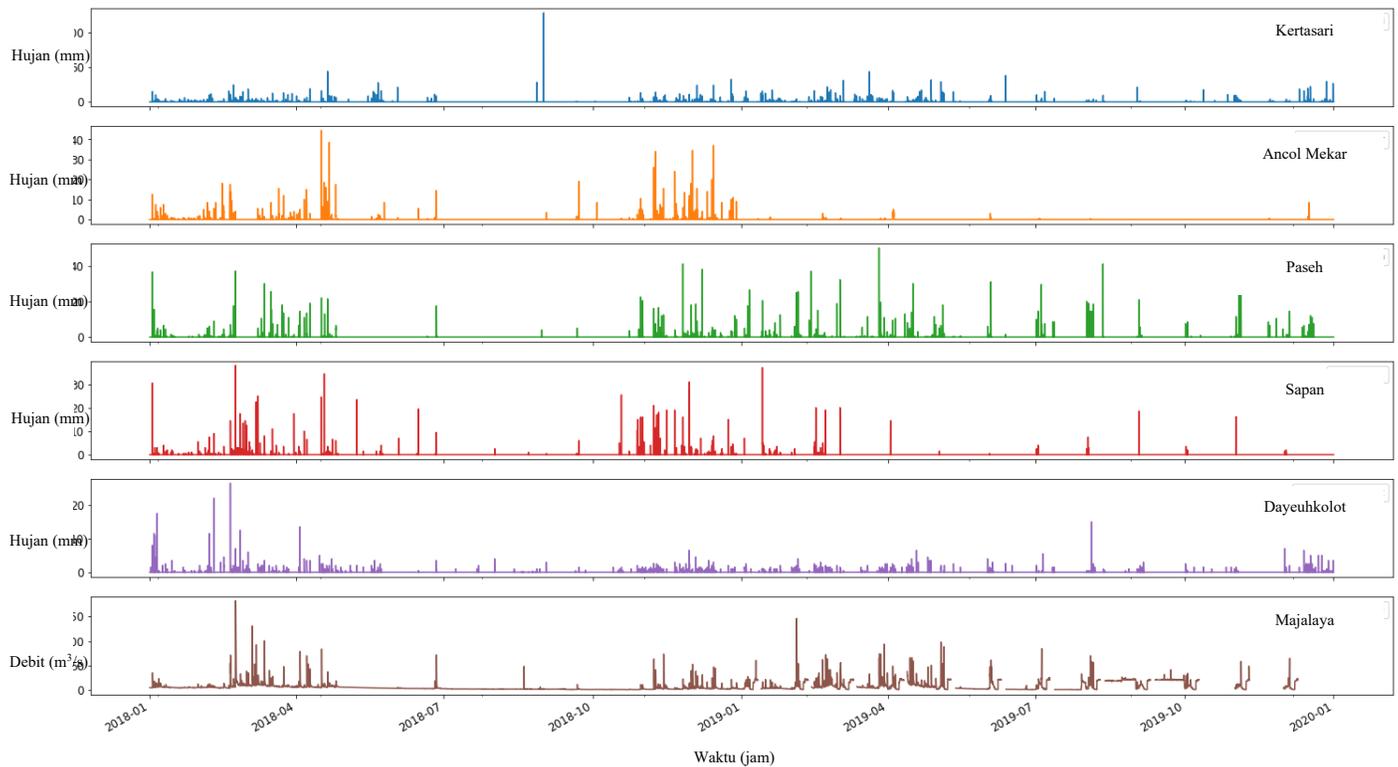
Penelitian ini dilakukan di Sungai Citarum bagian hulu di Kecamatan Majalaya. Secara hidrologis, daerah kajian berada di Daerah Aliran Sungai (DAS) Citarum Hulu mulai dari Gunung Wayang sampai dengan *outlet* di pos duga air Majalaya. Luas DAS Citarum hulu *outlet* Majalaya yaitu 208 km². Secara geografis terletak pada koordinat 7.151 S dan 107.719 E, sedangkan secara administrasi berada di 4 (empat) kecamatan yaitu Kecamatan Kertasari, Kecamatan Pacet, Kecamatan Ibum, Kecamatan Paseh, dan Kecamatan Majalaya. Lokasi studi seperti ditunjukkan pada Gambar 3.

2.3 Data

Input data yang digunakan dalam model prediksi debit di pos duga air Majalaya dengan menggunakan model MLP yaitu berupa data hujan dan debit di pos duga air yang ditinjau. Berdasarkan analisis poligon Thiessen, terdapat 4 (empat) stasiun hujan yang mempengaruhi debit di Majalaya yaitu: Kertasari, Ancol Mekar, Paseh, Sapan, dan Dayeuhkolot. Lokasi stasiun hujan dan pos duga air seperti pada Gambar 1. Data yang digunakan merupakan data hujan durasi pendek (jam-jam an) selama dua tahun yaitu dari 1 Januari 2018 sampai dengan 31 Desember 2019. Data tersebut bersumber dari Balai Besar Wilayah Citarum yang diakses melalui <http://103.110.9.91/>. Visualisasi data seperti pada Gambar 4.



Gambar 3 Lokasi studi (batas DAS dan stasiun hidrometeorologi)



Gambar 4 Data hujan dan debit

2.4 Perancangan Model

Model prediksi debit dirancang dengan menggunakan metode MLP. Tahapan desain model secara umum sebagai berikut:

1. Menentukan jenis *input* data yang akan digunakan. Pemilihan *input* data merupakan tahapan awal yang penting dalam merancang model prediksi dengan pendekatan basis data. Pemilihan jenis data harus disesuaikan dengan ketersediaan data yang ada dan juga tujuan dari model yang dikembangkan [14]. Dalam penelitian ini, *input* data yang dipilih yaitu berupa data hujan jam-jaman dari 4 (empat) stasiun hujan yang mempengaruhi debit di Majalaya. data curah hujan dan debit dari 24 jam terakhir ($t-1$ hingga $t-24$) digunakan untuk memperkirakan debit 1 jam kedepan.
2. Melakukan pengecekan kualitas dan kuantitas data, sehingga dapat yang digunakan dapat dipastikan tidak ada yang kosong ataupun data yang bersifat *outlier*.
3. Menyusun algoritma model MLP. Penelitian dilakukan dengan menggunakan bahasa pemrograman Python 3.7. Persiapan dan pengelolaan data telah dilakukan dengan menggunakan Scikit-learn, Pandas, dan Numpy. Model MLP diprogram dengan menggunakan algoritma Keras, dan Matplotlib digunakan untuk memproses angka. Pendekatan optimasi estimasi momen adaptif (ADAM) dipilih untuk melatih jaringan. Algoritma *Scikit-learn* adalah perpustakaan pembelajaran mesin sumber terbuka untuk bahasa pemrograman Python. *Scikit-learn* memanfaatkan lingkungan yang luas ini untuk menawarkan implementasi mutakhir dari beberapa teknik pembelajaran mesin yang terkenal sambil menjaga antarmuka yang ramah pengguna yang terhubung erat dengan bahasa pemrograman Python [15].
4. Menentukan jumlah *hidden layer* dan *hyper parameter* yang paling optimal. Untuk mendapatkan model prediksi yang paling optimal dilakukan dengan melakukan simulasi model dengan berbagai skenario. Tiga skenario *hidden layer* digunakan dalam penelitian ini seperti pada Tabel 1.

Tabel 1 Skenario model

Skenario	Jumlah Layer	Jumlah Neuron
MLP 01	1	128
MLP 02	2	128, 256
MLP 03	3	128, 256, 512

- Normalisasi data dilakukan dengan menggunakan metode *MinMax Scalar* dengan persamaan(1).

$$X = \frac{(X_{ori}-X_{max})}{(X_{max}-X_{min})} \quad (1)$$

Dengan: X = Data yang dinormalisasi, X_{ori} = data asli, X_{max} = nilai data maksimum, X_{min} = nilai data minimum.

- Membagi data menjadi data *training* dan *testing*. Menurut penelitian sebelumnya, hasil prediksi terbaik diperoleh dengan distribusi pembagian data *training* dan *testing* sebesar 70-80% untuk data *training*, dan 20-30% untuk *testing* [16]. Dalam penelitian ini data didistribusikan menjadi 75% *training* dan 25% *testing*.
- Analisis *loss* pada tahap *training* dianalisis dengan menggunakan fungsi MSE dengan persamaan (2).

$$MSE = \frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2 \quad (2)$$

Dengan: O_i sebagai data observasi, dan P_i sebagai nilai hasil prediksi.

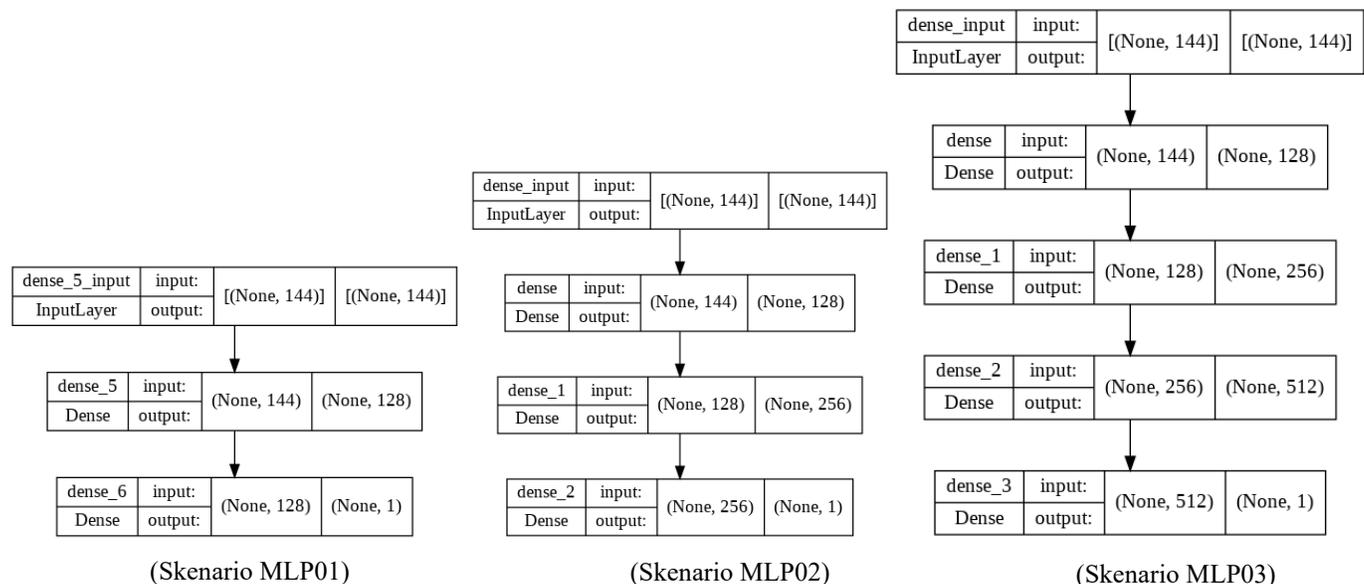
- Proses *training* data untuk masing-masing skenario dengan parameter *Epochs* =100 dan *Batch size* =10.
- Analisis kinerja model. Dalam penilaian ini, penilaian kinerja dengan metode pengukuran statistik. Kecocokan kriteria statistik menggunakan tiga kriteria: Efisiensi *Nash-Sutcliffe* (NSE), Koefisien determinasi (R^2), dan *Root Mean Square Error* (RMSE).

3. HASIL DAN PEMBAHASAN

Seperti yang sudah dijelaskan pada tahap desain model, tiga skenario model dikembangkan dalam penelitian ini untuk mendapatkan jumlah *hidden layer* yang paling optimal berdasarkan penilaian kinerja model. Prediksi debit satu jam yang akan datang ($t+1$) dilatih berdasarkan data 24 jam sebelumnya ($t-24$). Struktur model masing-masing skenario dapat dilihat pada Gambar 5.

Setelah dilakukan strukturisasi model, selanjutnya dilakukan proses *training data* dan analisis *loss function*. Tujuannya untuk meminimalkan *minimize loss function*/fungsi kerugian. Semakin rendah kerugian, semakin baik modelnya. *Loss function* digunakan untuk mengukur kesalahan antara keluaran prediksi dan nilai target yang diberikan. Sebuah *loss function* memberitahu kita seberapa jauh model algoritma dari mewujudkan hasil yang diharapkan. Dalam penelitian ini jenis *loss function* yang digunakan yaitu MSE. Grafik *loss function* untuk ketiga skenario menunjukkan perbedaan yang cukup signifikan satu sama lain (Gambar 6).

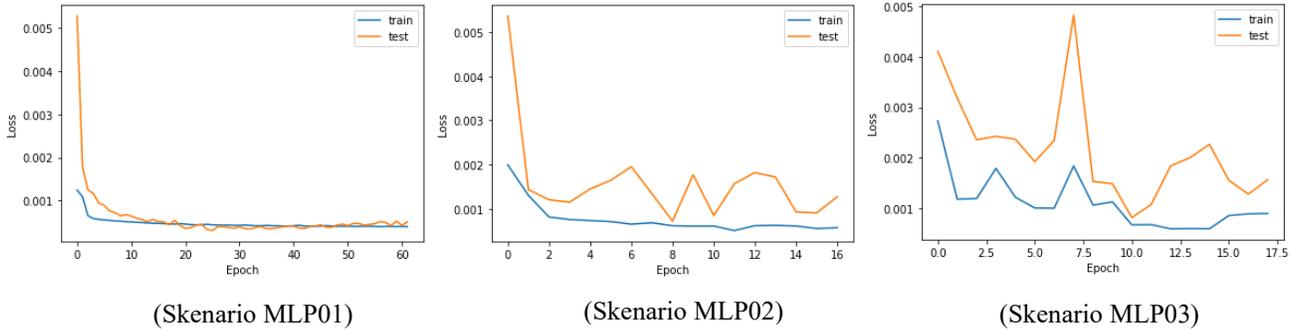
Berdasarkan Gambar 6, dapat dilihat bahwa model skenario MLP01 menunjukkan model MLP dengan 1 *hidden layer* 128 neuron dapat mempelajari data dengan baik. Sebaliknya dengan Skenario MLP 02 dan MLP03 yang menunjukkan model tidak dapat mempelajari data dengan baik. Tahap berikutnya yaitu model akan melakukan prediksi dengan menggunakan data testing. Penilaian model prediksi pada fase testing menggunakan pengukuran statistik berupa RMSE, R^2 , dan NSE. Hasil dari pengukuran kinerja model pada fase *testing* seperti dapat dilihat pada Tabel 2. Selain dengan menggunakan pendekatan statistik, penilaian model juga dilakukan secara visual dengan menggunakan grafik hidrograf dan *scatter plot* seperti dapat dilihat pada Gambar 7 sampai 9.



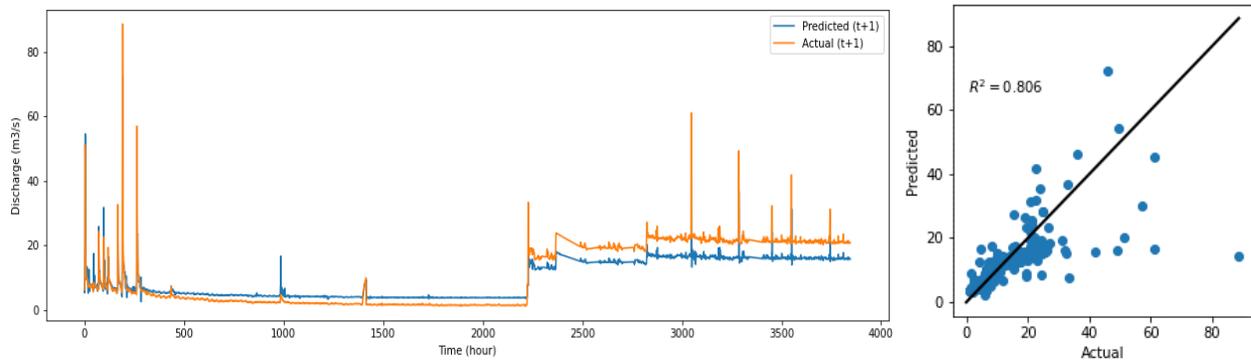
Gambar 5 Struktur model untuk berbagai skenario

Tabel 2 Penilaian kinerja model

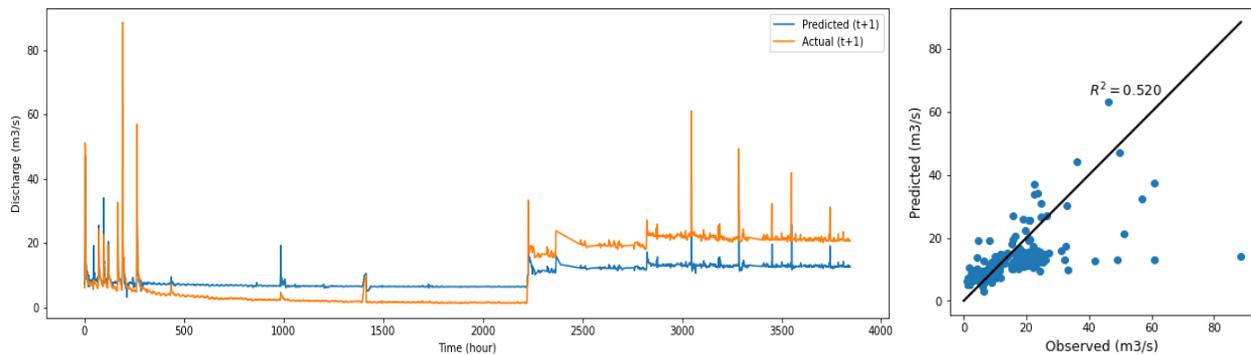
Skenario	RMSE	R ²	NSE
MLP 01	4.105	0.805	0.805
MLP 02	6.452	0.519	0.519
MLP 03	7.171	0.407	0.407



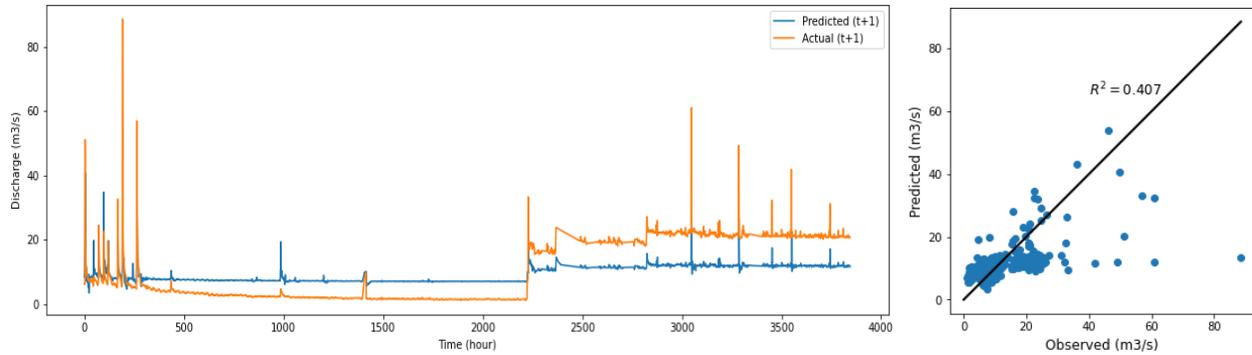
Gambar 6 Grafik loss function untuk berbagai skenario



Gambar 7 Perbandingan hidrograf dan scatter plot debit hasil prediksi dengan observasi skenario MLP01



Gambar 8 Perbandingan hidrograf dan scatter plot debit hasil prediksi dengan observasi skenario MLP02



Gambar 9 Perbandingan hidrograf dan scatter plot debit hasil prediksi dengan observasi skenario MLP03

Berdasarkan Tabel 2 diperoleh nilai RMSE untuk ketiga skenario yaitu sebesar 4.105 s.d 7.172 m^3/s . Sedangkan untuk nilai R^2 dan NSE berada pada rentang 0,805 s.d 0,407. Secara statistik berdasarkan kriteria nilai NSE dapat disimpulkan ketiga skenario model cukup baik dalam memprediksi debit untuk 1 jam kedepan. Skenario MLP01 dengan 1 *hidden layer* 128 Neuron menghasilkan kinerja model yang paling baik dibandingkan dengan skenario MLP02 dan MLP03. Secara grafis, dapat dilihat untuk ketiga skenario model menunjukkan pola yang sama, terjadi kesenjangan yang cukup besar antara debit prediksi terhadap debit aktual. Kesenjangan yang signifikan terutama terlihat pada kondisi debit maksimum, hal ini juga terkonfirmasi pada grafik *scatter plot* yang menunjukkan bahwa pada debit besar, sebaran data semakin menjauhi garis 45° atau garis ideal. Debit hasil prediksi sebagian besar berada dibawah garis 45° yang menunjukkan bahwa debit prediksi lebih kecil daripada debit aktual (*underestimate*).

4. KESIMPULAN

Dalam studi ini, model prediksi debit di pos duga air Majalaya dikembangkan dengan menggunakan model MLP. Input data yang digunakan dalam model ini yaitu berupa data hujan jam-jam an dari 4 (empat) stasiun hujan yang berpengaruh dan juga data debit di lokasi yang ditinjau. Tiga skenario model berdasarkan jumlah *hidden layer* dikembangkan untuk mendapatkan struktur model yang paling optimal.

Berdasarkan hasil analisis dapat disimpulkan bahwa model MLP01 dengan 1 *hidden layer* dan 128 Neuron merupakan model MLP yang paling optimal sesuai hasil RMSE, R^2 , dan NSE. Begitu pula berdasarkan grafik *loss* yang menunjukkan bahwa model MLP01 menghasilkan grafik *loss* yang ideal, yang berarti bahwa model tersebut dapat mempelajari *data training* dengan baik.

Secara visual berdasarkan grafik hidrograf dan *scatter plot*, ketiga skenario model menunjukkan debit hasil prediksi yang lebih kecil daripada debit aktual, terutama pada kasus debit puncak. Hasil pemodelan prediksi debit di pos duga air Majalaya ini masih perlu dilakukan peningkatan lagi untuk mendapatkan hasil yang lebih baik, terutama untuk mengatasi kesenjangan pada debit maksimum. Meskipun demikian, model yang dikembangkan dapat menjadi salah satu alternatif dalam pemodelan prediksi debit untuk keperluan peringatan dini banjir.

DAFTAR PUSTAKA

- [1] I. Dewa Gede A Junnaedhi, E. Riawan, R. Suwarman, T. Wahyu Hadi, A. Lubis, N. Joko Trilaksono, R. Rahayu, P. Kombara, R. Waskito, H. Ekalaya Oktora, R. Supriatna, A. Anugrah, A. Haq Mudzakkir, W. Setiawan, Majalaya Flood Early Warning System: A Community Based Approach, IOP Conf. Ser. Earth Environ. Sci. 71 (2017) 0–12. <https://doi.org/10.1088/1755-1315/71/1/012013>.
- [2] A.K. Pistrika, G. Tsakiris, Flood risk assessment: A methodological framework, Water Resour. Manag. New (2007) 14–16.
- [3] X.H. Le, H.V. Ho, G. Lee, S. Jung, Application of Long Short-Term Memory (LSTM) Neural Network for Flood Forecasting, Water. 11 (2019) 1–19. <https://doi.org/10.3390/W11071387>.
- [4] M. Nur Adli Zakaria, M. Abdul Malek, M. Zolkepli, A. Najah Ahmed, Application of artificial intelligence algorithms for hourly river level forecast: A case study of Muda River, Malaysia, Alexandria Eng. J. 60 (2021) 4015–4028. <https://doi.org/10.1016/j.aej.2021.02.046>.
- [5] N. Lv, X. Liang, C. Chen, Y. Zhou, J. Li, H. Wei, H. Wang, A long Short-Term memory cyclic model with mutual information for hydrology forecasting: A Case study in the xixian basin, Adv. Water Resour. 141 (2020) 1–0.

- <https://doi.org/10.1016/j.advwatres.2020.103622>.
- [6] S.N. Chanu, P. Kumar, Application Of Multilayer Perceptron Based Artificial Neural Network For Modeling Of Rainfall Runoff In A Himalayan Watershed, (2016).
- [7] M.T. Khan, M. Shoaib, M. Hammad, H. Salahudin, F. Ahmad, S. Ahmad, Application of Machine Learning Techniques in Rainfall Runoff Modelling of the Soan River Basin, Pakistan, *Water* 2021, Vol. 13, Page 3528. 13 (2021) 3528. <https://doi.org/10.3390/W13243528>.
- [8] M.N. Asaad, Forecasting of Streamflow and Comparison of Artificial Intelligence Methods : A Case Study for Meram Stream in, (2022).
- [9] M. Rezaeian Zadeh, S. Amin, D. Khalili, V.P. Singh, M. Rezaeian Zadeh, S. Amin, D. Khalili, V.P. Singh, Daily Outflow Prediction by Multi Layer Perceptron with Logistic Sigmoid and Tangent Sigmoid Activation Functions, *Water Resour Manag.* 24 (2010) 2673–2688. <https://doi.org/10.1007/s11269-009-9573-4>.
- [10] Q.B. Pham, H.A. Afan, B. Mohammadi, A.N. Ahmed, N.T.T. Linh, N.D. Vo, R. Moazenzadeh, P.S. Yu, A. El-Shafie, Hybrid model to improve the river streamflow forecasting utilizing multi-layer perceptron-based intelligent water drop optimization algorithm, *Soft Comput.* 24 (2020) 18039–18056. <https://doi.org/10.1007/S00500-020-05058-5/FIGURES/10>.
- [11] J. Hong, S. Lee, G. Lee, D. Yang, J. Bae, J. Kim, K. Kim, K. Lim, Comparison of machine learning algorithms for discharge prediction of multipurpose dam, *Water (Switzerland)*. 13 (2021) 1–12. <https://doi.org/10.3390/w13233369>.
- [12] P. Hosseinzadehtalaei, Multilayer perceptron with different training algorithms for streamflow forecasting Multilayer perceptron with different training algorithms for streamflow forecasting, *Neural Comput. Appl.* (2014). <https://doi.org/10.1007/s00521-012-1287-5>.
- [13] E.K. Onyari, F.M. Ilunga, Application of MLP neural network and M5P model tree in predicting streamflow: A case study of Luvuvhu catchment, South Africa, *Int. J. Innov. Manag. Technol.* 4 (2013) 11. <https://doi.org/10.7763/IJIMT.2013.V4.347>.
- [14] X.H. Le, H.V. Ho, G. Lee, S. Jung, Application of Long Short-Term Memory (LSTM) neural network for flood forecasting, *Water (Switzerland)*. 11 (2019). <https://doi.org/10.3390/W11071387>.
- [15] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, Scikit-learn: Machine Learning in Python, *J. Mach. Learn. Res.* 12 (2011) 2825–2830.
- [16] A. Gholamy, V. Kreinovich, O. Kosheleva, Why 70/30 or 80/20 Relation Between Training and Testing Sets: A Pedagogical Explanation, *Dep. Tech. Reports.* (2018) 1–6.