

DASHBOARD SISTEM PERINGATAN DINI PREDIKSI BANJIR MENGGUNAKAN METODE RADIAL BASIS FUNCTION BERBASIS WEB

WEB BASED DASHBOARD FOR FLOOD EARLY WARNING PREDICTION SYSTEM USING RADIAL BASIS FUNCTION METHOD

Muhammad Adli Azizulhaq¹, Dr.Eng. Asep Suhendi,S.Si., M.Si², Cesi Setianingsih S.T., M.T.³

^{1,2}Prodi S1 Teknik Fisika, Fakultas Teknik Elektro, Universitas Telkom

³Prodi S1 Teknik Sistem Komputer Fakultas Teknik Elektro, Universitas Telkom

¹adlizulhq@gmail.com, ²suhendi@telkomuniversity.ac.id, ³setiacasie@telkomuniversity.ac.id

Abstrak

Banjir merupakan salah satu dampak yang merugikan masyarakat yang disebabkan oleh manusia, disamping faktor tanah dan hujan. Kerugian yang disebabkan oleh banjir diantaranya menimbulkan masalah ekonomi, kesulitan air bersih, kesehatan, melumpuhkan aktivitas masyarakat, serta dapat menimbulkan korban jiwa. Salah satu solusi dampak dari permasalahan adalah dengan membuat dashboard sistem informasi peringatan dini banjir menggunakan prediksi metode *Radial Basis Function*. Dashboard adalah sistem pemantau informasi peringatan dini banjir untuk mengetahui data secara real-time dari sensor water level, debit aliran sungai dan curah hujan yang ditempatkan pada hulu dan hilir sungai dengan memanfaatkan teknologi berbasis IoT. *Radial Basis Function* merupakan jaringan syaraf tiruan untuk prediksi dengan mengambil data masa lampau serta data dan informasi yang relevan saat ini sebagai data latih menggunakan model matematis sehingga output dari pengolahan data oleh RBF tersebut akan mengeluarkan data periode yang akan datang sebagai data pra prediksi. Tampilan dashboard akan menampilkan tiga parameter yakni water level, debit aliran sungai dan curah hujan, serta indikator sebagai notifikasi ketika permukaan air sungai melewati batas level. Dengan membuat dashboard sistem peringatan dini prediksi banjir, maka akan mengurangi dampak kerugian yang diakibatkan oleh banjir. Cara mengetahui performansi terbaik dari model RBF dilihat berdasarkan hasil dengan kriteria nilai Mean Absolute Error (MAE) terkecil dan semakin MAE mendekati nilai 0 maka akurasi model semakin baik. Dari pengujian yang sudah dilakukan, hasil terbaik didapatkan dari metode RBF yaitu dengan rata-rata nilai MAE di setiap subdivisi sungai Cauvery, Godavari, Krishna, Mahanadi, Dan Son sebesar 0.048%.

Kata kunci: *Dashboard, Jaringan Syaraf Tiruan, Prediksi, Radial Basis Function*

Abstract

Flooding is one of the adverse impacts on society caused by humans, in addition to land and rain factors. Losses caused by floods include causing economic problems, lack of clean water, health, paralyzing community activities, and can cause fatalities. One solution to the impact of the problem is to create a flood warning information system Dashboard using the prediction of the Radial Base Function. The dashboard is a flood early warning information monitoring system to find out real-time data from water level, river flow discharge and rainfall sensors placed upstream and downstream of the river by utilizing IoT-based technology. Radial Basis Function is an Artificial Neural Network for prediction by taking past data and relevant data and information currently as training data using a mathematical model so that the output of RBF data processing will issue future period data as pre-predicted data. The dashboard display will display three parameters namely water level, river flow discharge and rainfall, as well as an indicator as a notification when the river water level exceeds the level limit. By creating a dashboard for flood warning early warning systems, it will reduce the impact of losses caused by flooding. How to find out the best performance of the RBF model is seen based on the results with the criteria for the smallest Mean Absolute Error (MAE) value and the more the MAE approaches a value of 0, the better the accuracy of the model. From the tests that have been carried out, the best results were obtained from the RBF method, namely the average MAE value in each subdivision of the Cauvery, Godavari, Krishna, Mahanadi, and Son rivers of 0.048%.

Keywords: *Dashboard, Artificial Neural Network, Prediction, Radial Basis Function.*

1. Pendahuluan

1.1 Latar Belakang

Bencana banjir merupakan bencana alam yang sangat merugikan manusia. Banjir disebabkan oleh air sungai yang meluap ke daerah yang tergenang karena air sungai tidak dapat menahan air hujan. Selain faktor tanah dan faktor manusia, curah hujan merupakan faktor penyebab terjadinya banjir. Pada dasarnya di daerah yang curah hujannya tinggi dalam rentan waktu yang lama, sangat berpotensi terjadinya banjir terutama daerah yang datarannya rendah. Dampak dari banjir akan menimbulkan masalah ekonomi, kesulitan air bersih, kesehatan, melumpuhkan aktivitas masyarakat, serta bisa menimbulkan korban jiwa [1].

Untuk mengurangi dampak bencana banjir tersebut dengan membuat sebuah sistem peringatan dini prediksi banjir. Sistem ini ditujukan kepada masyarakat yang bertempat di bantaran sungai. Di mana sistem informasi yang akan dibuat berbentuk *dashboard* dengan menggunakan metode prediksi yang akan memantau perubahan ketinggian pada permukaan sungai untuk periode yang akan datang, sehingga ketika permukaan aliran air sungai naik akan langsung menginformasikan ke masyarakat bahwa banjir akan segera datang.

Pada penelitian ini akan dibuat sebuah *dashboard* sistem peringatan dini prediksi banjir secara real-time berbasis web server. Parameter yang dipantau yaitu *water level*, debit aliran sungai dan curah hujan. Kemudian data parameter pengukuran tersebut akan diolah menggunakan metode prediksi *Radial Basis Function*. Diharapkan masyarakat lebih mudah mengakses hasil data yang akan ditampilkan oleh *dashboard* serta dapat memahami notifikasi darurat ketika permukaan air sungai telah melewati batas level sungai tersebut.

1.2. Tujuan

Adapun tujuan yang akan dilakukan pada penelitian ini :

Penelitian ini memiliki tujuan untuk menganalisis kemampuan jaringan syaraf tiruan dengan menggunakan metode *Radial Basis Function* untuk memprediksi banjir. Selanjutnya penelitian ini akan menganalisis pengaruh dari nilai parameter yang digunakan seperti data *discharge* dan data curah hujan terhadap prediksi banjir yang dihasilkan. Kemudian membuat sistem *dashboard* sebagai pemantau hasil data prediksi banjir.

1.3 Rumusan Masalah

Berdasarkan latar belakang di atas, maka dapat diuraikan perumusan masalah sebagai berikut :

Bagaimana kemampuan dari metode RBF dalam memprediksi banjir berdasarkan data *discharge*/TMA dan curah hujan. Selanjutnya bagaimana pengaruh nilai parameter RBF terhadap prediksi banjir. Kemudian Bagaimana cara menampilkan data hasil prediksi banjir

2. Landasan Teori

2.1. Banjir

Pada dasarnya banjir terjadi karena jumlah air yang mengalir pada suatu sistem drainase melebihi atau melebihi kapasitas drainasenya [5]. Biasanya bencana banjir terjadi di daerah dataran rendah, karena kebutuhan akan sumber daya air untuk berbagai keperluan dan pemanfaatan yang memadai, daerah tersebut berkembang menjadi daerah perkotaan. Kerusakan akibat banjir menunjukkan kurangnya sikap masyarakat terhadap bencana yang akan segera terjadi. Sebagian besar penyebab masalah ini adalah karena kurangnya infrastruktur dan perencanaan pengelolaan yang tidak memadai di daerah yang terkena dampak [6].

2.2. Curah Hujan

Intensitas curah hujan adalah banyaknya curah hujan yang dinyatakan dengan tingkat curah hujan per satuan waktu dalam suatu periode hujan terkonsentrasi (Wesli, 2008). Intensitas curah hujan tergantung pada lamanya dan frekuensi curah hujan [7].

2.3. Discharge

Discharge adalah debit aliran sungai (DAS). Discharge dapat digunakan dalam menganalisis hidrologi seperti pengaruh antara limpasan (run off) banjir, debit aliran sungai, serta intensitas curah hujan terhadap waktu. Gambar 2.2 menunjukkan gambaran terkait proses terjadinya discharge terjadi.

2.4. Dashboard

Menurut Stephen Few, informasi *dashboard* adalah alat penyajian informasi yang memberikan solusi terhadap kebutuhan informasi dengan menyediakan tampilan *interface* dalam berbagai bentuk, seperti grafik,

laporan, indikator visual, mekanisme peringatan, dan dinamika. *Dashboard* harus mengutamakan efektivitas penyampaian informasi agar lebih mudah bagi pengguna untuk melihat dan memantau secara *real-time*.

2.5. Prediksi dan Time Series

Model *time series* adalah prakiraan berdasarkan deret waktu peristiwa. Deret waktu digunakan untuk menentukan pola masa lalu yang dikumpulkan secara berkala berdasarkan urutan waktu kejadian. Data masa lalu ini dapat digunakan sebagai dasar untuk mempertimbangkan prakiraan masa depan. Gambar 2.3 menunjukkan grafik perubahan discharge terhadap waktu dalam model *time series*.

Dalam prediksi, akurasi prediksi yang dilakukan merupakan hal yang penting. Semakin tinggi akurasi prediksi maka akan semakin kecil tingkat kesalahan dari prediksi. Menurut Makridakis, salah satu cara untuk mengukur akurasi dalam prediksi adalah nilai tengah akar kuadrat atau *Root Square Mean Error* (RMSE). Persamaan 2.1 menunjukkan RMSE di bawah ini.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - o_i)^2}$$


Di mana f_i : Nilai prediksi untuk period ke i
 o_i : Nilai aktual untuk periode ke i
 n : Jumlah periode

RMSE adalah ukuran skor kuadrat yang mengukur besaran *error* rata-rata, juga dapat mewakili besarnya kesalahan yang dihasilkan oleh model prediksi [8]. Adapun nilai *Mean Absolute Error* (MAE) menyatakan besaran kesalahan (*error*) rata-rata pada model prediksi tanpa memperhatikan kecenderungan atau arah kesalahannya. Persamaan 2.2 menunjukkan MAE di bawah ini.

$$MAE = \frac{\sum_{t=1}^N |(Y_t - T_t)|}{N}$$

2.6. Radial Basis Function Neural Network

RBF merupakan salah satu model jaringan syaraf tiruan yang menggunakan fungsi aktivasi Gaussian pada hidden layer untuk melakukan konversi non-linier pada input, kemudian melakukan pengolahan linier pada lapisan keluaran. Jaringan syaraf metode RBF memiliki unit yang terdiri dari input layer, unit hidden layer, dan output layer. Topologi jaringan RBF digambarkan pada gambar 2.1 dibawah ini [12]



Gambar 2.1 Topologi Jaringan Syaraf RBF.

Struktur Jaringan *Radial Basis Funtion* :

1. Input layer

Input layer adalah lapisan yang membawa data masuk ke dalam sistem atau model dan di proses pada *layer* selanjutnya. *Input layer* membaca data dan nilai yang diperlukan dari keluaran sensor.

2. Hidden Layer

Hidden layer adalah lapisan kedua dalam struktur jaringan RBF. Dengan menyesuaikan nilai bobot di setiap koneksi input, *neuron* dan *output*, lapisan kedua adalah lapisan tersembunyi berdimensi lebih tinggi. Nilai bobot difungsikan untuk mempelajari dan mengingat informasi, dan nilai bobot akan dieksekusi terus menerus hingga diperoleh keluaran yang diharapkan.

Menghitung nilai bobot yang baru (w) dari data latih pada persamaan 2.3.

$$W_{kj}(\text{baru}) = W_{kj}(\text{lama}) + \Delta W_{kj}$$

(2.3)

3. Output Layer


Pada bagian *output layer* tiap unit masukan dijumlahkan dari perkalian antara bobot dengan fungsi basis akan mengeluarkan nilai yang disebut *output layer*. Transformasi dari bagian masukan ke bagian *hidden* adalah *non-linier*, dan transformasi dari bagian *hidden* ke bagian *output* adalah linier.

Melakukan perhitungan nilai *output* dari jaringan syaraf tiruan pada persamaan 2.4.

$$Y_k = \sum_j^L 1wG(\|x - t\|) + bias$$

(2.4)

2.7. Gambaran Sistem Secara Umum




Gambar 2.2 Gambaran Umum Sistem

Di gambar 2.2 menjelaskan proses prediksi banjir menggunakan metode RBF, tahap yang dilakukan adalah pencarian dan pengumpulan data sensor water level, debit aliran sungai dan sensor curah hujan yang akan digunakan proses pengujian pada data training dan testing. Setelah data yang diperoleh oleh sensor dikumpulkan, selanjutnya dilakukan proses pembersihan data dan dilakukan transformasi data agar data-data tersebut lebih mudah diproses oleh metode RBF untuk diprediksi.

2.8. Desain Sistem

Dashboard sebagai sistem informasi peringatan dini ini terdiri dari beberapa parameter yang akan diukur. *Device* yang terpasang pada daerah sungai akan dipantau melalui *dashboard*. *Device* yang akan dipantau pada *dashboard* adalah sensor *water level*, dan sensor curah hujan. Semua data terukur akan dikirim ke server *database* menggunakan peralatan teknologi berbasis *Internet of Things* (IoT).

Pada perancangan sistem ini menjelaskan secara umum mengenai tahapan sistem yang telah dibuat. Berikut merupakan perancangan secara umum yang terlihat pada gambar 2.3.



Gambar 2.3 Blok Diagram Sistem

3. Pengujian dan Hasil Analisis

3.1. Pengujian dan Hasil Analisis Pelatihan

Pada tahap pengujian melibatkan beberapa proses dengan tujuan mendapatkan performansi dari sebuah model yang diharapkan. Di mana proses tersebut melakukan *trial and error* pada parameter RBF diantaranya: Jumlah *hidden layer*, *learning rate*, *epoch*, *target error*, *spread constant*, dan terakhir dihasilkan nilai MAE yang ditujukan untuk mengetahui tingkat kesalahan (*error*) dan performansi seberapa akurat untuk prediksi.

3.2. Pengujian Terhadap Jumlah Hidden Layer

Tabel 3.1 Hasil Pengujian Berdasarkan Hidden Neuron.

Jumlah hidden neuron	Learning rate	Spread Constant	Epoch	Target Error	MAE	
					Discharge	Curah Hujan
5	0.1	1.1	500	0	0.00665	0.00651
10	0.1	1.1	500	0	0.00656	0.00649
15	0.1	1.1	500	0	0.00450	0.00643
20	0.1	1.1	500	0	0.00424	0.00425
25	0.1	1.1	500	0	0.00418	0.00402
30	0.1	1.1	500	0	0.00346	0.00396
35	0.1	1.1	500	0	0.00371	0.00409

Berdasarkan proses pengujian pada Tabel 3.1 didapatkan hasil MAE terkecil sebesar 0.00346 untuk data *discharge* dan 00396 untuk data curah hujan. Penurunan tingkat error dari jumlah *hidden neuron* 5 sampai dengan 30 menurun sebesar 92,20% untuk *discharge* dan 64,39% untuk curah hujan.

3.3. Pengujian Terhadap Learning Rate

Tabel 3.2 Hasil pengujian Berdasarkan Nilai Learning Rate.

Jumlah hidden neuron	Learning rate	Spread Constant	Epoch	Target Error	MAE	
					Discharge	Curah Hujan
30	0.1	1.1	500	0	0.00346	0.00396
30	0.2	1.1	500	0	0.00351	0.00399
30	0.3	1.1	500	0	0.00362	0.00403
30	0.4	1.1	500	0	0.00373	0.00418
30	0.5	1.1	500	0	0.00396	0.00421
30	0.6	1.1	500	0	0.00399	0.00429
30	0.7	1.1	500	0	0.00405	0.00466

Berdasarkan proses pengujian pada Tabel 3.2 didapatkan nilai MAE terkecil 0.00346 untuk *discharge* dan 0.00396 untuk curah hujan. Peningkatan tingkat kesalahan (*error*) sebesar 17,05% untuk *discharge* dan 17,68% untuk curah hujan.

3.4. Pengujian Terhadap Spread Constant

Tabel 3.3 Hasil pengujian Berdasarkan Nilai spread constant.

Jumlah hidden neuron	Learning rate	Spread Constant	Epoch	Target Error	MAE	
					Discharge	Curah Hujan
30	0.1	1.1	500	0	0.00346	0.00396
30	0.1	1.2	500	0	0.00350	0.00399
30	0.1	1.3	500	0	0.00361	0.00412
30	0.1	1.4	500	0	0.00394	0.00445
30	0.1	1.5	500	0	0.00377	0.00418
30	0.1	1.6	500	0	0.00388	0.00432
30	0.1	1.7	500	0	0.00391	0.00440

Berdasarkan proses pengujian pada tabel 3.3 didapatkan hasil MAE sebesar 0.00346 untuk *discharge* dan 0.00396 untuk curah hujan. Tingkat kesalahan (*error*) meningkat dan dihasilkan nilai terbaik untuk nilai *spread constant* pada nilai 1.1, di mana peningkatan *error* sebesar 13,01% untuk *discharge* dan 11,11% untuk curah hujan.

3.5. Pengujian Terhadap Jumlah Epoch

Tabel 3.4 Hasil pengujian Berdasarkan Nilai Maksimum epoch

Jumlah hidden neuron	Learning rate	Spread Constant	Epoch	Target Error	MAE	
					Discharge	Curah Hujan
30	0.1	1.1	500	0	0.00346	0.00396
30	0.1	1.1	600	0	0.00330	0.00370
30	0.1	1.1	700	0	0.00318	0.00371
30	0.1	1.1	800	0	0.00302	0.00332
30	0.1	1.1	900	0	0.00292	0.00312
30	0.1	1.1	1000	0	0.00269	0.00298
30	0.1	1.1	1100	0	0.00291	0.00306

Berdasarkan proses pengujian pada tabel 3.4 didapatkan bahwa hasil MAE terkecil dihasilkan pada 1000 epoch. Dengan nilai MAE terkecil 0.00269 untuk *discharge* dan 0.00298 untuk curah hujan. Perubahan nilai MAE menurun sebesar 28,62% untuk *discharge* dan 32,89% untuk curah hujan.

3.6. Pengujian Terhadap Nilai Target Error

Tabel 3.5 Hasil pengujian Berdasarkan Nilai Target Error.

Jumlah hidden neuron	Learning rate	Spread Constant	Epoch	Target Error	MAE	
					Discharge	Curah Hujan
30	0.1	1.1	1000	0	0.00269	0.00298
30	0.1	1.1	1000	0.01	0.00336	0.00645
30	0.1	1.1	1000	0.001	0.00612	0.00751
30	0.1	1.1	1000	0.0001	0.00269	0.00298
30	0.1	1.1	1000	0.0001	0.00269	0.00298
30	0.1	1.1	1000	0.00001	0.00269	0.00298
30	0.1	1.1	1000	0.000001	0.00269	0.00298

Berdasarkan proses pengujian pada tabel 3.5 dapat disimpulkan bahwa tingkat kesalahan (*error*) menurun sebesar 127,51% dari nilai 0 hingga 0.001 untuk *discharge* dan 152,01% untuk curah hujan.

3.7. Pengujian Dan Hasil Analisis Pengujian

Berdasarkan hasil yang didapat pada model dikatakan bahwa hasil prediksi pada metode RBF sama atau mendekati hasil target atau hasil yang sebenarnya. Dengan nilai MAE didapatkan sebesar 0.04. dapat dilihat pada gambar 3.1.

PROPERTIES	RESULT
Discharge	3662.0
Flood Runoff	0.0
Daily Runoff	4.36
Weekly Runoff	33.85
Mean Absolute Error	0.04
Predicted Water Level	Normal
Actual Water level	Normal

Gambar 3.1 Data Hasil Prediksi Banjir Pada Subdivisi Sungai Son.

Adapun pengujian data secara random setelah diuji beberapa kali sehingga menghasilkan prediksi untuk status prediksi high/banjir, di mana data prediksi sama atau mendekati data sebenarnya. Hasil uji dapat dilihat pada gambar 3.2.

PROPERTIES	RESULT
Discharge	3761.0
Flood Runoff	1.51
Daily Runoff	4.31
Weekly Runoff	27.29
Mean Absolute Error	0.06
Predicted Water Level	High
Actual Water level	High

Gambar 3.2 Hasil Data Untuk Menguji Prediksi.

Perbandingan didapatkan berdasarkan hasil nilai MAE pada setiap subdivisi sungai. Hasil yang didapatkan diperoleh saat testing model dengan memilih objek data sungai, tanggal, bulan, dan tahun. Berikut hasil perhitungan nilai MAE pada tabel 3.6.

Tabel 3.6 Hasil Nilai MAE Di Setiap Subdivisi Sungai.

No	Subdivisi Sungai	MAE
1	Cauvery	0.06
2	Godavari	0.08
3	krishna	0.01
4	Mahanadi	0.05
5	Son	0.04

4. Kesimpulan

Berdasarkan proses yang telah dilakukan pada penelitian tugas akhir ini, dengan dimulai dari pembangunan sebuah model machine learning sampai dengan pengujian dan analisis sistem model, dapat disimpulkan beberapa hal yaitu :

1. Model RBF yang telah dilatih dengan data *dishcharge* dan curah hujan, dapat digunakan untuk memprediksi banjir atau tinggi muka air dan curah hujan untuk satu hari ke depan, satu bulan ke depan, atau satu tahun ke depan.
2. Pada proses training untuk mendapatkan tingkat kesalahan (*error*) terkecil dalam proses pengujian prediksi banjir dan curah hujan dengan metode *Radial Basis Function neural network* yang terbaik didapatkan sebagai berikut :
 - a. *Learning rate* : 0.1
 - b. *Target Error* : 0
 - c. *Spread constant* : 1.1
 - d. *Hidden Layer* : 30
 - e. *Epoch* : 1000
 - f. *Data training* : 6940
 - g. *Data testing* : 730
3. Sistem *dashboard* yang dibuat dapat menampilkan data hasil prediksi banjir.
4. Performansi dari sebuah model dihasilkan dengan nilai uji rata-rata 85% pada saat melakukan training model, dan untuk MAE nilai uji pada setiap subdivisi sungai Cauvery, Godavari, Krishna, Mahanadi, Dan Son rata-rata sebesar 0.048% tingkat kesalahan (*error*) untuk prediksi banjir.

Daftar Pustaka:

- [1] Danang, D., Surwadi, S., Hidayat, I.A. 2019. Mitigasi Bencana Banjir dengan Sistem Informasi Monitoring dan Peringatan Dini Bencana menggunakan Arduino Berbasis IoT.
- [2] Fernando, Agus. Sistem Prediksi Banjir Menggunakan Monitoring Ketinggian Air Sungai Berbasis SMS Gateway. Jurnal PKIP Universitas Telkom, 2018.
- [3] Ramadhan, Muhammad Kahfi. Penggunaan Sensor Curah Hujan Dan Ultrasonik Single Transceiver Pada Sistem Monitoring Ketinggian Air Sungai Berbasis Internet Of Things, Jurnal Tugas Akhir Universitas Telkom, 2020.
- [4] Sanubari, A.R., Kusuma P.D., dan Setianingsih, C. "Pemodelan Prediksi Banjir Menggunakan Artificial Neural Network" e-Proceeding of Engineering, vol. 5, no. 3, p. 6276. Desember 2018.
- [5] Rosyidie, Arief. (2013). Banjir: Fakta dan Dampaknya, Serta Pengaruh dari Perubahan Guna Lahan.
- [6] Arief, Dian Adhietya. (2017). Kerentanan Masyarakat Perkotaan terhadap Bahaya Banjir di Kelurahan Legok, Kecamatan Telanipura, Kota Jambi.
- [7] Juleha. (2016). Analisa Metode Intensitas Hujan Pada Stasiun Hujan Rokan IV Koto, Ujung Batu, Dan Tandun Mewakili Ketersediaan Air Di Sungai Rokan.
- [8] Susilokarti, D., Arif S.S., Susanto, S., Sutiarsa, L. "Identifikasi Perubahan Iklim Berdasarkan Data Curah Hujan Di Wilayah Selatan Jatiluhur Kabupaten Subang, Jawa Barat", Vol. 35, No. 1, Februari 2015.
- [9] Radiansyah, Ismail. dkk. (2008). Sistem Monitoring Tinggi Muka Air Sungai Dan Curah Hujan Berbasis Mikrokontroler AVR 8535 River Water level And Precipitation Monitoring System Based On Microcontroller AVR 8535.
- [10] Lestari, Utami Sylvia. "Kajian Metode Empiris Untuk Menghitung Debit Banjir Sungai Negara Di Ruas Kecamatan Sungai Pandan (Alabio)", Volume 8 No. 2, Desember 2016 : 55-103
- [11] Setyawan, Bintang. (2017). Visualisasi *Dashboard* Power BI Dan Peramalan Jumlah Kasus Demam Berdarah Dengue Di Kabupaten Malang Menggunakan Metode Artificial Neural Network.
- [12] Hardiyanti, Sri Rezeki. (2016). Prediksi Harga Komoditas Pertanian Menggunakan Hybrid Algoritma Jaringan Syaraf Tiruan Arsitektur Radial Basis Function (RBF) Dengan Algoritma Genetika.
- [13] Rauhan, Ahmad. (2019). Pengolahan Data Menggunakan Machine Learning.
- [14] Abdulloh, Rohi. (2016). Trik Mudah Membuat CMS Website dari Nol. Jakarta: PT Elex Media Komputindo.
- [15] Nugroho, Muh Aziz. (2012). Adaptive Genetic Algorithm (AGA) Radial Basis Function (RBF) Neural Network Untuk Klasifikasi.