

Model Prototipe Alih Ragam Hujan Ke Debit Menggunakan Data Satelit TRMM Dan Jaringan Syaraf Tiruan

Ery Suhartanto¹⁾, Ussy Andawayanti²⁾, Rahmah Dara Lufira³⁾,
Azhar Adi Darmawan⁴⁾ Angelina Satya Putri⁵⁾

^{1, 2)} Departemen Teknik Pengairan Universitas Brawijaya

^{3, 4)} Program Doktor Teknik Sumber Daya Air Universitas Brawijaya

⁵⁾ Program Magister Teknik Pengairan Universitas Brawijaya

Jl. MT. Haryono 167, Malang, Jawa Timur

Email: [^{1\)}erysuhartanto@ub.ac.id](mailto:erysuhartanto@ub.ac.id), [^{2\)}uandawayanti@ub.ac.id](mailto:uandawayanti@ub.ac.id), [^{3\)}rahmahdara@ub.ac.id](mailto:rahmahdara@ub.ac.id),
[^{4\)}azharadidfts@umm.ac.id](mailto:azharadidfts@umm.ac.id), [^{5\)}angelina.satyaputri@gmail.com](mailto:angelina.satyaputri@gmail.com)

DOI: <http://dx.doi.org/10.29103/tj.v15i1.1219>

(Received: 16 December 2024 / Revised: 23 February 2025 / Accepted: 02 March 2025)

Abstrak

Ketersediaan dan akurasi data hujan maupun debit menjadi masalah umum di setiap DAS termasuk Sub DAS Lesti. Penelitian ini fokus pada kalibrasi dan validasi data satelit TRMM terhadap pos hujan lapangan. selain itu, bertujuan untuk mengembangkan model prototipe alih ragam hujan ke debit menggunakan JST. Pemodelan ini memanfaatkan data masukan hidrologi, termasuk data satelit TRMM, hari hujan, evaporasi, dan penggunaan lahan, serta data target debit dari Sub DAS Lesti. Hasil kalibrasi dan validasi data satelit TRMM menghasilkan nilai NSE sebesar 0,97 (sangat baik) dan koefisien korelasi (R) sebesar 1,00 (sangat kuat). Selain itu, hasil pemodelan diperoleh kalibrasi terbaik model prototipe yang mengkonversi data hujan menjadi debit menggunakan JST dengan fungsi transfer logsig, menghasilkan nilai koefisien korelasi $R = 0,98897$ (sangat kuat) dengan skema arsitektur jaringan 8-2-10-1 (terdiri dari delapan lapisan masukan, dua lapisan tersembunyi, sepuluh neuron, satu lapisan keluaran) pada 3000 epochs.

Kata kunci: *Hujan, Debit, TRMM, Jaringan Syaraf Tiruan*

Abstract

The availability and accuracy of rain and discharge data is a common problem in every watershed, including the Lesti sub-watershed. This research focuses on the calibration and validation of TRMM satellite data on field rain posts. Apart from that, it aims to develop a prototype model for transferring rainfall variations to discharge using ANN. This modeling utilizes hydrological input data, including TRMM satellite data, rainy days, evaporation, and land use, as well as discharge target data from the Lesti Sub-watershed. The results of calibration and validation of TRMM satellite data produced an NSE value of 0.97 (very good) and a correlation coefficient (R) of 1.00 (very strong). In addition, the modeling results obtained the best calibration of the prototype model which converts rain data into discharge using ANN with the logsig transfer function, producing a correlation coefficient value of $R = 0.98897$ (very strong) with an 8-2-10-1 network architecture scheme (consisting of eight input layers, two hidden layers, ten neurons, one output layer) at 3000 epochs.

Keywords: *Rainfall, Discharge, TRMM, Artificial Neural Network*

1. Latar Belakang

Kerusakan lingkungan hidup pada Daerah Aliran Sungai (DAS) yang semakin meluas akibat kerusakan hutan dan lahan yang cukup parah menyebabkan menurunnya daya dukung DAS sehingga perlu adanya pengelolaan secara optimal. Hal ini juga diperkuat dengan adanya beberapa penelitian bahwa telah berubahnya penggunaan lahan di DAS. Komponen utama pada siklus hidrologi dan analisis hidrologi adalah parameter DAS (Darmawan et al., 2021).

Selama sepuluh tahun terakhir bencana banjir di wilayah Indonesia sebagai dampak kerusakan lahan dan DAS terjadi secara beruntun dengan intensitas, frekuensi, dan distribusi atau wilayah yang terkena bencana semakin meningkat dan meluas. Alih fungsi lahan dari hutan menjadi lahan pertanian maupun pemukiman pada DAS Brantas Hulu cenderung meningkat intensitasnya dan berdampak negatif terhadap kondisi hidrologis serta keberlanjutan produksi air ke Waduk Sutami yang mengalami banjir di musim hujan dan kekeringan di musim kemarau. Hal ini terjadi karena DAS tidak bisa menyerap, menyimpan, dan mengalirkan air hujan di musim hujan dan musim kemarau. Selain itu, dampak negatif lain berubahnya penggunaan lahan adalah meningkatnya laju sedimen dan menurunnya kualitas air di sungai. Hal ini juga diperkuat dengan adanya beberapa penelitian, bahwa telah berubahnya penggunaan lahan di Sub DAS Lesti (Suharyanto et al., 2013).

Data debit di sungai dipergunakan untuk mengetahui ketersediaan debit di DAS yang akan dimanfaatkan untuk mencukupi kebutuhan sumber daya air disekitarnya. Tapi pada kenyataannya ketersediaan data debit di sungai pada umumnya tidak lengkap dan tidak akurat. Maka dari itu diperlukan suatu model prototipe yang akan merubah data hujan ke debit atau yang biasa disebut alih ragam hujan ke debit (Tama et al., 2023).

Hujan adalah salah satu parameter iklim yang penting karena berperan signifikan dalam siklus hidrologi, pertanian, manajemen sumber daya air, dan mitigasi bencana seperti banjir dan kekeringan. Namun, pengukuran hujan secara langsung sering menghadapi kendala keterbatasan alat pengukur hujan (*rain gauge*) yang tersebar tidak merata dan kesulitan akses di wilayah terpencil. Dalam rangka mengatasi keterbatasan ini, data satelit seperti *Tropical Rainfall Measuring Mission* (TRMM) dikembangkan untuk memberikan estimasi hujan yang lebih luas dan konsisten secara temporal serta spasial, serta dirancang untuk menyediakan data hujan berkualitas tinggi di wilayah tropis dan subtropis (Huffman et al., 2007) (Iguchi et al., 2000) (Kummerow et al., 2000) (Nogueira et al., 2018) (Omotoshio et al., 2013) (Pakoksung et al., 2012) (Pratiwi et al., 2017) (Sekaranom et al., 2018) (Simpson et al., 1988) (Syaifullah, 2014) (Tan and Duan, 2017) (Tarnavsky et al., 2013) (Worqlul et al., 2014) (Yuan et al., 2019) (Yuan et al., 2017).


Dalam pengolahan data hujan satelit, pendekatan berbasis Jaringan Syaraf Tiruan (JST) sering digunakan untuk meningkatkan akurasi estimasi data. JST merupakan algoritma pembelajaran mesin yang dibuat untuk menyerupai sistem bekerjanya otak manusia dalam mengenali pola dan hubungan kompleks dalam data. Dengan memanfaatkan JST, penelitian meteorologi dan klimatologi dapat menghasilkan estimasi hujan ke debit yang lebih akurat, terutama di wilayah dengan keterbatasan data pengukuran langsung. JST adalah salah satu cabang utama dalam kecerdasan buatan (*artificial intelligence*) yang terinspirasi dari sistem bekerjanya otak manusia untuk memproses informasi. Konsep ini bermula dari

keinginan para peneliti untuk meniru mekanisme biologis dalam menyelesaikan masalah kompleks yang melibatkan pengenalan pola, klasifikasi, dan prediksi. Pengembangan JST telah berkembang pesat sejak konsep awalnya pada 1940-an hingga kini menjadi bagian integral dari teknologi modern seperti pengenalan wajah, diagnosis medis, dan kendaraan otonom (Elbeltagi et al., 2022) (Jabbari and Bae, 2018) (Kim and Singh, 2015) (Obasi et al., 2020) (Suhartanto et al., 2021) (Toth, 2009) (Hinton et al., 2006) (LeCun et al., 2015) (Rumelhart et al., 1986) (Schmidhuber, 2015).

Tujuan dari penelitian ini adalah 1) melakukan kalibrasi dan validasi data TRMM dengan membandingkannya terhadap pengamatan lapangan, 2) mengembangkan model prototipe alih ragam hujan ke debit dengan JST untuk memprediksi hubungan nonlinier kompleks antara hujan dan debit. Model ini meningkatkan akurasi estimasi debit di sungai dengan mempertimbangkan berbagai variabel di Sub DAS Lesti.

2. Metode Penelitian

Penelitian dilaksanakan di Sub DAS Lesti, secara geografis terletak antara $112^{\circ}41'7,10''$ – $112^{\circ}55'14,50''$ Bujur Timur dan $8^{\circ}3'1,81''$ – $8^{\circ}18'9,35''$ Lintang Selatan. Sub DAS Lesti berada di 5 kecamatan di Kabupaten Malang yaitu Poncokusumo, Turen, Wajak, Tirtoyudo, dan Dampit. Daerah hulu sungai berada di bagian Timur Kabupaten Malang yang mempunyai kontribusi debit sungai yang sebagian besar ke daerah hilir Kabupaten Malang, yaitu di Waduk Sengguruh dan Waduk Sutami seperti yang diperlihatkan pada Gambar 1.



Gambar 1 Peta lokasi penelitian di Sub DAS Lesti

2.1 Pengumpulan Data

Pengumpulan data merupakan proses untuk memperoleh data yang dibutuhkan dalam penelitian, yaitu data-data sekunder berupa data hujan pos lapangan periode 2000-2019 dari Perum Jasa Tirta I, data hujan satelit TRMM periode 2000-2019 dari NASA, data debit pos duga air periode 2007-2019 dari Perum Jasa Tirta I, peta topografi menggunakan data Digital Elevation Model (DEM) dari USGS, peta penggunaan lahan diperoleh dari interpretasi citra satelit Landsat 7-8-9 periode 2007-2019 dari USGS.

2.2 Kalibrasi dan Validasi TRMM

Tahap kalibrasi dan validasi dilakukan dengan menggunakan persamaan regresi sederhana (Soewarno, 1995):

- Membagi data hujan satelit TRMM dan hujan pos dengan pembagian 19 tahun data (data tahun 2000-2019) untuk kalibrasi dan 1 tahun untuk validasi (data tahun 2019).
- Mengkalibrasi data hujan satelit TRMM dan hujan pos selama 19 tahun dengan membuat grafik *scatterplot* tersebut.
- Menampilkan persamaan regresi yang dibentuk oleh hubungan antara data hujan satelit TRMM dan hujan pos.
- Memvalidasi data hujan satelit TRMM dan hujan pos selama 1 tahun menggunakan persamaan regresi dari grafik *scatterplot*.

$$Y = a_1X + b_1 \quad (1)$$

$$Y = b_0 + b_1X + b_2X^2 + b_3X^3 + \dots + b_mX^m \quad (2)$$

Keterangan:

Y = persamaan garis lurus Y atas X

X = variabel bebas

a = koefisien regresi merupakan koefisien arah dari garis regresi.

b = koefisien yang merupakan titik potong dari garis regresi.

Nash-Sutcliffe Efficiency (NSE) merupakan fungsi objektif yang dapat mengetahui sejauh mana kemiripan dari pemodelan data hujan yang di uji terhadap data hujan pengamatan. Nilai NSE memiliki rentang antara 0 sampai dengan 1 dimana nilai NSE mendekati 1 mengindikasikan hasil simulasi yang semakin baik terhadap nilai pengamatan (Moriassi et al., 2007).

$$NSE = \frac{\sum_{i=1}^n (Q_{obs} - Q_{sim})^2}{\sum_{i=1}^n (Q_{obs} - RQ_{obs})^2} \quad (3)$$

Keterangan:

NSE = *Nash-Sutcliffe Efficiency*

Q_{sim} = Hujan simulasi (mm)

Q_{obs} = Hujan pencatatan (mm)

RQ_{obs} = Rata-rata hujan pencatatan (mm)

n = Jumlah data

Tabel 1 Kriteria nilai NSE

No.	Nilai NSE	Kriteria model
1	$NSE \leq 0,50$	Tidak Memuaskan
2	$0,50 < NSE \leq 0,65$	Memuaskan
3	$0,65 < NSE \leq 0,75$	Baik
4	$0,75 < NSE \leq 1,00$	Sangat Baik

Sumber: (Moriassi et al., 2007).

Koefisien korelasi bertujuan untuk menilai berapa kuat atau derajat kedekatan, dari suatu hubungan yang terjadi antar variabel. Korelasi merupakan salah satu cara analisis dalam statistik yang dimanfaatkan untuk memperoleh relasi antara dua variabel yang sifatnya kuantitatif. Korelasi sederhana adalah suatu analisis statistik yang dimanfaatkan untuk menilai kekuatan relasi antara dua variabel serta untuk memperoleh bentuk hubungan keduanya dengan hasil yang

bersifat kuantitatif. Kekuatan relasi antara dua variabel yang dimaksud adalah apakah relasi tersebut sangat kuat, sedang ataupun sangat rendah. Sedangkan bentuk relasinya adalah apakah bentuk korelasinya linier positif atau linier negatif (Sugiyono, 2007).

$$R = \frac{n \sum_{i=1}^N X_i Y_i - \sum_{i=1}^N X_i \times \sum_{i=1}^N Y_i}{\sqrt{n \sum_{i=1}^N X_i^2 - (\sum_{i=1}^N X_i)^2} \sqrt{n \sum_{i=1}^N Y_i^2 - (\sum_{i=1}^N Y_i)^2}} \quad (4)$$

Keterangan:

R = Koefisien korelasi

X_i = Data observasi (data sebenarnya)

Y_i = Data perkiraan (data hasil estimasi)

n = Jumlah data

Tabel 2 Kriteria nilai R


No.	Nilai R	Kriteria korelasi
1	0,00 – 0,199	Sangat Rendah
2	0,20 – 0,399	Rendah
3	0,40 – 0,599	Sedang
4	0,60 – 0,799	Kuat
5	0,80 – 1,000	Sangat kuat

Sumber: (Sugiyono, 2007)

2.3 Jaringan Syaraf Tiruan (JST)

Arsitektur jaringan akan menemukan keberhasilan target yang akan dicapai, karena tidak setiap permasalahan bisa diselesaikan dengan arsitektur jaringan yang sama. Sebelum mengenal arsitektur jaringan yang umum digunakan pada JST, berikut adalah lapisan penyusun yang terdapat pada JST (Hermawan, 2006):

- Lapisan Input (*input layer*).
- Dalam lapisan input terdapat unit input atau masukan yang berfungsi menerima pola masukan dari luar yang merupakan gambaran dari suatu permasalahan yang akan diselesaikan melalui JST.
- Lapisan Tersembunyi (*hidden layer*).
- Pada lapisan tersembunyi terdapat unit-unit tersembunyi, yang nilai output tidak dapat diperlihatkan secara langsung, maka dinamakan tersembunyi.
- Lapisan Output (*output layer*).



Gambar 2 Contoh arsitektur jaringan *feedforward*

Sumber: (Jabbari and Bae, 2018)

JST dicirikan oleh proses simulasi dan respons untuk mempelajari respons yang benar untuk setiap masukan melalui pelatihan. Fungsi umum antara input dan output disebut fungsi transfer (aktivasi), yang dapat berupa fungsi linier atau nonlinier. Dalam penelitian ini, fungsi sigmoid nonlinier diterapkan untuk jaringan saraf. Fungsi transfer mengubah penjumlahan bobot (w) dan bias masukan (x) dan (b) menjadi vektor keluaran dengan persamaan berikut (Jabbari and Bae, 2018):

$$y = f(\sum w \times x + b) \quad (5)$$

Masukan dikalikan dengan bobot dan kemudian diumpankan ke lapisan tersembunyi pertama. Bobot dapat dipilih dengan meminimalkan fungsi kesalahan berikut:

$$E = \frac{1}{2} [Tar_j - O_j(w, x)]^2 \quad (6)$$

Di mana O_j adalah keluaran dari lapisan keluaran dan Tar_j adalah target yang sesuai. Prosedur penyesuaian bobot masukan disebut pelatihan (pembelajaran). Dalam penelitian ini, Levenberg-Marquardt (trainlm) dipilih sebagai fungsi pelatihan dan *back propagation generalized delta rule* (BPGDR), diterapkan sebagai algoritma pelatihan yang meminimalkan fungsi kesalahan berdasarkan perbedaan antara keluaran yang dimodelkan dan yang diinginkan. Rumusan BPGDR dapat diringkas dalam dua bagian sebagai berikut (Jabbari and Bae, 2018):

- a. Untuk bobot keluaran, yang dihubungkan ke node keluaran:

$$\Delta w_{kj} = \eta \frac{\partial E}{\partial w_{kj}} \quad (7)$$


- b. Untuk bobot tersembunyi, yang terhubung ke node tersembunyi:

$$\Delta w_{ji} = \eta \frac{\partial E}{\partial w_{ji}} \quad (8)$$


di mana w_{kj} dan w_{ji} masing-masing adalah bobot keluaran dan bobot tersembunyi, E adalah fungsi kesalahan, dan η adalah kecepatan pembelajaran.

3. Hasil dan Pembahasan


Data satelit TRMM merupakan data hujan yang diperkirakan sebelum hujan tersebut turun ke bumi sedangkan data hujan pos merupakan hujan yang telah jatuh dan terukur di permukaan bumi. Data satelit TRMM dianggap sebagai data model sedangkan data hujan pos dianggap sebagai data observasi.




Gambar 3 Scatterplot dengan fungsi linear



Gambar 4 Scatterplot dengan fungsi *linear intercept*



Gambar 5 Scatterplot dengan fungsi *polynomial*



Gambar 6 Scatterplot dengan fungsi *polynomial intercept*

Dari gambar *scatterplot* di atas maka proses kalibrasi dengan menggunakan persamaan *linear*, *linear intercept*, *polynomial* dan *polynomial intercept* diperoleh koefisien korelasi seperti pada tabel berikut.

Tabel 3 Hasil kalibrasi data TRMM dengan persamaan regresi

No	Jenis Persamaan	Persamaan y	Nilai R
1	Persamaan <i>Linear</i>	$y = 0,9195x - 0,3107$	R = 0,867
2	Persamaan <i>Linear Intercept</i>	$y = 0,9184x$	R = 0,942
3	Persamaan <i>Polynomial</i>	$y = -0,0002x^2 + 0,9867x - 3,2617$	R = 0,867
4	Persamaan <i>Polynomial Intercept</i>	$y = -0,0001x^2 + 0,9575x$	R = 0,867

Dari tabel 3 dipergunakan persamaan *linear intercept* $y = 0,9184x$ dengan koefisien R = 0,942 untuk proses kalibrasi. Hasil validasi menggunakan data hujan wilayah dengan data satelit TRMM terkoreksi seperti pada Tabel 4.

Tabel 4 Hasil validasi data satelit TRMM terkoreksi

Jumlah Tahun		NSE		Koefisien Korelasi	
Kalibrasi	Validasi	Nilai	Kriteria	Nilai	Kriteria
19	1	0,97	Sangat Baik	1,00	Sangat Kuat

Hasil validasi data satelit TRMM terkoreksi menunjukkan nilai NSE = 0,97 (sangat baik), sedangkan untuk nilai koefisien korelasi R = 1,00 (sangat kuat). Hasil validasi ini menunjukkan hubungan yang sangat baik dan sangat kuat antara data satelit TRMM dan data hujan wilayah, sehingga data satelit TRMM dapat diandalkan dan akurat untuk dipergunakan dalam proses pemodelan dengan JST.

Secara keseluruhan parameter jumlah hujan, hari hujan, evaporasi, dan penggunaan lahan berpengaruh terhadap debit aliran bulanan yang terjadi pada Sub DAS Lesti. Berdasarkan hipotesis tersebut, maka dapat dibuat suatu model prototipe alih ragam hujan ke debit sesuai parameter yang ditentukan. Hasil analisis diharapkan dapat ditemukan arsitektur jaringan sehingga dapat menggambarkan pola JST. Pemodelan ini dilakukan untuk delapan parameter sebagai data masukan dan satu parameter sebagai data target seperti Tabel 5.

Tabel 5 Data masukan dan target untuk model prototipe JST

No	Data Masukan	Data Target
1	Jumlah hujan bulanan (mm)	Debit (m ³ /detik)
2	Jumlah hari hujan (hari)	
3	Evaporasi (mm/hari)	
4	Lahan terbuka (ha)	
5	Kawasan terbangun (ha)	
6	Lahan terbuka (ha)	
7	Hutan (ha)	
8	Lain-lain (ha)	

Kemudian melakukan *Train Network* 1 dengan simulasi parameter *Number of Layers* 1 sampai dengan 10, *Number of Neurons* = 10 dan *Transfer Function* = Tansig, maka diperoleh hasil training 1 seperti pada Tabel 6.

Tabel 6 Hasil training 1 menggunakan JST dengan fungsi tansig

Layer	Neuron	Function	Epochs dan Koefisien Korelasi				
			1000	1500	2000	2500	3000
1	10	Tansig	0,91892	0,82829	0,65335	0,78368	0,82081
2	10	Tansig	0,92217	0,93022	0,98517	0,87456	0,80963
3	10	Tansig	-0,22431	0,00000	0,00000	0,09883	-0,17215
4	10	Tansig	-0,05676	0,49308	0,50343	0,57070	0,12089
5	10	Tansig	-0,00346	0,02890	0,60713	0,73621	0,62831
6	10	Tansig	0,18698	0,60013	0,45116	0,84235	0,80440
7	10	Tansig	0,31197	0,45987	0,22964	0,57337	0,59877
8	10	Tansig	0,79750	0,49005	0,52381	0,68116	0,28699
9	10	Tansig	0,71509	0,74899	0,56061	0,88358	0,80479
10	10	Tansig	0,73148	0,14318	0,60223	0,72786	0,62263
Koefisien Korelasi Maksimum			0,92217	0,93022	0,98517	0,88358	0,82081

Hasil training 1 menggunakan JST dengan fungsi tansig diperoleh koefisien korelasi maksimum $R = 0,98517$ (sangat kuat) dengan skema arsitektur jaringan 8-2-10-1 (terdiri dari 8 lapisan masukan, 2 lapisan tersembunyi, 10 neuron, 1 lapisan keluaran) pada 2000 epochs.

Kemudian melakukan *Train Network* 2 dengan simulasi parameter *Number of Layers* 1 sampai dengan 10, *Number of Neurons* = 10 dan *Transfer Function* = Logsig, maka diperoleh hasil training 2 seperti pada Tabel 7.

Tabel 7 Hasil training 2 menggunakan JST dengan fungsi logsig

Layer	Neuron	Function	Epochs dan Koefisien Korelasi				
			1000	1500	2000	2500	3000
1	10	Logsig	0,15348	0,69148	0,74833	0,92259	0,93425
2	10	Logsig	0,50344	0,82810	0,75329	0,96520	0,98895
3	10	Logsig	0,34794	0,73785	0,47664	0,62599	0,69655
4	10	Logsig	-0,21848	0,13741	0,35391	0,43632	0,96643
5	10	Logsig	-0,08674	0,97988	0,88277	0,94155	0,39883
6	10	Logsig	0,15348	0,69148	0,74833	0,92259	0,93425
7	10	Logsig	0,50344	0,82810	0,75329	0,96520	0,83785
8	10	Logsig	0,01699	0,00000	0,00000	0,00000	0,00000
9	10	Logsig	0,49457	0,56091	0,51081	0,88698	0,32569
10	10	Logsig	0,06344	0,41524	0,59861	0,86726	0,61085
Koefisien Korelasi Maksimum			0,50344	0,97988	0,88277	0,96520	0,98895

Hasil training 2 menggunakan JST dengan fungsi logsig diperoleh koefisien korelasi maksimum $R = 0,98895$ (sangat kuat) dengan skema arsitektur jaringan 8-

2-10-1 (terdiri dari 8 lapisan masukan, 2 lapisan tersembunyi, 10 neuron, 1 lapisan keluaran) pada 3000 epochs.


Kemudian melakukan *Train Network* 3 dengan simulasi parameter *Number of Layers* 1 sampai dengan 10, *Number of Neurons* = 10 dan *Transfer Function* = Purelin, maka diperoleh hasil training 3 seperti pada Tabel 8.

Tabel 8 Hasil training 3 menggunakan JST dengan fungsi purelin

Layer	Neuron	Function	Epochs dan Koefisien Korelasi				
			1000	1500	2000	2500	3000
1	10	Purelin	0,68121	0,59376	0,52740	0,63471	0,47174
2	10	Purelin	0,04281	0,49691	0,57491	0,68292	0,08992
3	10	Purelin	0,31057	0,41522	0,77057	0,35311	0,47132
4	10	Purelin	0,40113	0,32405	0,62629	0,58951	0,54885
5	10	Purelin	0,62193	0,83250	0,52457	0,49282	0,76042
6	10	Purelin	0,50340	0,43566	0,67896	0,85330	0,70814
7	10	Purelin	0,64710	0,66179	0,87257	0,54738	0,42095
8	10	Purelin	0,67511	0,18082	0,57350	0,54646	0,71014
9	10	Purelin	0,48108	0,65788	0,35863	0,56785	0,40963
10	10	Purelin	0,44640	0,19814	0,43782	0,74600	0,83329
Koefisien Korelasi Maksimum			0,68121	0,83250	0,87257	0,85330	0,83329

Hasil training 3 menggunakan JST dengan fungsi purelin diperoleh koefisien korelasi maksimum $R = 0,87257$ (sangat kuat) dengan skema arsitektur jaringan 8-7-10-1 (terdiri dari 8 lapisan masukan, 7 lapisan tersembunyi, 10 neuron, 1 lapisan keluaran) pada 2000 epochs.

Dari hasil training 1, 2, 3, maka diperoleh hasil model prototipe terbaik untuk alih ragam hujan ke debit menggunakan JST berdasarkan koefisien korelasi yang paling maksimum $R = 0,98895$ (sangat kuat) dengan skema arsitektur jaringan 8-2-10-1 (terdiri dari 8 lapisan masukan, 2 lapisan tersembunyi, 10 neuron, 1 lapisan keluaran) seperti pada Gambar 7.



Gambar 7 Arsitektur jaringan model prototipe menggunakan JST

4. Kesimpulan dan Saran

4.1 Kesimpulan

Berdasarkan hasil analisis dan pembahasan maka diperoleh kesimpulan yaitu hasil kalibrasi dan validasi data satelit TRMM menghasilkan nilai NSE sebesar 0,97 (sangat baik) dan koefisien korelasi sebesar 1,00 (sangat kuat). Sedangkan hasil training terbaik model prototipe yang mengkonversi data hujan menjadi debit menggunakan JST dengan fungsi transfer logsig, menghasilkan nilai koefisien korelasi $R = 0,98897$ (sangat kuat) dengan skema arsitektur jaringan 8-2-10-1 (terdiri dari delapan lapisan masukan, dua lapisan tersembunyi, sepuluh neuron, satu lapisan keluaran) pada 3000 epochs.

4.2 Saran

Penelitian ini menggunakan parameter hujan dan DAS, sehingga diperlukan penelitian dengan parameter dan karakteristik DAS yang berbeda untuk mendapatkan hasil yang lebih bervariasi. Diperlukan penelitian lebih lanjut untuk pengembangan model kecerdasan buatan (*artificial intelligence*) yang lain.

Ucapan Terima Kasih

Ucapan terima kasih kepada Badan Penelitian dan Pengabdian Kepada Masyarakat di Fakultas Teknik Universitas Brawijaya (BPPM FTUB) yang telah memberikan dana untuk penelitian ini.

Daftar Kepustakaan

- Darmawan, A.A., Suhardjono, Bisri, M., Suhartanto, E., 2021. Assessment of Spatial Changes of LULC Dynamics, Using Multi-Temporal Landsat Data (Case Study: Lesti Sub Watershed, Malang Regency, Indonesia). IOP Conf. Ser. Earth Environ. Sci. 930, 1–7.
- Elbeltagi, A., Nagy, A., Mohammed, S., Pande, C.B., Kumar, M., Bhat, S.A., Zsembeli, J., Huzsvai, L., Tamás, J., Kovács, E., Harsányi, E., Juhász, C., 2022. Combination of Limited Meteorological Data for Predicting Reference Crop Evapotranspiration Using Artificial Neural Network Method. *Agronomy* 12, 1–18. <https://doi.org/10.3390/agronomy12020516>.
- Hermawan, A., 2006. Jaringan Saraf Tiruan: Teori dan Aplikasi, Penerbit Andi.
- Hinton, G.E., Osindero, S., Teh, Y.-W., 2006. A Fast Learning Algorithm for Deep Belief Nets. *Neural Comput.* 18, 1527–1554. <https://doi.org/10.7763/ijesd.2010.v1.67>.
- Huffman, G.J., Adler, R.F., Bolvin, D.T., Gu, G., Nelkin, E.J., Bowman, K.P., Hong, Y., Stocker, E.F., Wolff, D.B., 2007. The TRMM Multi-satellite Precipitation Analysis (TMPA): Quasi-Global, Multiyear, Combined-Sensor Precipitation Estimates at Fine Scales. *J. Hydrometeorol.* 8, 38–55. <https://doi.org/10.1175/JHM560.1>.
- Iguchi, T., Kozu, T., Meneghini, R., Awaka, J., Okamoto, K.I., 2000. Rain-Profiling Algorithm for the TRMM Precipitation Radar. *J. Appl. Meteorol.* 39, 2038–2052. [https://doi.org/10.1175/1520-0450\(2001\)040<2038:rpaftt>2.0.co;2](https://doi.org/10.1175/1520-0450(2001)040<2038:rpaftt>2.0.co;2).

- Jabbari, A., Bae, D.H., 2018. Application of Artificial Neural Networks for Accuracy Enhancements of Real-Time Flood Forecasting in The Imjin Basin. *Water (Switzerland)* 10, 1–20. <https://doi.org/10.3390/w10111626>.
- Kim, S., Singh, V.P., 2015. Spatial Disaggregation of Areal Rainfall Using Two Different Artificial Neural Networks Models. *Water (Switzerland)* 7, 2707–2727. <https://doi.org/10.3390/w7062707>.
- Kummerow, C., Simpson, J., Thiele, O., Barnes, W., Chang, A.T.C., Stocker, E., Adler, R.F., Hou, A., Kakar, R., Wentz, F., Ashcroft, P., Kozu, T., Hong, Y., Okamoto, K., Iguchi, T., Kuroiwa, H., Im, E., Haddad, Z., Huffman, G., Ferrier, B., Olson, W.S., Zipser, E., Smith, E.A., Wilheit, T.T., North, G., Krishnamurti, T., Nakamura, K., 2000. The Status of the Tropical Rainfall Measuring Mission (TRMM) after Two Years in Orbit. *J. Appl. Meteorol.* 39, 1965–1982. [https://doi.org/10.1175/1520-0450\(2001\)040<1965:tsottr>2.0.co;2](https://doi.org/10.1175/1520-0450(2001)040<1965:tsottr>2.0.co;2).
- LeCun, Y., Bengio, Y., Hinton, G., 2015. Deep learning. *Nature* 521, 436–444. <https://doi.org/10.1038/nature14539>.
- Moriassi, D.N., Arnold, J.G., Van Liew, M.W., Bingner, R.L., Harmel, R.D., Veith, T.L., 2007. Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations. *Trans. ASABE* 50, 885–900. <https://doi.org/10.13031/2013.23153>.
- Nogueira, S.M.C., Moreira, M.A., Volpato, M.M.L., 2018. Evaluating Precipitation Estimates from Eta, TRMM, and CHIRPS Data in The South-Southeast Region of Minas Gerais State-Brazil. *Remote Sens.* 10, 1–16. <https://doi.org/10.3390/rs10020313>.
- Obasi, A.A., Ogbu, K.N., Orakwe, L.C., Ahaneku, I.E., 2020. Rainfall-River Discharge Modelling for Flood Forecasting Using Artificial Neural Network (ANN). *J. Water L. Dev.* 44, 98–105. <https://doi.org/10.24425/jwld.2019.127050>.
- Omosho, T. V., Mandeep, J.S., Abdullah, M., Adediji, A.T., 2013. Distribution of One-Minute Rain Rate in Malaysia Derived from TRMM Satellite Data. *Ann. Geophys.* 31, 2013–2022. <https://doi.org/10.5194/angeo-31-2013-2013>.
- Pakoksung, K., Koontanakulvong, S., Sriaiyawat, A., 2012. Satellite Data Application for Flood Simulation, in: PAWEES 2012 International Conference. pp. 1–7.
- Pratiwi, D.W., Sujono, J., Rahardjo, A.P., 2017. Evaluasi Data Hujan Satelit Untuk Prediksi Data Hujan Pengamatan Menggunakan Cross Correlation. *J. Semin. Nas. Sains dan Teknol. UNJ* 025, 1–11.
- Rumelhart, D.E., Hinton, G.E., Williams, R.J., 1986. Learning Representations by Back-Propagating Errors. *Nature* 323, 533–536. <https://doi.org/10.7551/mitpress/1888.003.0013>.
- Schmidhuber, J., 2015. Deep Learning in neural networks: An overview. *Neural Networks* 61, 85–117. <https://doi.org/10.1016/j.neunet.2014.09.003>.
- Sekaranom, A.B., Nurjani, E., Hadi, M.P., Marfai, M.A., 2018. Comparison of TRMM Precipitation Satellite Data over Central Java Region - Indonesia. *Quaest. Geogr.* 37, 97–114. <https://doi.org/10.2478/quageo-2018-0028>.
- Simpson, J., Adler, R.F., North, G.R., 1988. A Proposed Tropical Rainfall Measuring Mission (TRMM) Satellite. *Bull. Am. Meteorol. Soc.* 69, 278–295.

- [https://doi.org/10.1175/1520-0477\(1988\)069<0278:aptrmm>2.0.co;2](https://doi.org/10.1175/1520-0477(1988)069<0278:aptrmm>2.0.co;2).
- Soewarno, 1995. Hidrologi: Aplikasi Metode Statistik Untuk Analisa Data Jilid 2, Penerbit Nova.
- Sugiyono, 2007. Statistika Untuk Penelitian, Alfabeta.
- Suhartanto, E., Wahyuni, S., Mufadhal, K.M., 2021. Estimation of Rainfall from Climatology Data Using Artificial Neural Networks in Palembang City South Sumatera, in: IOP Conference Series: Earth and Environmental Science. pp. 1–8. <https://doi.org/10.1088/1755-1315/930/1/012062>.
- Suharyanto, A., Suhartanto, E., Pudyono, 2013. The Use of Satellite Remote Sensing Data and Geographic Information Systems on Critical Land Analysis. *Agrivita* 35, 119–126. <https://doi.org/10.17503/Agrivita-2013-35-2-p119-126>.
- Syaifullah, M.D., 2014. Validasi Data TRMM Terhadap Data Curah Hujan Aktual di Tiga DAS di Indonesia. *J. Meteorol. dan Geofis.* 15, 109–118.
- Tama, D.R., Limantara, L.M., Suhartanto, E., Devia, Y.P., 2023. The Reliability of W-flow Run-off-Rainfall Model in Predicting Rainfall to the Discharge. *Civ. Eng. J.* 9, 1768–1778. <https://doi.org/10.28991/CEJ-2023-09-07-015>.
- Tan, M.L., Duan, Z., 2017. Assessment of GPM and TRMM Precipitation Products over Singapore. *Remote Sens.* 9, 1–16. <https://doi.org/10.3390/rs9070720>.
- Tarnavsky, E., Mulligan, M., Ouassar, M., Faye, A., Black, E., 2013. Dynamic Hydrological Modeling in Drylands with TRMM: Based Rainfall. *Remote Sens.* 5, 6691–6716. <https://doi.org/10.3390/rs5126691>.
- Toth, E., 2009. Classification of Hydro-Meteorological Conditions and Multiple Artificial Neural Networks for Streamflow Forecasting. *Hydrol. Earth Syst. Sci.* 13, 1555–1566. <https://doi.org/10.5194/hess-13-1555-2009>.
- Worqlul, A.W., Maathuis, B., Adem, A.A., Demissie, S.S., Langan, S., Steenhuis, T.S., 2014. Comparison of Rainfall Estimations by TRMM 3B42, MPEG, and CFSR with Ground-Observed Data for The Lake Tana Basin in Ethiopia. *Hydrol. Earth Syst. Sci.* 18, 4871–4881. <https://doi.org/10.5194/hess-18-4871-2014>.
- Yuan, F., Zhang, L., Soe, K.M.W., Ren, L., Zhao, C., Zhu, Y., Jiang, S., Liu, Y., 2019. Applications of TRMM- and GPM-Era Multiple-Satellite Precipitation Products for Flood Simulations at Sub-Daily Scales in a Sparsely Gauged Watershed in Myanmar. *Remote Sens.* 11, 1–31. <https://doi.org/10.3390/rs11020140>.
- Yuan, F., Zhang, L., Wah Win, K.W., Ren, L., Zhao, C., Zhu, Y., Jiang, S., Liu, Y., 2017. Assessment of GPM and TRMM Multi-Satellite Precipitation Products in Streamflow Simulations in a Data Sparse Mountainous Watershed in Myanmar. *Remote Sens.* 9, 1–23. <https://doi.org/10.3390/rs9030302>.