

**ESTIMASI CURAH HUJAN BULANAN MENGGUNAKAN
MULTI LAYER PERCEPTRON DI KOTA TANGERANG
SELATAN**
MONTHLY RAINFALL ESTIMATION USING MULTI-LAYER
PERCEPTRON IN SOUTH TANGERANG CITY

Naufal Ananda^{1*}, dan G.A. Monang Lumban Gao²

^{1,2)} Balai Besar Meteorologi Klimatologi dan Geofisika Wilayah II, Jalan H. Abdul Ghani
No. 05, Kota Tangerang Selatan, 15412

*Email: naufal.ananda17@gmail.com

ABSTRAK

Curah hujan merupakan salah satu parameter meteorologi dan klimatologi yang informasinya wajib disebarluaskan kepada masyarakat dalam kehidupan sehari-hari. Informasi curah hujan memiliki peranan penting dalam berbagai sektor kehidupan masyarakat. Dalam bidang pertanian, jumlah curah hujan memiliki peranan penting dalam penentuan musim tanam, sehingga hal ini dapat mencegah potensi gagal panen. Dalam bidang kebencanaan, Kota Tangerang Selatan selama periode 2016-2021 mengalami kejadian banjir, tanah longsor, dan kekeringan yang sangat erat kaitannya dengan informasi curah hujan karena kejadian bencana tersebut salah satunya merupakan dampak dari banyak atau sedikitnya curah hujan pada suatu wilayah. Oleh karena itu, pentingnya informasi prediksi curah hujan dapat meningkatkan layanan informasi meteorologi dan klimatologi di berbagai sektor. Namun, saat ini masih sulitnya masyarakat maupun stakeholder untuk mendapatkan prediksi curah hujan bulanan dengan akurasi tinggi dalam jangka panjang, menjadi latar belakang dilakukannya penelitian ini. Pada penelitian ini dirancang estimasi curah hujan bulanan menggunakan metode Multi Layer Perceptron (MLP). Data yang digunakan merupakan data hujan bulanan Climate Hazards Group InfraRed Precipitations (CHIRPS) selama 42 tahun (periode tahun 1981 – 2022) dengan batas koordinat sesuai lokasi penelitian yaitu Kota Tangerang Selatan, yang berada di antara 106,625° – 106,825° BT dan 6,4° – 6,2° LS sebanyak 16 grid dengan resolusi tiap grid 0,05°. Estimasi curah hujan bulanan menggunakan metode MLP menghasilkan nilai rata-rata RMSE sebesar 90,19 dan MAPE sebesar 40,55.

Kata kunci: Estimasi, Curah Hujan, Multi-Layer Perceptron, CHIRPS, Spasial

ABSTRACT

Rainfall information plays a crucial role in daily life. In agriculture, the amount of rainfall is essential for determining the planting season, thereby preventing potential crop failure. In terms of disasters, South Tangerang City experienced floods, landslides, and droughts during the 2016-2021 period. Therefore, accurate rainfall prediction information is vital for enhancing meteorological and climatological services across different sectors. However, it remains challenging for the community and stakeholders to obtain long-term monthly rainfall predictions with high accuracy. In this research, monthly rainfall estimation is conducted using a Multi-Layer Perceptron (MLP). The data used includes monthly rainfall data from the Climate Hazards Group InfraRed Precipitation (CHIRPS) dataset, spanning 42 years (1981-2022). The study focuses on South Tangerang City, located between 106.625° - 106.825° East and 6.4° - 6.2° South, covering 16 grids with a resolution of 0.05° per grid. The monthly rainfall prediction using MLP resulted in an RMSE value of 90.19 and a MAPE of 40.55.

Keywords: estimation, rainfall, Multi-Layer Perceptron, CHIRPS, Spatial

1. Pendahuluan

Kebutuhan informasi prediksi curah hujan oleh masyarakat luas terutama untuk instansi terkait maupun *stakeholder* pengambil keputusan di berbagai sektoral seperti pertanian, pembangunan infrastruktur, serta kebencanaan, seiring waktu mengalami peningkatan. Dalam bidang pertanian, jumlah curah hujan memiliki peranan penting dalam penentuan musim tanam [1], sehingga hal ini dapat mencegah potensi gagal panen.

Bencana banjir dan tanah longsor dipicu oleh adanya jumlah curah hujan tinggi dapat menimbulkan kerugian [2]. Informasi prediksi curah hujan yang lebih panjang rentang waktunya ke depan, lebih akurat, dan cepat dalam diseminasinya menjadi tantangan baru dalam memenuhi peningkatan kebutuhan informasi tersebut. Perancangan sistem estimasi curah hujan bulanan berbasis *deep learning* diharapkan dapat menjadi salah satu daya dukung dalam peningkatan pelayanan terkait informasi meteorologi dan klimatologi [3].

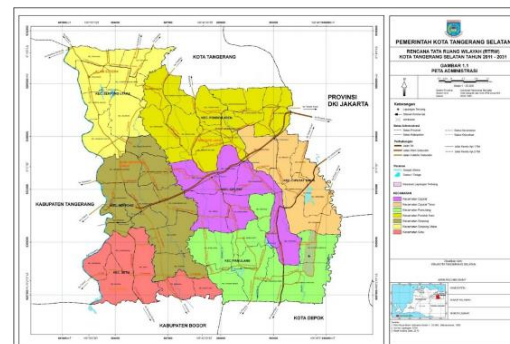
Informasi prakiraan curah hujan bulanan dalam jangka waktu yang panjang ke depan sudah menjadi kebutuhan besar bagi institusi dan masyarakat di berbagai sektor yang pada umumnya memerlukan informasi prakiraan curah hujan bulanan lebih dari 6 (enam) bulan ke depan seperti 1 (satu) tahun atau 5 (lima) tahun ke depan, salah satunya sebagai informasi yang mendukung rencana strategis. Informasi prakiraan curah hujan bulanan juga dituntut memiliki akurasi yang cukup tinggi, dimana saat ini akurasi hasil prakiraan curah hujan BMKG berkisar antara 61–87 % (data empiris BMKG) [4], sehingga masih ada ruang untuk peningkatan akurasi dengan jangkauan kisaran tingkat akurasi hasil prediksi yang lebih baik.

Penerapan prediksi curah hujan bulanan pada tahun 2019 di Kabupaten Majalengka telah dilakukan menggunakan metode persamaan regresi linier berganda, namun hasil akurasi masih belum memadai [15]. Sehingga pada penelitian ini meneliti terkait penggunaan metode Multi Layer Perceptron dalam mengestimasi curah hujan bulanan di Banten, sehingga dapat meningkatkan akurasi dan dapat dimanfaatkan dalam rangka melakukan perencanaan kegiatan di masa depan.

2. Metode Penelitian

2.1. Lokasi Penelitian

Penelitian berlokasi di Kota Tangerang Selatan Provinsi Banten. Gambar 1 Menunjukkan Kota Tangerang Selatan terletak di bagian timur Provinsi Banten yang merupakan pemekaran diri Kabupaten Tangerang. Secara administratif, wilayah Kota Tangerang Selatan terdiri dari 7 (tujuh) kecamatan antara lain: kecamatan Ciputat, Ciputat Timur, Pamulang, Pondok Aren, Serpong, Serpong Utara, dan Setu; serta 54 kelurahan.



Gambar 1. Peta Kota Tangerang Selatan (Sumber: Pemerintah Kota Tangerang Selatan).

Berdasarkan letak geografis, terletak pada koordinat $106^{\circ} 38' - 106^{\circ} 47'$ Bujur Timur dan $06^{\circ} 13'30'' - 06^{\circ} 22'00''$ Lintang Selatan, dengan batas wilayah antara lain: di sebelah utara

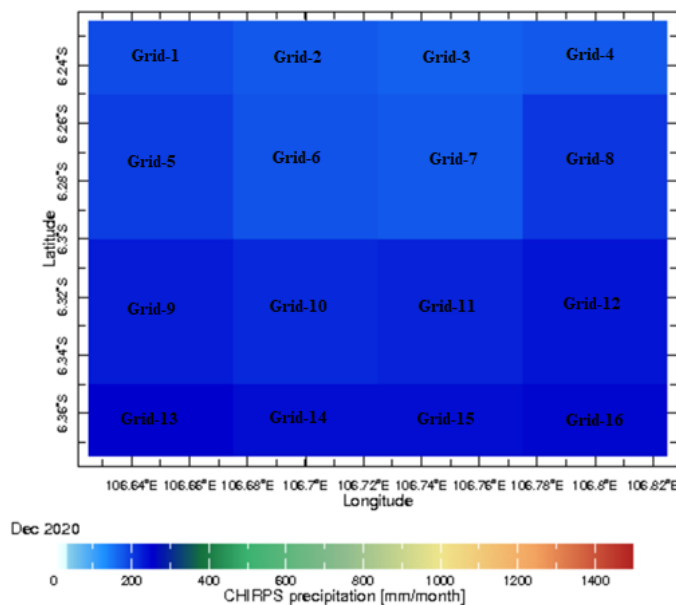
berbatasan dengan Kota Tangerang, di sebelah timur berbatasan dengan Provinsi DKI Jakarta, di sebelah selatan berbatasan dengan Kabupaten Bogor dan Kota Depok Provinsi Jawa Barat, serta di sebelah barat berbatasan dengan Kabupaten Tangerang.

2.2. Data Penelitian

Penelitian ini menggunakan data sekunder berupa data curah hujan bulanan *Climate Hazards Group InfraRed Precipitations* (CHIRPS) selama 42 tahun (tahun 1981–2022) dengan batas koordinat sesuai lokasi penelitian yaitu Kota Tangerang Selatan, antara $106,625^{\circ}$ – $106,825^{\circ}$ BT dan $6,4^{\circ}$ – $6,2^{\circ}$ LS sebanyak 16

grid seperti terlihat pada Gambar 2. Data diunduh melalui IRI *Data Library*, dengan alamat *website* <http://iridl.ldeo.columbia.edu/SOURCES/.UCSB/.CHIRPS/.v2p0/.monthly/.global/.precipitation/>.


Data curah hujan bulanan CHIRPS merupakan data reanalisis, gabungan data curah hujan stasiun pengamatan/observasi dan data curah hujan yang berasal dari hasil estimasi satelit yang mencakup hampir seluruh daratan di bumi (50° LU – 50° LS) serta tersedia dalam skala waktu harian, 5 harian/pentad, dan bulanan dari tahun 1981 hingga saat ini [5]. Data CHIRPS memiliki resolusi spasial cukup tinggi, yaitu $0,05^{\circ}$ atau kurang lebih 5×5 km.



Gambar 2. Data Curah Hujan Bulan Desember 2020 dengan Koordinat Kota Tangerang Selatan dalam Bentuk Grid (Sumber: IRIDL).

2.3. Diagram Alir Penelitian

Diagram alir dalam penelitian ini, secara garis besarnya ditampilkan pada diagram teknis analisis data pada Gambar 3, dimana ada 2 (dua) arsitektur *deep learning* yang akan dibangun untuk melakukan estimasi curah hujan bulanan.



Gambar 3. Diagram Alir Penelitian.

Pada data curah hujan yang dikumpulkan akan dilakukan *preprocessing data* yang meliputi tahap normalisasi dengan fungsi aktivasi, yang dilanjutkan dengan tahap pembagian komposisi atas data pelatihan (*data training*) sebesar 80% dan data pengujian (*data testing*) sebesar 20% [6], [7].

2.4. Pemodelan Multi-Layer Perceptron (MLP)

MLP terdiri dari *input layer*, *hidden layer*, dan *output layer*. MLP memproses input melalui jaringan neuron dengan pembobotan tertentu yang bersifat adaptif. *Output* MLP merupakan kombinasi fungsi aktivasi, pembobotan *input*, dan bias yang secara matematis dinyatakan sebagai berikut [8]:

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (1)$$

Dimana *y* sebagai *output*, *x* sebagai *input*, *w* sebagai bobot, dan *b* sebagai bias. Fungsi tersebut merupakan

bentuk umum dari fungsi aktivasi. Penelitian ini menggunakan fungsi aktivasi non-linier yaitu fungsi sigmoid, tangensial hiperbolik (*tanh*), dan *rectified linear unit* [9]. Fungsi sigmoid, *tanh*, dan *relu* secara berturut-turut dinyatakan sebagai berikut [10]:

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

$$f_t = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3)$$

$$f_r = f(x) = \max(0, x) \quad (4)$$

Fungsi *f_s* merupakan persamaan fungsi sigmoid, fungsi *f_t* merupakan persamaan fungsi tangensial hiperbolik, dan fungsi *f_r* merupakan fungsi *rectified linear unit*. Tahap awal pemodelan MLP yaitu menentukan nilai *hyperparameter* yang sederhana. Tingkat kompleksitas *hyperparameter* menentukan waktu komputasi algoritma. Tabel 1 menunjukkan komposisi *hyperparameter* model MLP [11].

Tabel 1. Komposisi *Hyperparameter* MLP.


Number of Layer	100
Batch Size	6
Epoch	150

3. Hasil dan Pembahasan

Data yang digunakan dalam penelitian ini merupakan data curah hujan yang diperoleh secara spasial. Data tersebut merupakan data reanalisis dalam periode bulanan, sehingga menghasilkan data curah hujan bulanan. Total jumlah data curah hujan bulanan yang tersedia yaitu 504 data. Tabel 2 menunjukkan *time series* data curah hujan bulanan pada masing-masing grid yaitu sebanyak 16 grid.

Tabel 2. Statistika Deskriptif Data Time Series Curah Hujan Bulanan Januari 1981-Desember 2022.

Grid	Curah Hujan			Grid	Curah Hujan		
	Rata-rata (mm)	Max (mm)	Min (mm)		Rata-rata (mm)	Max (mm)	Min (mm)
Grid 1	182.9	696.8	7.0	Grid 9	224.6	744.9	14.8
Grid 2	166.3	744.0	5.8	Grid 10	216.7	729.9	14.3
Grid 3	159.4	791.0	4.8	Grid 11	213.7	747.8	13.7
Grid 4	160.9	823.0	4.4	Grid 12	209.7	767.0	12.0
Grid 5	202.1	678.5	13.6	Grid 13	241.8	779.2	17.9
Grid 6	189.1	710.1	12.8	Grid 14	237.9	756.7	17.2
Grid 7	185.9	796.2	12.6	Grid 15	234.4	750.4	17.4
Grid 8	185.2	799.1	10.2	Grid 16	224.2	752.2	14.5



Gambar 4. Plotting Data Curah Hujan Bulanan Periode 1981-2022.

Pada Gambar 4 menunjukkan adanya kesamaan pola data curah hujan bulanan pada 16 grid di periode 1981 – 2022. Namun, terdapat adanya variabilitas jumlah curah hujan di masing-masing grid, hal ini dipengaruhi adanya pengaruh cuaca

ekstrem, hujan yang tidak merata, dan pengaruh geografis [12].

Pola data curah dapat digunakan dalam meramalkan curah hujan bulanan di periode selanjutnya [13]. Metode yang digunakan dalam penelitian ini menggunakan *Multiple Layer Perceptron* (MLP). Sebelum

dilakukan pemodelan, perlu dilakukan komposisi data *training* dan data uji. Komposisi data yang digunakan dalam penelitian ini yaitu 403 data (80%) data sebagai data *training* dan 101 data (20%) sebagai data uji.

Berdasarkan pengolahan serta analisis statistika menggunakan data *time series* dengan parameter curah hujan rata rata, maksimum, dan minimum pada Tabel 2, didapatkan adanya variasi data dari masing-masing grid, kemudian dilakukan *plotting data* tersebut dalam grafik untuk masing-masing grid pada Gambar 4.

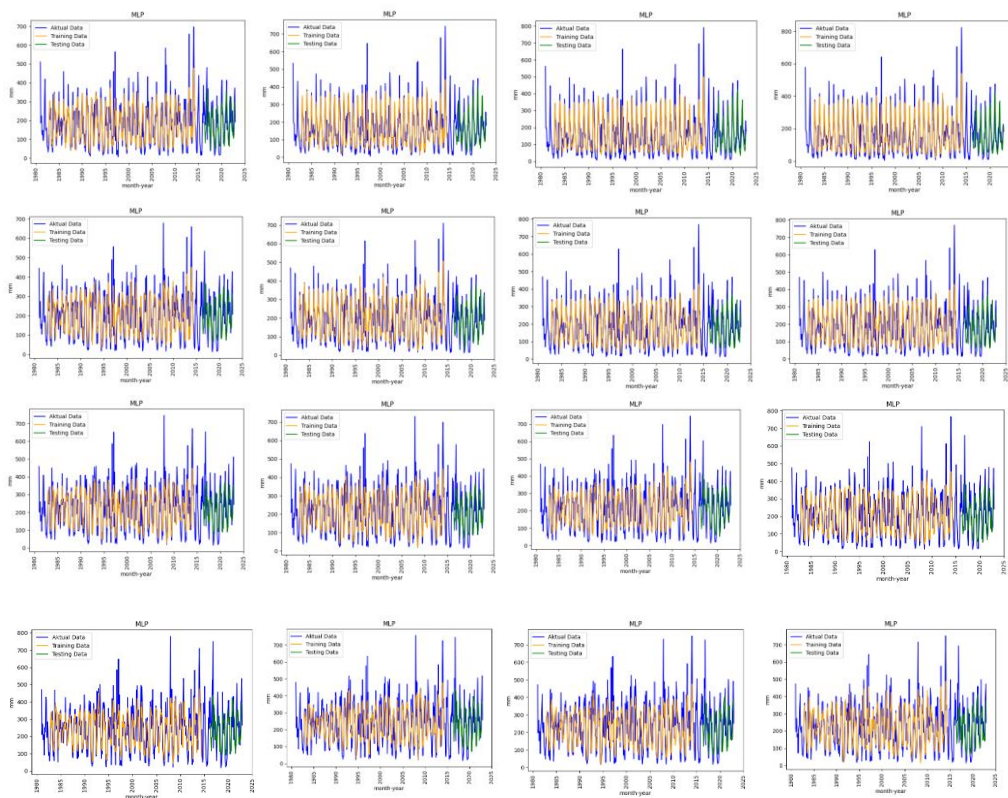
Pada penelitian ini menggunakan fungsi aktivasi relu, *batch size* sebanyak 150 dan jumlah *batch size* sebanyak 6. Komposisi data yang digunakan yaitu 403 data (80%) sebagai *data training* dan 101 data (20%) sebagai *data testing* pada 16 grid data curah bulanan. Tabel 3 merupakan nilai RMSE data *training* dan data *testing*, serta nilai MAPE (*Mean Absolute Percentage Error*) data *testing*.

Tabel 3 menunjukkan hasil uji performa model MLP dalam estimasi curah hujan bulanan pada 16 Grid data di Kota Tangerang Selatan. Nilai rata-

rata RMSE sebesar 86.54 mm dan nilai rata-rata MAPE sebesar 0.79 %. Nilai RMSE tertinggi terjadi pada Grid 1 sebesar 108.63 mm. Nilai MAPE tertinggi sebesar 0.84 % pada Grid 6. Nilai RMSE terendah sebesar 63.91 mm di Grid 4, dan MAPE terendah sebesar 0.74 % di Grid 16.

Tabel 3. Hasil Uji Performa Model MLP.


Grid	RMSE (mm)	MAPE (%)
Grid 1	77.03	0.80
Grid 2	65.22	0.79
Grid 3	64.52	0.79
Grid 4	63.91	0.80
Grid 5	86.58	0.82
Grid 6	72.68	0.84
Grid 7	74.72	0.81
Grid 8	82.09	0.80
Grid 9	97.57	0.76
Grid 10	88.60	0.81
Grid 11	91.29	0.78
Grid 12	97.04	0.79
Grid 13	108.63	0.75
Grid 14	108.05	0.80
Grid 15	106.68	0.75
Grid 16	100.10	0.74
Rata-rata	86.54	0.79
Maks	108.63	0.84
Min	63.91	0.74




Gambar 5. Plotting Performa Hasil Uji MLP.

Gambar 5 merupakan plotting data performa hasil uji menggunakan metode MLP. Pola garis warna biru merupakan hasil data real curah hujan bulanan, garis warna oranye merupakan hasil data training, dan warna hijau sebagai hasil data testing. Secara keseluruhan dari hasil olahan pada grid tersebut menunjukkan pola yang sama. Namun, hasil training dan testing data mempunyai rentang data yang cukup jauh dengan data aktualnya. Hal ini dikarenakan

kejadian hujan ekstrem di periode waktu tertentu dengan akumulasi yang cukup tinggi, sehingga menghasilkan nilai error yang cukup tinggi serta jumlah dataset yang dinilai cukup rendah menghasilkan nilai RMSE yang cukup tinggi. Hasil RMSE yang dihasilkan masih berada dalam rentang toleransi yaitu 0 -508 mm [14], sehingga pemodelan MLP ini digunakan untuk estimator curah hujan bulanan.





Gambar 6. Plotting Hasil Estimasi Curah Hujan Bulanan Menggunakan MLP.

Model estimator curah hujan bulanan yang telah dirancang tahapan selanjutnya, yaitu menunjukkan hasil estimasi curah hujan bulanan di Kota Tangerang Selatan dalam bentuk grafik. Hasil estimasi yang dibuat adalah plot estimasi curah hujan bulanan mulai dari Januari 2023 - Juni 2025 kemudian digabungkan dengan plot aktual data dari Januari 1981 hingga Desember 2022 yang ditunjukkan pada Gambar 6.

Pengujian estimator yang dirancang selanjutnya adalah membandingkan data curah hujan bulanan yang diukur oleh instrumen pengukur curah hujan dengan estimator curah hujan bulanan yang dirancang pada periode Januari hingga Juni 2023. Tabel 4 menunjukkan hasil evaluasi estimator curah hujan bulanan berupa nilai RMSE dan MAPE. Nilai rata-rata RMSE dan MAPE dengan metode MLP menunjukkan nilai 90.19 mm dan 40.55 %.

Tabel 4. Hasil Uji Performa Estimator MLP.

Grid	RMSE (mm)	MAPE (%)
Grid 1	87.87	57.10
Grid 2	99.29	73.71
Grid 3	106.74	56.93
Grid 4	95.34	34.99
Grid 5	87.94	50.50
Grid 6	76.84	42.69

Grid 7	90.17	39.98
Grid 8	79.45	31.76
Grid 9	89.03	29.48
Grid 10	76.73	25.54
Grid 11	80.00	29.91
Grid 12	83.47	33.98
Grid 13	89.57	35.42
Grid 14	76.48	24.44
Grid 15	110.88	39.47
Grid 16	113.19	42.95
Rata-rata	90.19	40.55
Maks	113.19	73.71
Min	76.48	24.44

4. Kesimpulan

Berdasarkan hasil pemodelan estimasi curah hujan bulanan menggunakan metode *Multi Layer Perceptron* (MLP) menunjukkan hasil uji yang berada pada rentang toleransi. Uji estimator MLP dibandingkan dengan instrumen pengukur curah hujan bulanan menghasilkan RMSE sebesar 90.19 mm dan MAPE sebesar 40.55 % untuk di 16 Grid di provinsi Tangerang Selatan. Pemodelan curah hujan yang dihasilkan ini dapat dijadikan pertimbangan kepada para stakeholder dalam pengambilan keputusan terkait faktor curah hujan. Namun, untuk penelitian kedepannya dapat menguji *hyperparameter* sehingga dapat meningkatkan akurasi model.

Daftar Pustaka

- [1] Herlina, N., & Prasetyorini, A. (2020). Pengaruh Perubahan Iklim pada Musim Tanam dan Produktivitas Jagung (*Zea mays L.*) di Kabupaten Malang (Effect of Climate Change on Planting Season and Productivity of Maize (*Zea mays L.*) in Malang Regency). *Jurnal Ilmu Pertanian Indonesia (JIPI)*, Januari, 25(1), 118–128.
<https://doi.org/10.18343/jipi.25.1.118>
- [2] Sainstek, J., & Pekanbaru, S. (2021). SAINSTEK (e-Journal) Analisis Kondisi Atmosfer Saat Banjir dan Tanah Longsor (Studi Kasus: Nganjuk, 14 Februari 2021) INFORMASI ARTIKEL ABSTRACT.
- [3] Yulizar, D., Aofany, D., Soekirno, S., Ananda, N., Prabowo, M. A., & Adi, S. P. (2024). Visualization of Rainfall Classification using Rain Gauge based on Website. 2024 IEEE International Conference on Artificial Intelligence and Mechatronics Systems (AIMS), 1–5.
<https://doi.org/10.1109/AIMS61812.2024.10512600>
- [4] Gaol, G. M. L., Syafrullah, M., & Supardi, S. (2024). Comparison of Monthly Rainfall Prediction using Long Short Term Memory and Multi Layer Perceptron Methods in South Tangerang City. *Jurnal Sisfokom (Sistem Informasi Dan Komputer)*, 13(2), 293–297.
<https://doi.org/10.32736/sisfokom.v13i2.2149>
- [5] Funk, C.C., Peterson, P.J., Landsfeld, M.F., Pedreros, D.H., Verdin, J.P., Rowland, J.D., Romero, B.E., Husak, G.J., Michaelsen, J.C. and Verdin, A.P., 2014. A quasi-global precipitation time series for drought monitoring. *US Geological Survey data series*, 832(4), pp.1-12.
- [6] Huang, X., Gao, L., Crosbie, R. S., Zhang, N., Fu, G., & Doble, R. (2019). Groundwater recharge prediction using linear regression, multi-layer perception network, and deep learning. *Water (Switzerland)*, 11(9).
<https://doi.org/10.3390/w11091879>.
- [7] Wibawa AP, Utama AB, Elmunsyah H, Pujiyanto U, Dwiyanto FA, Hernandez L. Time-series analysis with smoothed Convolutional Neural Network. *Journal of big Data*. 2022 Apr 26;9(1):44.
- [8] Bilgili M, Sahin B. Comparative analysis of regression and artificial neural network models for wind speed prediction. *Meteorology and atmospheric physics*. 2010 Nov;109:61-72
- [9] Lin Z, Feng J, Lu Z, Li Y, Jin D. Deepstn+: Context-aware spatial-temporal neural network for crowd flow prediction in metropolis. In *Proceedings of the AAAI conference on artificial intelligence 2019 Jul 17 (Vol. 33, No. 01, pp. 1020-1027)*.
- [10] Szandala, Tomasz. (2021). Review and Comparison of Commonly Used Activation Functions for Deep Neural Networks. In *Bio-inspired*

- Neurocomputing, 203-224.
Springer, Singapore
- [11] Sahu RK, Müller J, Park J, Varadharajan C, Arora B, Faybishenko B, Agarwal D. Impact of input feature selection on groundwater level prediction from a multi-layer perceptron neural network. *Frontiers in Water*. 2020 Nov 19;2:573034
- [12] Prasetyo B, Pusparini N. Pemanfaatan SATAID Untuk Analisa Atmosfer di Wilayah Perairan. *Jurnal Fisika dan Aplikasinya*. 2018 Jun 1;14(2):37-44
- [13] Kafara Z, Rumlawang FY, Sinay LJ. Peramalan Curah Hujan Dengan Pendekatan Seasonal Autoregressive Integrated Moving Average (Sarima). *Barekeng: Jurnal Ilmu Matematika dan Terapan*. 2017 Mar 1;11(1):63-74
- [14] Fiebrich, C. A., Morgan, C. R., McCombs, A. G., Hall, P. K., & McPherson, R. A. (2010). Quality Assurance Procedures for Mesoscale Meteorological Data. *Journal of Atmospheric and Oceanic Technology*, 27(10), 1565–1582.
<https://doi.org/10.1175/2010JTECHHA1433.1>
- [15] Evi Dewi Sri Mulyani, Indah Septianingrum, Nisa Nurjanah, Reka Rahmawati, Syifa Nurhasani, Kiky Milky R. K., 2019. Prediksi Curah Hujan Di Kabupaten Majalengka Dengan Menggunakan Algoritma Regresi., Volume 8, Nomor 1, *Jurnal Sistem Informasi dan Teknologi Informasi (JUSITI)*.<https://doi.org/10.36774/jusiti.v8i1.602>.