



Prediksi Curah Hujan Harian di Stasiun Meteorologi Kemayoran Menggunakan *Artificial Neural Network* (ANN)

Richard Mahendra Putra^{1*}, Nurhastuti Anjar Rani²

¹Sub Bidang Manajemen Observasi Meteorologi Permukaan, Badan Meteorologi Klimatologi dan Geofisika (BMKG), Kemayoran, Jakarta Pusat, 10720

²Sub Bidang Manajemen Operasi Meteorologi Maritim, Badan Meteorologi Klimatologi dan Geofisika (BMKG), Kemayoran, Jakarta Pusat, 10720

*Email: richardmahendrap@gmail.com

Naskah Masuk: 12 November 2020 | Naskah Diterima: 28 November 2020 | Naskah Terbit: 01 Desember 2020

Abstrak. Prakiraan cuaca sangat penting untuk mendukung segala kegiatan aktivitas masyarakat. Untuk menghasilkan prakiraan cuaca yang akurat dibutuhkan pengetahuan dan pengalaman dari prakirawan cuaca yang didukung dengan teknologi pemodelan cuaca. Pada penelitian ini, dilakukan sebuah pemodelan curah hujan menggunakan *artificial neural network* (ANN) di Stasiun Meteorologi Kemayoran. Pada proses pembuatan model ANN, dibutuhkan pelatihan data menggunakan kondisi cuaca di masa lalu. Data yang digunakan untuk pelatihan dalam membuat model ANN adalah data cuaca harian periode Januari 2011 s.d. Desember 2019 yang selanjutnya diuji dengan menggunakan studi kasus selama periode Januari s.d. Agustus 2020. Variasi model dibuat berdasarkan jenis *input* dan jumlah *hidden layer* untuk mengetahui perbedaan penggunaan data prediktor yang digunakan. Kemudian model ANN dibuat dengan menggunakan pendekatan 3 – lapisan yang terdiri dari lapisan *input*, lapisan tersembunyi, dan lapisan output. Selanjutnya perbandingan model tersebut diuji menggunakan nilai koefisien korelasi (R) dan rata – rata kesalahan absolut (MAE) untuk mengetahui model yang terbaik. Berdasarkan hasil penelitian, prediksi hujan menggunakan data parameter *input* kondisi cuaca harian berupa suhu udara, kelembaban udara, dan durasi penyinaran matahari memiliki nilai koefisien korelasi (R) sebesar 0.4 – 0.5 dan rata – rata kesalahan absolut (MAE) sebesar 9.7 – 9.8 mm. Sedangkan jika model dibuat dengan parameter *input* hujan di hari – hari sebelumnya, nilai koefisien korelasi (R) hanya 0.1 – 0.3 dengan nilai rata – rata kesalahan absolut (MAE) sebesar 11.3 – 12.3 mm. Kondisi tersebut menunjukkan bahwa prediktor yang lebih baik digunakan dalam memprediksi hujan harian berdasarkan *artificial neural network* adalah dengan menggunakan parameter *input* kondisi cuaca permukaan.

Kata Kunci: Model, Hujan, Jaringan Saraf Tiruan (JST)

Abstract. Forecasting the weather conditions is very important to support all community activities. An accurate weather forecast requires knowledge and experience from weather forecasters and is supported by weather modelling technology. In this study, a rainfall intensity modelling was carried out using an artificial neural network (ANN) at the Kemayoran Meteorological Station. In the process of making ANN models, data training is required using past weather conditions. The data used for training in making ANN models are daily weather data for January 2011 until December 2019, which was then tested using a case study from January until August 2020. Model variations are made based on the type of input and the number of hidden layers to determine differences in the use of the predictor data. The ANN model was then created using 3 layers consisting of input layer, hidden layer, and output layer. Furthermore, the model's comparison is tested using the correlation coefficient (R) and mean absolute error (MAE) to determine the best model. Based on the research results, rainfall prediction using input parameter data for daily weather conditions consist of temperature, humidity, and sunshine has a correlation coefficient (R) is 0.3 – 0.5 and a mean absolute error

(MAE) is 9.7 – 9.8 mm. Meanwhile, if the model is made with the rainfall input parameter in the previous days, the correlation coefficient (R) is only 0.1 – 0.3 with the mean absolute error (MAE) is 11.3 – 12.3 mm. This condition indicates that a better predictor to predict daily rainfall using an artificial neural network is to use the input parameter of surface weather conditions.

Keywords: Modeling, Rainfall, Artificial Neural Network (ANN)

Pendahuluan

Informasi cuaca merupakan kebutuhan pokok dalam mendukung berbagai sektor kehidupan. Pada sektor transportasi penerbangan, kondisi cuaca memiliki peran yang signifikan dalam keselamatan pesawat, baik saat di darat ataupun di udara [1]. Pada penelitian – penelitian sebelumnya, informasi cuaca juga diperlukan untuk menentukan bagaimana pola tanam dari sebuah daerah agar hasil panen dapat mencapai maksimal [2]. Selain itu, kondisi cuaca ekstrem juga berpengaruh pada kondisi kelistrikan hingga pemadaman listrik [3]. Salah satu parameter cuaca yang berpengaruh signifikan adalah curah hujan. Berdasarkan penelitian sebelumnya, kejadian hujan dapat diprediksi dengan baik menggunakan beberapa pendekatan, seperti menggunakan *downscaling* model WRF (*Weather Research and Forecasting*) [4], Model cuaca dari *Bureau of Meteorology* Australia [5], dan menggunakan sistem kecerdasan buatan seperti *Artificial Neural Network* [6]–[8].

Artificial Neural Network (ANN) merupakan salah satu metode yang didesain untuk menirukan cara kerja otak manusia dalam menyelesaikan masalah melalui pembobotan pada data *input* yang diberikan. Berdasarkan penelitian yang dilakukan oleh Yusran (2016) [9], model ANN dapat digunakan untuk memprediksi kondisi di masa depan dengan menggunakan pola data pada periode masa lalu. Di bidang meteorologi, pemanfaatan model ANN sudah dilakukan dalam hal prakiraan cuaca jangka pendek [10], prediksi kondisi PM_{10} di Kemayoran [11], deteksi debu vulkanik [12], dan identifikasi kondisi atmosfer global terhadap kondisi cuaca di Indonesia [13].

Salah satu faktor yang mempengaruhi performa model yang dibuat adalah arsitektur jaringan dari model ANN. Arsitektur jaringan pada model ANN terdiri atas beberapa lapisan yaitu lapisan masukan (*input layer*) yang merupakan lapisan terdiri dari beberapa neuron yang menerima sinyal dari luar kemudian meneruskan ke neuron lain di lapisan selanjutnya yaitu lapisan tersembunyi. Lapisan tersembunyi (*hidden layer*) merupakan lapisan tiruan dari sel – sel saraf konektor seperti pada jaringan saraf biologis. Lapisan tersembunyi berpengaruh dalam meningkatkan kemampuan jaringan untuk memecahkan masalah. Lapisan terakhir adalah lapisan keluaran (*output layer*) yang berfungsi menyalurkan sinyal – sinyal keluaran hasil dari model ANN. Ilustrasi arsitektur jaringan dari model ANN dapat dilihat pada Gambar 1.

Penelitian ini difokuskan pada pemanfaatan model ANN untuk melakukan prediksi curah hujan harian di Stasiun Meteorologi Kemayoran. Berdasarkan penelitian sebelumnya tentang tema yang sama, curah hujan dapat diprediksi menggunakan model ANN dengan parameter *input* data curah hujan pada hari – hari sebelumnya [6], dan menggunakan parameter cuaca lain [8]. Namun kedua penelitian tersebut tidak menggunakan studi kasus yang sama. Dalam penelitian ini, model ANN dibuat melalui 2 pendekatan parameter *input*, yaitu data hujan di hari sebelumnya dan data cuaca permukaan. Hal tersebut bertujuan untuk mengetahui performa dari model ANN terhadap prediksi curah hujan harian di Kemayoran. Selain itu, penelitian ini juga melakukan pengujian desain arsitektur dari model ANN yang digunakan.

Letak Geografis

Stasiun Meteorologi Kemayoran merupakan salah satu Unit Pelaksana Teknis (UPT) dari Badan Meteorologi Klimatologi dan Geofisika (BMKG) yang terletak pada koordinat 6.16° LS dan 106.84°




BT. Stasiun ini melakukan pengamatan cuaca dan iklim dengan jam operasional 24 jam setiap harinya. Wilayah Kemayoran termasuk dalam tipe hujan Monsunal dengan intensitas hujan maksimum terjadi pada bulan Desember – Januari – Februari (DJF), dan hujan minimum terjadi pada bulan Juni – Juli – Agustus (JJA). Pada tahun 2019, intensitas hujan yang terjadi berkisar antara 0 – 382.2 mm / bulan.

Metode Penelitian

Pada proses pembuatan model ANN, parameter *input* dilakukan pelatihan pola terhadap data target yang diberikan Model ini dapat melakukan pengenalan kegiatan berbasis data sehingga data sebelumnya yang diberikan akan digunakan untuk membuat keputusan terhadap data yang baru. Dalam proses pembuatan model, sistem dibentuk dengan beberapa asumsi, diantaranya [14] :

1. Pemrosesan informasi terjadi pada elemen sederhana (neuron).
2. Sinyal dikirimkan di antara sel saraf / neuron melalui suatu sambungan penghubung.
3. Setiap sambungan penghubung memiliki bobot yang bersesuaian. Bobot ini akan digunakan untuk mengalikan sinyal yang dikirim.
4. Setiap sel saraf akan menerapkan fungsi aktivasi terhadap sinyal hasil penjumlahan yang masuk untuk menentukan sinyal keluaran.



Gambar 1. Ilustrasi Jaringan Model [15]

Pada penelitian ini, data yang digunakan adalah data kondisi cuaca permukaan berupa intensitas hujan harian, suhu udara, kelembaban udara, dan durasi penyinaran matahari di Stasiun Meteorologi Kemayoran periode Januari 2011 s.d. Agustus 2020 yang diperoleh dari website dataonline.bmkg.go.id/. Tahap awal sebelum proses pelatihan untuk membuat model ANN adalah melakukan pengecekan terhadap kelengkapan data yang digunakan sebagai parameter *input* maupun parameter *output*. Dataset yang disiapkan adalah data suhu udara, kelembaban udara, durasi penyinaran matahari, dan intensitas curah hujan periode Januari 2011 s.d Agustus 2020. Apabila pada dataset terdapat salah satu parameter tersebut kosong, maka data pada hari tersebut akan dihilangkan dan tidak digunakan pada proses pelatihan model.

Pada proses pembuatan model ANN, dilakukan proses pelatihan data menggunakan data cuaca periode Januari 2011 s.d. Desember 2019. Variasi model yang dibuat dibagi menjadi dua model, yaitu model yang hanya menggunakan parameter *input* intensitas hujan di 5 hari sebelumnya seperti penelitian yang dilakukan oleh Khalili (2011) [6], dan model yang menggunakan parameter *input* cuaca lain seperti suhu udara, kelembaban, dan durasi penyinaran matahari berdasarkan penelitian sebelumnya [8]. Selanjutnya pembuatan arsitektur model ANN dibuat dengan menggunakan 1 lapisan tersembunyi yang memiliki neuron 2, 3, dan 7 seperti pada penelitian sebelumnya [6]. Total model yang digunakan dalam penelitian ini ada 6 variasi, yaitu 3 variasi dengan menggunakan parameter *input* hujan, dan 3

variasi dengan menggunakan parameter cuaca dengan masing – masing variasi dibedakan berdasarkan jumlah neuron yang digunakan (Tabel 1). Untuk variasi hujan, data parameter *input* yang digunakan sebanyak 5 *input*, yaitu hujan pada $h - 5$, $h - 4$, $h - 3$, $h - 2$, dan $h - 1$. Sedangkan untuk parameter cuaca permukaan, data *input* yang digunakan sebanyak 3 input, yaitu suhu udara, kelembaban udara dan penyinaran matahari.

Tabel 1. Variasi Model Artificial Neural Network (ANN)

Model	Keterangan
ANN521	Parameter <i>input</i> hujan 5 hari sebelumnya dengan 2 neuron pada <i>hidden layer</i>
ANN531	Parameter <i>input</i> hujan 5 hari sebelumnya dengan 3 neuron pada <i>hidden layer</i>
ANN571	Parameter <i>input</i> hujan 5 hari sebelumnya dengan 7 neuron pada <i>hidden layer</i>
ANN321	Parameter <i>input</i> cuaca permukaan(T,RH,SSS)dengan 2 neuron pada <i>hidden layer</i>
ANN331	Parameter <i>input</i> cuaca permukaan(T,RH,SSS) dengan 3 neuron pada <i>hidden layer</i>
ANN371	Parameter <i>input</i> cuaca permukaan(T,RH,SSS) dengan 7 neuron pada <i>hidden layer</i>

Setelah dilakukan proses pelatihan menggunakan data pengamatan cuaca periode Januari 2011 s.d. Desember 2019, seluruh *output* model ANN berupa intensitas hujan harian diuji dengan data pengamatan intensitas hujan cuaca di Stasiun Meteorologi Kemayoran periode Januari 2020 s.d. Agustus 2020. Pengujian dilakukan dengan mencari nilai koefisien korelasi dari seluruh *output* model terhadap data hujan observasi di Stasiun Meteorologi Kemayoran. Semakin tinggi nilai korelasi, maka menunjukkan performa model yang semakin baik. Tabel 2, merupakan pembagian kategori koefisien korelasi [16].

Tabel 2 Kategori koefisien Korelasi

Interval Korelasi	Tingkat Hubungan
0.00 – 0.199	Sangat Lemah
0.20 – 0.399	Lemah
0.40 – 0.599	Sedang
0.60 – 0.799	Kuat
0.80 – 1.000	Sangat Kuat

Nilai korelasi dari *output* model dengan data observasi dapat dihitung dengan persamaan berikut [17]:

$$R = \frac{\sum_{i=1}^n (RO_i - \overline{RO})(RM_i - \overline{RM})}{\sqrt{\sum_{i=1}^n (RO_i - \overline{RO})^2} \sqrt{\sum_{i=1}^n (RM_i - \overline{RM})^2}}$$

Keterangan :

R = Koefisien orelesi

RM = Intensitas hujan model

\overline{RM} = Rata – rata Intensitas hujan model

RO = Intensitas hujan observasi

\overline{RO} = Rata – rata intensitas hujan observasi

n = Banyaknya data



Selain itu, uji tingkat kesalahan model dilakukan dengan menghitung nilai *Mean Absolute Error* (MAE) dari seluruh model. Semakin besar nilai MAE, maka tingkat kesalahan dari *output* tersebut semakin besar sehingga menunjukkan bahwa model kurang optimal dalam membuat prakiraan hujan tersebut. Secara matematis, nilai dari MAE dapat dihitung sebagai berikut [17]:

$$MAE = \frac{\sum_{i=1}^n |RM_i - RO_i|}{n}$$

Keterangan :

MAE = Mean absolute error

RM = Intensitas hujan model


RO = Intensitas hujan observasi

n = Banyaknya data

Hasil dan Pembahasan


Gambar 2 menunjukkan pola perbandingan *output* model ANN dengan data Observasi Hujan Stasiun Meteorologi Kemayoran. Pada model ini, data parameter *input* yang digunakan adalah curah hujan di beberapa hari sebelumnya. Berdasarkan hasil tersebut, terlihat bahwa secara keseluruhan, pola kejadian dapat dideteksi dengan menggunakan model ini. Namun terdapat sebuah kesalahan yang cukup signifikan pada *output* model tersebut.

Pada keseluruhan variasi model, yaitu ANN521, ANN531, dan ANN571 menunjukkan bahwa kejadian hujan lebat dihasilkan di hari setelahnya, bukan saat peristiwa hujan lebat terjadi. Hal tersebut menunjukkan bahwa hasil *output* model yang diprediksi menggunakan parameter *input* hujan di hari sebelumnya sangat bergantung pada kondisi hujan di hari terakhir sebelum model melakukan prediksi. Apabila kondisi hujan di hari terakhir menunjukkan intensitas tinggi, maka prediksi hujan di hari setelahnya juga akan meningkat cukup signifikan. Hal tersebut menyebabkan model ini mengalami pergeseran kejadian curah hujan tinggi ke hari setelah kejadian hujan lebat yang sebenarnya. Kondisi tersebut terjadi di seluruh variasi model, baik ketika menggunakan 2 neuron, 3 neuron, ataupun 7 neuron pada lapisan tersembunyi. Namun untuk kejadian hujan saat memiliki intensitas yang rendah, model ANN ini dapat menunjukkan hasil yang mendekati data observasinya.



Gambar 2. Hasil Perbandingan Model ANN dengan data Observasi Stasiun Meteorologi Kemayoran menggunakan parameter *input* hujan di 5 hari sebelumnya

Gambar 3 menunjukkan perbandingan intensitas hujan harian yang dihasilkan dari model ANN dengan parameter *input* cuaca permukaan seperti suhu udara, kelembaban, dan durasi penyinaran matahari. Berdasarkan gambar tersebut, hasil *output* model ANN321, ANN331, dan ANN371 menunjukkan nilai yang *underestimate* dibandingkan dengan intensitas hujan observasi di Stasiun Meteorologi Kemayoran. Namun saat diperhatikan lebih detail pada saat kejadian hujan, kondisi pola dari intensitas hujan di setiap waktu memiliki pola yang serupa. Hal tersebut berbeda dengan hasil *output* model dengan parameter hujan saja yaitu hasil prediksi intensitas mengalami perbedaan waktu kejadian hujan yaitu 1 hari setelah kejadian hujan lebat. Pada model ini menunjukkan pola yang lebih mendekati intensitas hujan dari data observasi. Kondisi tersebut terlihat ketika kejadian hujan meningkat, maka hasil *output* model juga memiliki peningkatan dari intensitas hujan. Hal tersebut juga terjadi ketika hujan mengalami penurunan intensitas curah hujan. .



Gambar 3. Hasil Perbandingan Model ANN dengan data Observasi Stasiun Meteorologi Kemayoran menggunakan parameter *input* kondisi cuaca permukaan

Uji performa model ANN dilakukan dengan membandingkan nilai intensitas hujan hasil *output* model dengan intensitas hujan observasi Stasiun Meteorologi Kemayoran. Berdasarkan hasil perbandingan tersebut, nilai korelasi dari keseluruhan model berkisar antara 0.1 – 0.5. Hal tersebut menunjukkan bahwa tingkat korelasi antara model ANN dan observasi masuk pada katagori sangat lemah s.d. sedang [16].

Tabel 3. Performa Model *Artificial Neural Network*

Input Mode		MAE	KORELASI
RR Historis	ANN521	12.3	0.1
	ANN531	11.4	0.2
	ANN571	11.3	0.3
Cuaca Permukaan	ANN321	9.7	0.4
	ANN331	9.7	0.5
	ANN371	9.8	0.4

Tabel 3 menunjukkan hasil performa *output* intensitas hujan dari model ANN yang dibandingkan dengan data hujan observasi di Stasiun Meteorologi Kemayoran. Berdasarkan hasil tersebut, nilai MAE dari *output* model yang menggunakan parameter *input* intensitas hujan di hari sebelumnya, yaitu

model ANN521, ANN531 dan ANN571 yang memiliki nilai MAE antara 11.3 – 12.3 mm. Sedangkan nilai MAE dari *output* model dengan parameter *input* kondisi cuaca permukaan seperti ANN321, ANN331, dan ANN371 memiliki nilai MAE sebesar 9.7 mm dan 9.8 mm.

Selanjutnya, nilai korelasi *output* model ANN521, ANN531, dan ANN571 memiliki tingkat korelasi yang sangat lemah hingga lemah, yaitu 0.1 – 0.3. Hal tersebut disebabkan oleh kejadian peningkatan kejadian hujan yang signifikan terjadi di hari setelah kejadian hujan lebat. Berdasarkan hasil tersebut, model dengan jumlah neuron sebanyak 7 pada lapisan tersembunyi memiliki performa yang paling baik dibandingkan arsitektur model lainnya saat menggunakan parameter *input* intensitas hujan di beberapa hari sebelumnya.

Untuk tingkat korelasi yang terjadi pada model dengan parameter *input* cuaca permukaan, nilai korelasi yang dihasilkan pada keseluruhan model adalah 0.4 – 0.5. Hal tersebut menunjukkan bahwa tingkat korelasinya termasuk pada kategori sedang. Pada model tersebut, tingkat korelasi paling tinggi dihasilkan oleh model yang dibuat dengan arsitektur 3 neuron pada lapisan tersembunyi. Selain dari tingkat korelasi yang paling tinggi, arsitektur dengan 3 neuron pada lapisan tersembunyi juga memiliki nilai kesalahan yang paling rendah yaitu 9.7 mm. Hal tersebut menunjukkan bahwa pada studi kasus ini, model terbaik yang dihasilkan pada proses pengujian data dengan data intensitas hujan periode Januari 2020 s.d. Agustus 2020 adalah model ANN331 yang memiliki 3 neuron di lapisan tersembunyi.

Kesimpulan

Berdasarkan hasil *output* model yang dilakukan menggunakan data pelatihan periode Januari 2011 s.d. Desember 2019 yang diuji dengan data periode Januari s.d. Agustus 2020 menunjukkan hasil yang bervariasi. Model dengan parameter *input* intensitas hujan pada beberapa hari sebelumnya memiliki hasil yang kurang sesuai untuk prediksi hujan. Kejadian hujan yang seharusnya terjadi pada satu hari tertentu justru ditunjukkan pada hari setelahnya. Sedangkan untuk model dengan parameter *input* cuaca harian dapat menangkap pola – pola peningkatan intensitas hujan dan pola penurunan intensitas hujan di waktu yang sama. Model terbaik yang diperoleh berdasarkan studi kasus penelitian ini adalah model ANN331, yaitu model ANN yang menggunakan parameter data *input* berupa cuaca permukaan dan arsitektur model menggunakan 3 neuron di lapisan tersembunyi. Tingkat kesalahan yang dihasilkan model tersebut adalah 9.7 mm dengan nilai korelasi 0.5. Kondisi tersebut menunjukkan bahwa model ANN yang dibuat untuk memprediksi curah hujan harian di Kemayoran menggunakan data *input* cuaca permukaan seperti suhu udara, kelembaban udara dan penyinaran matahari memiliki hasil yang lebih baik dibandingkan model yang hanya dengan menggunakan data *input* curah hujan di hari sebelumnya.

Saran

Pada penelitian ini, penulis hanya menggunakan model dengan memanfaatkan data cuaca permukaan saja. Saran yang bisa diberikan penulis untuk penelitian serupa di waktu mendatang adalah data *input* yang digunakan dalam model bisa ditambahkan dengan data observasi udara atas seperti Radiosonde. Hal tersebut dimungkinkan akan meningkatkan performa dari model ini, mengingat bahwa dengan menggunakan data observasi udara atas, kita dapat mengetahui bagaimana kondisi atmosfer secara vertikal dan sifat dari atmosfer saat itu apakah stabil atau labil.

Ucapan Terima Kasih

Penulis mengucapkan terima kasih yang sebesar – besarnya kepada seluruh pihak yang membantu dalam proses penelitian ini. Pihak yang bersedia menyediakan data cuaca permukaan yang dapat dimanfaatkan dalam penelitian ini, pihak yang memberikan pengetahuan tentang metode yang

digunakan, dan pihak yang memberikan pelatihan teknis membuat *script* pemodelan *artificial neural network*.

Daftar Pustaka

- [1] Gultepe, I., Sharman, R., Williams, P. D., Zhou, B., Ellrod, G., Minnis, P., dan Feltz, W. 2019. A review of high impact weather for aviation meteorology. *Pure and applied geophysics*, 176(5), 1869-1921.
- [2] Dwiratna, N. P. S., Nawawi, G., dan Asdak, C. 2013. Analisis Curah Hujan dan Aplikasinya dalam Penetapan Jadwal dan Pola Tanam Pertanian Lahan Kering di Kabupaten Bandung. *Bionatura*, 15(1).
- [3] Kezunovic, M., Dobson, I., & Dong, Y. 2008. Impact of extreme weather on power system blackouts and forced outages: New challenges. In 7th Balkan Power Conf (pp. 1-5).
- [4] R. M. Putra, J. R. Simamora, and Dedyarza. 2017. Simulasi Hujan Lebat Di Daerah Bandung Dengan Menggunakan Parameterisasi Cumulus Skema Grell-3d Dan Grell-Devenyi Ensemble. *Prosiding Seminar Hari Meteorologi Dunia STMKG*, hal. 13 - 22
- [5] R. M. Putra dan N. A. Rani. 2017. Pemanfaatan Data Prakiraan Model Dengan Inisial 12.00 Utc Untuk Membuat Prakiraan Cuaca Di Stmkg. *Buletin Meteo Ngurah Rai* vol. 3, hal. 39 - 46
- [6] Khalili, N., Khodashenas, S. R., Davary, K., dan Karimaldini, F. 2011. Daily rainfall forecasting for Mashhad synoptic station using artificial neural networks. In *International conference on environmental and computer science*, Vol. 19, pp. 118-123
- [7] R. Salmayenti, R. Hidayat, dan A. Pramudia. 2017. Prediksi Curah Hujan Bulanan Menggunakan Teknik Jaringan Syaraf Tiruan. *Agromet* vol. 31, no. 1, hal. 11–21
- [8] R. M. Putra, Y. Kusumayanti, E. Afriani, dan H. Herawati. 2019. Implementasi Jaringan Syaraf Tiruan untuk Prediksi Cuaca Harian di Stasiun Meteorologi Soekarno Hatta. *Buletin BMKG* Vol 14, no 1, hal. 1 - 8
- [9] Yusran, Y. 2016. Implementasi Jaringan Syaraf Tiruan (Jst) Untuk Memprediksi Hasil Nilai Un Menggunakan Metode Backpropagation. *Jurnal Ipteks Terapan*, 9(4).
- [10] G B Wanugroho, Martarizaland, and R M Putra. 2020. Implementation of artificial neural networks for very short range weather prediction. In *Journal of Physics: Conference Series* (Vol. 1528, No. 1, p. 012039)
- [11] A M M B Putra, Martarizal, and R M Putra. 2020. Prediction of PM2 . 5 and PM10 parameters using artificial neural network : a case study in Kemayoran. In *Journal of Physics: Conference Series* (Vol. 1528, No. 1, p. 012036)
- [12] Putra, R. M., Saputro, A. H., Arazak, L., and Kharisma, S. 2019. Automatic detection of volcanic ash from Himawari-8 satellite using artificial neural network. In *AIP Conference Proceedings* ,Vol. 2202, No. 1, p. 020112
- [13] R. M. Putra, S. Alfiandy, dan B. E. A. Haq. 2020. “Identifikasi Pengaruh El Nino Southern Oscillation (Enso), Indian Ocean Dipole (Iod), And Madden Julian Oscillation (Mjo) Terhadap Intensitas Curah Hujan Bulanan Di Indonesia Berbasis Machine Learning,” *Buletin Ngurah Rai*, vol. 6, hal. 1 - 8
- [14] J. J. Siang, 2004. *Jaringan Syaraf Tiruan dan Pemogramannya Menggunakan MATLAB*. Yogyakarta: Penerbit ANDI
- [15] Putra, J. W. G. 2019. *Pengenalan Konsep Pembelajaran Mesin dan Deep Learning*. Tokyo. Jepang.
- [16] Azka, M. A., Sugianto, P. A., Silitonga, A. K., dan Nugraheni, I. R. 2018. Uji Akurasi Produk Estimasi Curah Hujan Satelit GPM IMERG di Surabaya, Indonesia. *Jurnal Sains & Teknologi Modifikasi Cuaca*, 19(2), 83-88.
- [17] D. S. Wilks. 2006. *Statistical Methods in the Atmospheric Sciences*. California: Elsevier Inc

