

# OPTIMALISASI ESTIMASI CURAH HUJAN BERDASARKAN CITRA RADAR MENGGUNAKAN MODEL PEMBELAJARAN MESIN MLP

## Optimizing Rainfall Estimation based on Radar Imagery Using MLP Machine Learning Models

Mohammad Isa Irawan<sup>1)\*</sup>, Kistosil Fahim<sup>1)</sup>, Lalu Muhammad Jaelani<sup>2)</sup>, Oky Sukma Hakim<sup>3)</sup>, Sony Susanto<sup>4)</sup>

<sup>1)</sup>Departemen Matematika, Fakultas Sains dan Analitika Data, Institut Teknologi Sepuluh Nopember, Kampus ITS Sukolilo, Surabaya, 60111

<sup>2)</sup>Departemen Teknik Geomatika, Fakultas Teknologi Sipil, Perencanaan, dan Kebumihan, Institut Teknologi Sepuluh Nopember, Kampus ITS Sukolilo, Surabaya, 60111

<sup>3)</sup>Stasiun Meteorologi Kelas I Juanda Sidoarjo, BMKG, Jl. Raya Bandara Juanda, Sidoarjo, 61253

<sup>4)</sup>Departemen Teknik Sipil, Fakultas Teknik, Universitas Kadir, Jl. Selomangleng No. 1, Kediri 64115  
\*e-mail: mii@its.ac.id

### Intisari

Bencana hidrometeorologi di Jawa Timur dalam 10 tahun terakhir memiliki catatan lebih banyak dibandingkan jenis bencana lainnya. Urgensi penelitian ini adalah membuat model yang tepat dalam mengestimasi curah hujan dari nilai reflektivitas citra radar sebab ketersediaan alat pengamatan in situ tidak menyeluruh dan hasil pemindaian citra radar masih terdapat noise. Terdapat 3 tahap dalam penelitian ini, yaitu tahap data preprocessing, pelatihan data, dan pengujian data. Tahap data preprocessing untuk menghilangkan noise sebelum mengestimasi curah hujan, meliputi koreksi VPR, koreksi atenuasi, dan clutter removal. Pembelajaran mesin Multi-layer Perceptron (MLP) digunakan untuk pelatihan dan pengujian data. Simulasi percobaan dengan variasi jumlah hidden layers dibutuhkan untuk mendapatkan pengaturan terbaik sebelum melakukan pelatihan data. Data tahun 2018-2019 digunakan sebagai pelatihan data, sedangkan data tahun 2020 digunakan sebagai pengujian data. Data input meliputi estimasi curah hujan radar dan jarak titik pengamatan curah hujan dari pusat radar yang dinormalisasi, sementara data output adalah nilai curah hujan hasil pengamatan in situ. Tahap data preprocessing menghasilkan nilai reflektivitas rata-rata dari partikel bukan air hujan atau clutter adalah 1,93 dBz. Hasil simulasi memperoleh jumlah hidden layers terbaik adalah 65. Pengujian data menggunakan model MLP dari hasil pelatihan data memperoleh nilai RMSE sebesar 16.2 mm, skill score sebesar -0.33, dan mean bias sebesar -0.83 mm. Hasil visualisasi model MLP menunjukkan semakin jauh dari pusat radar, maka nilai bobot bias yang akan dikalikan terhadap data input juga semakin besar.

**Kata Kunci:** Curah Hujan, Citra Radar, Clutter Removal, MLP.

### Abstract

Hydrometeorological disasters in East Java in the past 10 years have been recorded more than other types of disasters. The urgency of this research is to create an appropriate model for estimating rainfall from radar image reflectivity values because the availability of in situ observation tools is not comprehensive and the results of radar image scanning still contain noise. There are 3 stages in this research, those are data preprocessing, data training, and data testing. The data preprocessing stage aims to remove noise before estimating rainfall, including VPR correction, attenuation correction, and clutter removal. Multi-layer Perceptron (MLP) machine learning is used for training and testing data. Experimental simulations with variations in the number of hidden layers in a certain range are needed to get the best settings before doing data training. The 2018–2019 data is used as training data, while the 2020 data is used as testing data. Input data include the estimated radar rainfall and the normalized distance of the rainfall observation point from the radar center, while the output data is rainfall values resulting from in situ observations. The data preprocessing stage produces an average reflectivity value for non-precipitation particles or clutter of 1.93 dBz. The simulation results show that the best number of hidden layers is 65. Data testing using the MLP model from the training data results obtained an RMSE value of 16.2 mm, a skill score of -0.33, and a mean bias of -0.83 mm. The visualization results of the MLP model show that the further away from the radar center, the greater the bias weight value as a multiplier for the input data.

**Keywords:** Rainfall, Radar Imagery, Clutter Removal, MLP.

## 1. PENDAHULUAN

Dalam 10 tahun terakhir (2014 hingga 2023), tercatat jumlah kejadian bencana banjir adalah sebanyak 980 kejadian dan jumlah kejadian bencana tanah longsor sebanyak 639 kejadian. Catatan terkait kejadian kedua bencana ini, lebih besar dibandingkan jenis bencana lainnya. Kedua bencana tersebut biasanya disebabkan oleh curah hujan dengan intensitas tinggi atau biasa disebut bencana hidrometeorologi (BNPB, 2023). Hal ini menunjukkan faktor intensitas curah hujan yang tinggi berperan penting dalam memicu terjadinya bencana di Jawa Timur. Teknologi modifikasi cuaca dapat dimanfaatkan untuk mitigasi bencana hidrometeorologi dan terbukti mampu meminimalkan bencana banjir di Provinsi DKI Jakarta dan sekitarnya. Namun, dalam pengambilan keputusan terkait misi penyemaian awan, dibutuhkan sebuah alat yang dapat memberikan informasi mengenai keberadaan dan kondisi awan yang berada di sekitar daerah target (Seto *et al.*, 2013).

Terdapat dua teknologi penginderaan jarak jauh yang biasa digunakan untuk mendeteksi awan penghujan, yaitu radar dan satelit. Citra radar cuaca memiliki keunggulan dalam resolusi spasial yang lebih tinggi dibandingkan dengan satelit (He *et al.*, 2019). Di sisi lain, citra satelit memiliki keunggulan dalam cakupan area yang lebih luas dari cakupan radar (Stanley *et al.*, 2021). Oleh karena itu, hasil estimasi curah hujan menggunakan radar lebih mendekati nilai pengamatan *in situ* dibandingkan satelit. Hal ini juga didukung dengan teknologi radar cuaca yang dapat menginterpretasi profil awan penghujan secara 3D (He *et al.*, 2019), sedangkan satelit hanya dapat menginterpretasi secara 2D dari bagian atas permukaan awan (Stanley *et al.*, 2021). Selain itu, radar cuaca terbukti handal dalam menganalisis kondisi cuaca yang fluktuatif pada skala kecamatan dan durasi yang relatif singkat saat kejadian banjir di Kota Medan tanggal 5 Oktober 2018 (Prasetyo *et al.*, 2019).

Dari hasil analisis reflektivitas citra radar dapat diketahui sebaran dan jenis awan hujan sebagai data dukung kegiatan modifikasi cuaca, sehingga dapat dimanfaatkan sebagai peringatan adanya potensi bencana hidrometeorologi (Renggono, 2015). Namun pemanfaatan citra radar dalam mengestimasi curah hujan, memiliki sejumlah tantangan. Tantangan yang pertama adalah memisahkan antara partikel air hujan dan partikel bukan air hujan (He *et al.*, 2019). Pesawat terbang, burung, dan abu vulkanik dalam ruang udara dapat menjadi *noise* dalam interpretasi citra (Kasebzadeh, 2020). Teknik pengolahan citra seperti *enhancement* dan segmentasi dibutuhkan untuk mengatasi hal ini.

Tantangan berikutnya adalah mengestimasi curah hujan sedemikian hingga mendekati hasil pengamatan *in situ* dengan nilai

*error* yang sangat kecil. Penerapan metode seperti Relasi Z-R Marshall-Palmer dengan faktor pengali yang sama untuk seluruh piksel dalam satu citra radar, akan menghasilkan nilai *error* yang berbeda antar piksel (Shin *et al.*, 2021). Hal ini dikarenakan adanya berbagai gangguan seperti atenuasi gelombang, *ground clutter*, dan berbagai gangguan secara lokal di suatu wilayah (Kosasih *et al.*, 2021). Oleh karena itu, metode dengan faktor pengali yang dapat bervariasi pada setiap piksel citra radar sangat dibutuhkan dalam mengestimasi curah hujan.

Salah satu metode yang dapat digunakan adalah pembelajaran mesin. Namun metode ini membutuhkan data dengan ukuran yang besar untuk menghasilkan algoritma pembelajaran mesin yang handal. Beberapa macam algoritma pembelajaran mesin sudah terbukti menghasilkan estimasi curah hujan dengan akurat. Diantaranya adalah *regression tree* dan *random forest* (Shin *et al.*, 2021). Adapun pembelajaran mesin *Multi-Layer Perceptron* (MLP), dapat mengimplementasikan diskriminan non-linier jika digunakan untuk klasifikasi dan dapat mendekati fungsi input non-linier jika digunakan untuk regresi. *Perceptron* adalah elemen pemrosesan dasar, yang mana nilai setiap *perceptron* adalah fungsi lokal dari *input* dan *connection weightnya* sebagai *network* (Alpaydin, 2010).

Dalam memprediksi curah hujan seminggu ke depan dari 7 stasiun cuaca di Kota Madrid, Spanyol, metode MLP dengan 11 *input perceptron* dan 50 *hidden layers* mampu menghasilkan nilai *Mean Absolute Error* (MAE) sebesar 0.01388 dan *Root Mean Squared Error* (RMSE) sebesar 0.01557 (Velasco *et al.*, 2019). Penerapan metode ini pada estimasi curah hujan citra radar juga berhasil menurunkan nilai RMSE dari 3,05 menggunakan metode Relasi Z-R Marshall-Palmer menjadi 1,03 menggunakan MLP dengan 2 *hidden layers*, yang mana 4 data AWS di Yogyakarta yang digunakan sebagai *ground truth* (Waskita *et al.*, 2020). Perbandingan metode MLP dengan *Extreme Learning Machine* (ELM) dalam estimasi curah hujan dari citra satelit pada *domain* global juga menunjukkan MLP dengan 7 *input perceptron* dan 3 *hidden layers* memiliki nilai RMSE lebih baik 7 mm dibandingkan dengan ELM, dengan estimasi curah hujan dari citra radar sebagai *ground truth* dan pengaturan jumlah *hidden layers* adalah 3, yang diperoleh dari simulasi percobaan sebelumnya antara 1 hingga 7 *hidden layers* (Lazri *et al.*, 2022).

Dengan demikian, penelitian ini juga melakukan simulasi percobaan MLP dengan rentang jumlah *hidden layers* tertentu terlebih dahulu. Selain itu, untuk menerapkan metode estimasi curah hujan yang memiliki faktor pengali atau nilai bobot yang berbeda antar piksel citra radar, perlu adanya penambahan data input berupa jarak dari pusat radar, sehingga model yang diperoleh memecahkan masalah atenuasi citra radar selama ini. Dari hasil jumlah *hidden*

layers terbaik yang diperoleh dari simulasi dan nilai bobot yang bervariasi terhadap jarak suatu piksel tertentu ke piksel pusat radar, diharapkan dapat menghasilkan model estimasi curah hujan yang tepat berdasarkan data citra radar secara spasial di Jawa Timur menggunakan model pembelajaran mesin MLP. Model ini juga diharapkan mampu menghasilkan estimasi curah hujan yang mendekati hasil pengamatan *in situ*, baik pada titik lokasi yang dekat dengan pusat radar maupun pada titik lokasi yang jauh dengan pusat radar. Selain itu, penelitian ini diharapkan dapat bermanfaat untuk kepentingan mitigasi bencana.

## 2. METODE

Tahap pertama dari penelitian adalah pengumpulan data. Pengumpulan data dilakukan untuk memperoleh berbagai data *input* dan data *output*. Data input terdiri dari data citra radar cuaca dan jarak titik pos hujan ke titik pusat piranti radar. Sementara itu, data output adalah data curah hujan hasil pengamatan *in situ*. Radar cuaca gematronik Badan Meteorologi Klimatologi dan Geofisika (BMKG), Desa Kwangsari, Kecamatan Sedati, Kabupaten Sidoarjo. Data citra radar yang diambil adalah nilai reflektivitas dari tahun 2018 hingga 2020. Sebenarnya, data mentah yang pertama kali diamati radar adalah faktor reflektivitas. Namun karena perbedaan nilai yang begitu jauh antara partikel awan dan tetes hujan, maka yang ditampilkan dalam citra radar adalah nilai reflektivitas. Nilai ini dihitung dari Persamaan (1), dimana  $z$  disebut faktor reflektivitas dengan satuan  $\text{mm}^6/\text{m}^3$  dan  $Z$  disebut nilai reflektivitas, yang dihitung sebagai penjumlahan seluruh partikel dalam satuan dBz (Ernvik, 2002). Data curah hujan harian dari tahun 2018 hingga 2020 dalam milimeter, yang berasal dari 118 titik pengamatan alat Penakar Hujan Obs BMKG, dimana lokasinya ditunjukkan pada Gambar 1 di bawah ini.

$$Z = 10 \log z \quad (1)$$

*Data preprocessing* dilakukan untuk menghilangkan *noise* pada data input. Pada tahap ini digunakan bantuan *library wradlib* pada bahasa pemrograman *python*. Langkah pertama adalah koreksi *vertical profile of reflectivity* (VPR) menggunakan Persamaan (2) yang diasumsikan bahwa reflektivitas  $Z$  dapat dibagi menjadi dua suku orthogonal baik pada koordinat *cartesian*  $(x, y, h)$  maupun sferis  $(r, \theta, \phi)$ , dengan  $Z_{REF}(x, y)$  mewakili faktor reflektivitas pada ketinggian

referensi tertentu  $h_{REF}$  (Berne, 2003). Data nilai reflektivitas dari citra radar yang sudah terkoreksi profil vertikalnya diolah lebih lanjut menggunakan CMAX, yaitu perhitungan nilai reflektivitas tertinggi dalam kolom yang bersesuaian di atas permukaan bumi.

$$Z(r, \theta, \phi) = Z(x, y, h) = Z_{REF}(x, y)z(h) \quad (2)$$

Langkah selanjutnya berupa koreksi atenuasi terhadap *raw data* nilai reflektivitas citra radar untuk mengatasi pelemahan energi pulsa radar yang diterima oleh *receiver*. Atenuasi adalah pelemahan suatu sinyal yang timbul akibat jarak yang semakin jauh. Koreksi atenuasi ini dapat dilakukan dengan teknik *enhancement* menggunakan Persamaan (3), dimana  $i$  adalah *gate* radar,  $K$  adalah atenuasi,  $\Delta r$  adalah panjang *gate*, sementara  $\alpha$  dan  $\beta$  adalah koefisien (Kosasih *et al.*, 2021).

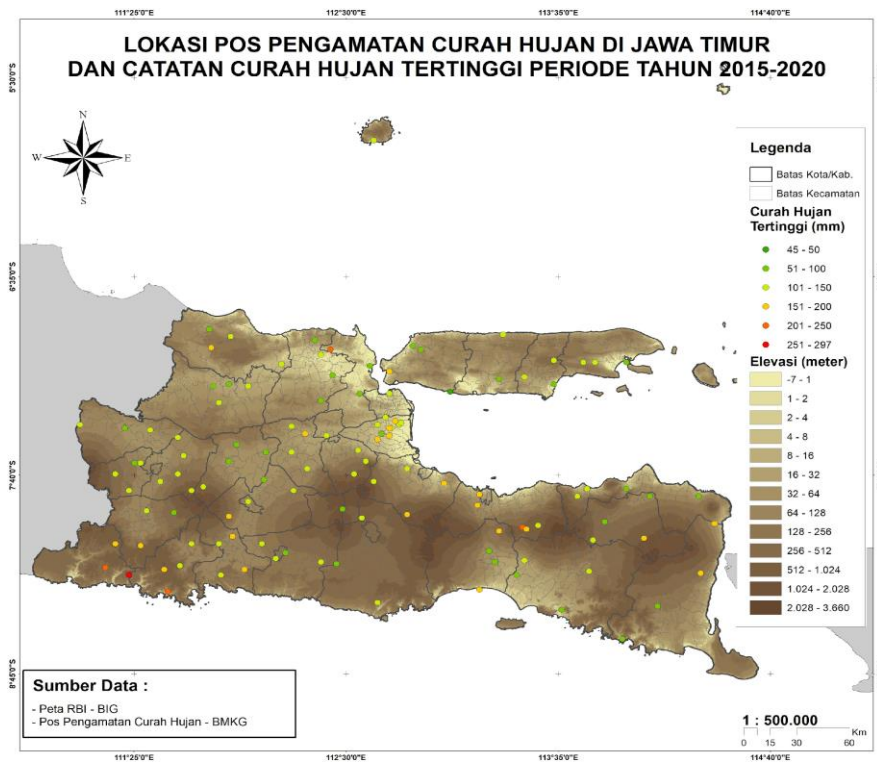
$$K_i = \alpha \left( Z_i + \sum_{j=1}^i K_j \right)^\beta 2\Delta r \quad (3)$$

Pada penelitian ini digunakan *modified Kraemer* untuk koreksi atenuasi. Nilai  $\alpha$  pada rentang  $2,33 \times 10^{-5}$  hingga  $1,67 \times 10^{-4}$  dengan *step* 100. Sementara itu, nilai  $\beta$  diatur pada rentang 0,65 hingga 0,7 dengan *step* 6. Adapun  $\Delta r$  diatur pada nilai 1,0 (Jacobi & Heistermann, 2016).

Selanjutnya, dilakukan penghapusan *clutter* atau partikel bukan tetes hujan. *Clutter* dapat dihilangkan dengan pendekatan Gabella (Gabella & Notarpietro, 2002) dan segmentasi *thresholding* pada Persamaan (4), dimana  $P_z$  adalah nilai hasil *thresholding* pada suatu piksel dan  $Z_0$  merupakan nilai ambang batas dari reflektivitas ( $Z$ ) untuk partikel tetes hujan (He *et al.*, 2019).

$$P_z = \begin{cases} 1 & \text{jika } Z \geq Z_0 \\ 0 & \text{jika } Z < Z_0 \end{cases} \quad (4)$$

Tahap terakhir, dilakukan konversi nilai reflektivitas dari format data *volumetric* menjadi *Temporary Instruction File Format* (TIFF), agar dapat diolah dalam *library TIFFFILE*, yaitu *library* dengan bahasa pemrograman *python* untuk memudahkan pengolahan data geospasial. Sebagai gambaran hasil tahap *preprocessing*, diambil satu studi kasus citra radar yang sudah berformat TIFF, untuk dibandingkan antara citra sebelum dilakukan *preprocessing* dan citra setelah dilakukan *preprocessing*. Citra radar tanggal 21 Februari 2020 pukul 16.00 WIB diambil sebagai studi kasus, karena terdapat kejadian bencana tanah longsor di Kabupaten Ponorogo.



**Gambar 1.** Lokasi pos pengamatan curah hujan di Jawa Timur

Estimasi curah hujan dari citra radar diperoleh dengan data masukan nilai reflektivitas dari CMAX yang diolah dengan algoritma *Precipitation Accumulation* (PAC) menggunakan Persamaan (5), dimana  $R$  adalah curah hujan,  $a$  dan  $b$  adalah koefisien. Algoritma PAC diatur dengan koefisien  $a$  sebesar 200 dan  $b$  sebesar 1,6 (Marshall & Palmer, 1948), yang merupakan standar pengaturan dalam aplikasi *Rainbow*, yaitu aplikasi untuk pemrosesan data citra radar cuaca dari pabrikan radar Gematronik. Persamaan (5) digunakan untuk memperoleh nilai akumulasi curah hujan 24 jam pada setiap piksel, sebagai salah satu data *input* pada proses pelatihan data dengan MLP.

$$Z = aR^b \quad (5)$$


Karena *noise* yang semakin besar pada titik lokasi yang semakin jauh dari pusat radar, maka Persamaan (6) menyajikan penambahan koreksi degradasi jarak jangkauan, dimana  $R_{corr}$  adalah curah hujan terkoreksi,  $r$  adalah jangkauan, serta  $c$  adalah koefisien yang diperoleh dari studi secara lokal (Fulton *et al.*, 1997). Persamaan (6) ini menginspirasi untuk dilakukan pengoptimalan estimasi curah hujan dari algoritma PAC pada Persamaan (5), dengan menambahkan data *input* berupa jarak dari titik lokasi alat penakar hujan ke pusat radar, dalam satuan km. Nilai jarak ini kemudian dinormalisasi pada rentang 0 hingga 1 (Pyle, 1999), dimana nilai 0 merepresentasikan jarak pusat radar ke pusat radar sendiri dan nilai 1 merepresentasikan jarak terjauh dari jangkauan radar, yaitu sejauh 200 km. Data input tersebut hanya diambil pada piksel-piksel yang terdapat

pengamatan curah hujan *in situ*, yang digunakan sebagai data *output*. Dengan demikian, penggunaan algoritma pembelajaran mesin yaitu MLP untuk regresi adalah sebagai pengganti nilai-nilai koefisien  $c$  dari Persamaan (6).

$$R_{corr} = Zr^c \quad (6)$$

Pembelajaran mesin MLP yang digunakan adalah untuk regresi. Dalam tugas regresi, tujuannya adalah untuk memprediksi suatu bilangan real, atau angka *floating-point* dalam istilah pemrograman (Müller & Guido, 2016). Algoritma pembelajaran mesin MLP ada yang diatur tetap dan ada yang diatur sesuai hasil terbaik dari simulasi percobaan. Beberapa pengaturan yang ditetapkan adalah fungsi aktivasi *Rectified Linear Unit* (ReLU), algoritma optimasi Adam, nilai *learning rate* 0.0001, dan iterasi maksimum 1000. Sementara itu, nilai *depth* atau jumlah *hidden layers*, ditentukan berdasarkan hasil simulasi percobaan terbaik antara rentang 5 hingga 100 *hidden layers* dengan *step* 5. *Mean Squared Error* (MSE) pada Persamaan (8) digunakan sebagai tolak ukur untuk menentukan jumlah *hidden layers* terbaik antara rentang tersebut, yang kemudian digunakan dalam arsitektur MLP pada tahap pelatihan data. Output  $y_i$  sebagai estimasi curah hujan pada persamaan (7) adalah *perceptron* di lapisan kedua yang mengambil unit *hidden* sebagai *inputnya*, dimana  $i = \{1, 2, \dots, k\}$ . Ada juga unit bias di lapisan *hidden*, yang dilambangkan dengan  $z_0$ , dan  $v_{i0}$  adalah bobot bias (Alpaydin, 2010). Struktur MLP secara sederhana ditunjukkan pada Gambar 2.

$$y_i = \sum_{h=1}^H v_{ih}z_h + v_{i0} \quad (7)$$



Gambar 2. Struktur MLP

Data sepanjang tahun 2018–2019 digunakan sebagai pelatihan data, sedangkan data sepanjang tahun 2020 digunakan sebagai pengujian data. Setelah dilakukan pengujian data, hasil keluaran estimasi curah hujan diverifikasi menggunakan *Root Mean Squared Error* (RMSE), *skill score* (SS), dan *mean bias* (MB).

Nilai RMSE digunakan untuk memperoleh nilai akurasi, yang dihitung menggunakan Persamaan (8). RMSE adalah akar kuadrat dari MSE. Dalam Persamaan (8), *f* mengindikasikan nilai curah hujan yang diestimasi, sedangkan *o* mengindikasikan nilai curah hujan hasil pengamatan, yang mana *f, o* ∈ *R*. Sementara itu, *N* adalah jumlah data dan *i* merupakan indeks setiap data, yang mana *i* ∈ *N*. Semakin kecil nilai RMSE, maka nilai akurasi semakin tinggi, yang mana nilai sempurna dari RMSE adalah 0 (Gordon & Shaykewich, 2000).

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (f_i - o_i)^2} \quad (8)$$

SS pada Persamaan (9) digunakan untuk mendapatkan nilai *skill*, dimana *RMSE<sub>f</sub>* adalah nilai RMSE dari estimasi MLP atau hasil pengujian data, sedangkan *RMSE<sub>b</sub>* adalah nilai RMSE dari hasil pelatihan data sebagai *benchmark*. Dengan demikian, *f* merupakan nilai curah hujan yang diestimasi pada periode tahun 2020, sedangkan *b* merupakan nilai curah hujan yang diestimasi pada periode tahun 2018-2019. Nilai SS dikatakan memiliki *skill* yang baik jika bernilai positif, sedangkan nilai negatif menunjukkan nilai *skill* belum baik karena nilai akurasi hasil pengujian lebih kecil daripada hasil pelatihan data (Gordon & Shaykewich, 2000).

$$SS = 1 - \frac{RMSE_f}{RMSE_b} = 1 - \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N (f_i - o_i)^2}}{\sqrt{\frac{1}{N} \sum_{i=1}^N (b_i - o_i)^2}} \quad (9)$$

MB pada Persamaan (10) digunakan untuk mendapatkan nilai reliabilitas, yang juga nilai 0 menjadi nilai sempurna dari MB. Jika bernilai positif, maka model melakukan estimasi yang *overestimate*, sedangkan nilai negatif menunjukkan model mengestimasi secara *underestimate*. Dalam persamaan (10), *f* mengindikasikan nilai yang diestimasi, *o* mengindikasikan nilai pengamatan, dan *N* adalah jumlah data, yang mana *f, o* ∈ *R* dan *i* ∈ *N* (Gordon & Shaykewich, 2000).

$$MB = \frac{1}{N} \sum_{i=1}^N (f_i - o_i) \quad (10)$$

Terakhir, dilakukan simulasi model MLP untuk estimasi curah hujan radar pada rentang 0–200 mm dan jarak ternormalisasi 0–1 dalam bentuk grafik *surface*. Model MLP yang diperoleh dari hasil pelatihan data juga diterapkan pada studi kasus yang masih sama, yaitu pada citra radar tanggal 21 Februari 2020 pukul 16.00 WIB.

### 3. HASIL DAN PEMBAHASAN

Setelah dilakukan koreksi VPR pada Persamaan (2) dan koreksi atenuasi dengan Persamaan (3), kemudian dicari nilai *Z<sub>0</sub>* dalam Persamaan (4). Gambar 3 menyajikan sebaran data antara nilai reflektivitas maksimum yang terjadi hujan dan yang tidak terjadi hujan. Pada Gambar 3(a), diperoleh rata-rata nilai reflektivitas maksimum dalam sehari yang tidak terjadi hujan sebesar 1,93 dBz. Nilai reflektivitas ini kemudian digunakan sebagai ambang batas bukan partikel-

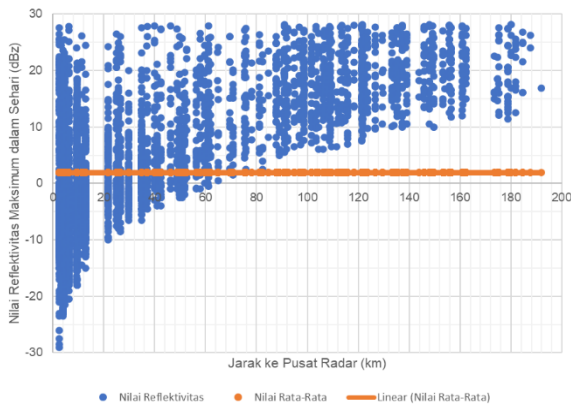
partikel hujan atau *clutter*, yaitu nilai yang dibawah 1,93 dBz. Adapun pada Gambar 3(b), diperoleh rata-rata nilai reflektivitas maksimum dalam sehari yang terjadi hujan sebesar 10,90 dBz.

Setelah dilakukan *clutter removal* menggunakan teknik segmentasi *thresholding* dengan  $Z_0$  sebesar 1,93 dBz, didapatkan nilai reflektivitas yang dapat digunakan sebagai data pelatihan pembelajaran mesin MLP. Gambar 4 menyajikan perbandingan citra, sebelum dan sesudah dilakukan *clutter removal*. Pada Gambar 4(a) terlihat banyak piksel dengan nilai reflektivitas di antara 0–5 dBz pada jarak yang dekat dengan pusat radar (Ditunjukkan pada area dalam lingkaran hitam putus-putus). Sementara itu, pada Gambar 4(b) terlihat *echo* tersebut sudah dihilangkan karena dianggap *clutter*.

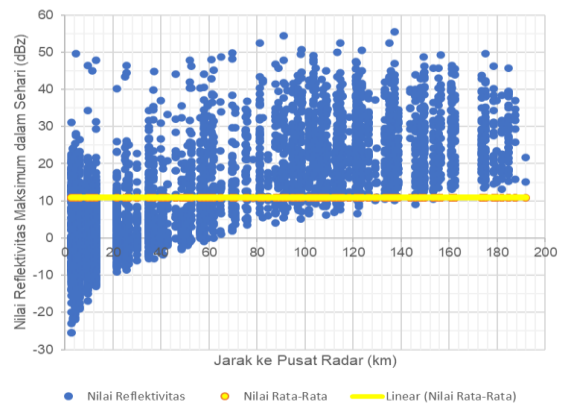
Berdasarkan perbandingan citra pada Gambar 4, terlihat ada perbedaan nilai reflektivitas yang signifikan pada wilayah Kabupaten

Lumajang (ditunjukkan pada area dalam lingkaran coklat putus-putus). Dari perbedaan tersebut, dapat disimpulkan bahwa nilai reflektivitas citra radar mengalami pelemahan. Koreksi atenuasi radar juga terlihat jelas pada wilayah Bondowoso (ditunjukkan pada area dalam lingkaran abu-abu putus-putus).

Dari simulasi percobaan jumlah *hidden layers* yang bervariasi pada rentang nilai 5 hingga 100, diperoleh bahwa jumlah *hidden layers* dengan *error* terkecil untuk model MLP adalah 65, seperti yang ditunjukkan pada Gambar 5. Model MLP dengan jumlah *hidden layers* ini memperoleh nilai MSE sebesar 262. Setelah simulasi percobaan dengan skenario jumlah *hidden layers* sebanyak 65, nilai MSE kembali membesar, sehingga dapat diasumsikan bahwa tidak ada nilai MSE yang lebih baik lagi dari skenario jumlah *hidden layers* sebanyak 65.

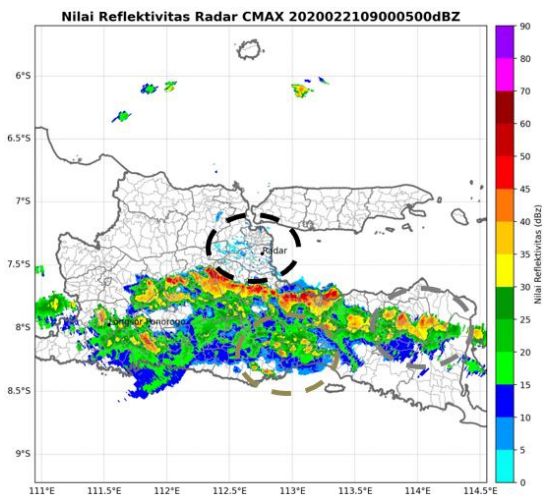


(a) Sebaran data reflektivitas maksimum dalam sehari yang tidak terjadi hujan

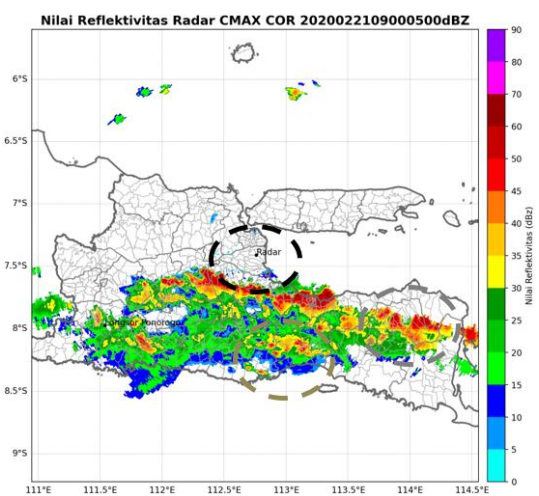


(b) Sebaran data reflektivitas maksimum dalam sehari yang terjadi hujan

**Gambar 3.** Perbandingan sebaran data reflektivitas maksimum dari citra radar antara yang tidak terjadi hujan dan terjadi hujan




(a) Citra sebelum dilakukan *clutter removal*



(b) Citra setelah dilakukan *clutter removal*

**Gambar 4.** Perbandingan citra sebelum dan sesudah dilakukan *clutter removal*.



**Gambar 5.** Nilai MSE dari percobaan pelatihan data MLP dengan rentang 5–100 *hidden layers*

Hasil pengujian Model MLP dengan *hidden layers* 65, memperoleh nilai RMSE sebesar 16,25 mm. Nilai error ini masih dalam kategori hujan ringan untuk perhitungan curah hujan harian (BMKG, 2016). Adapun nilai SS yang diperoleh sebesar -0,33, yang mana nilai negatif menunjukkan hasil pengujian model masih belum lebih baik dari *benchmarknya*. Adapun nilai MB yang diperoleh sebesar -0,83 mm, yang menunjukkan bahwa nilai estimasi cenderung lebih kecil daripada nilai *ground truth*, sehingga dapat dikatakan model cenderung *underestimate* dengan nilai rata-rata 0,83 mm. Namun nilai bias ini sangat kecil karena masih mendekati nilai sempurnanya, yaitu 0.


Tabel 1 menyajikan perbandingan hasil uji verifikasi Model MLP dengan *hidden layers* 65 terhadap 2 penelitian sebelumnya, yaitu Model MLP dengan *hidden layers* 2 (Waskita *et al.*, 2020) dan Model MLP dengan *hidden layers* 3 (Lazri *et al.*, 2022). Model MLP dengan *hidden layers* 65 unggul dalam nilai akurasi dan reliabilitas, tetapi masih kurang baik dalam nilai *skill* dibandingkan Model MLP dengan *hidden layers* 3. Namun perbedaannya sangat kecil yaitu, hanya lebih *underestimate* sebesar 0,03 mm. Dengan demikian, Model MLP dengan *hidden layers* 65 dapat dikatakan lebih optimal dalam mengestimasi curah hujan berdasarkan citra radar dibandingkan dua penelitian sebelumnya.

**Tabel 1.** Perbandingan uji verifikasi Model MLP

Metode	Akurasi (mm)	Skill	Reliabilitas (mm)
Waskita <i>et al.</i> , 2020	27,17	-0,33	-15,80
Lazri <i>et al.</i> , 2022	16,69	-0,30	-4,28
MLP 65 <i>Hidden Layers</i>	16,25	-0,33	-0,83

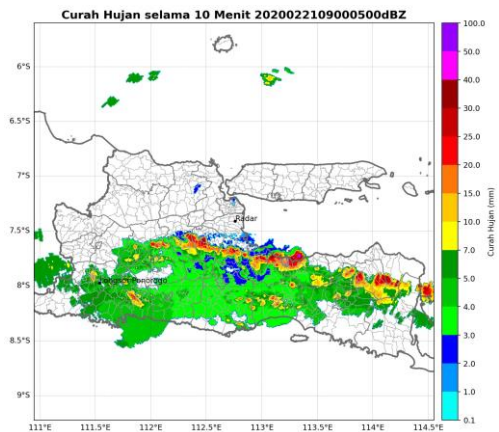
Dalam visualisasi model MLP pada Gambar 6, juga menunjukkan hubungan semakin besar curah hujan pada radar dan semakin jauh jarak piksel radar ke pusat radar, maka estimasi nilai

curah hujan MLP juga mengalami peningkatan. Hal ini diduga karena nilai reflektivitas pada jarak yang lebih jauh dari pusat radar, terdapat lebih banyak menjumpai *noise* selama hamburan balik energi *pulse* radar menuju *receiver* radar. Dengan demikian, nilai bobot bias ( $v$ ) pada Persamaan (7) akan semakin besar seiring semakin jauhnya jarak dari pusat radar.



**Gambar 6.** Simulasi Model MLP untuk estimasi curah hujan radar pada rentang 0–200 mm dan jarak ternormalisasi 0–1

Gambar 7 menunjukkan hasil keluaran citra dengan studi kasus yang sama dengan Gambar 4. Terlihat penyebaran nilai curah hujan radar dengan intensitas yang tinggi pada citra merata dari yang dekat dengan radar hingga jauh dari radar. Namun sebaliknya, nilai intensitas curah hujan yang rendah pada piksel yang jauh dari pusat radar masih kurang terestimasi dengan baik oleh model MLP. Hal ini diduga karena curah hujan dengan intensitas ringan pada jarak yang jauh dari pusat radar memiliki energi *pulse* radar yang kecil dalam hamburan baliknya. Selain itu, semakin jauh dari pusat radar, maka *noise* juga semakin banyak. Dengan demikian, energi *pulse* radar seluruhnya tidak dapat sampai diterima oleh *receiver* radar sebab terhalang *noise*.



**Gambar 7.** Penerapan Model MLP dengan jumlah *hidden layers* 65 pada pada citra radar tanggal 21 Februari 2020 pukul 16.00 WIB

#### 4. KESIMPULAN

Berdasarkan pembahasan di atas dapat disimpulkan bahwa metode MLP dapat digunakan dalam mengatasi tantangan untuk mengestimasi curah hujan dengan besaran *noise* yang bervariasi pada setiap jarak suatu piksel citra radar ke pusat radar, sehingga mendekati hasil pengamatan *in situ*. Proses data *preprocessing* juga mampu menjawab tantangan memisahkan antara partikel air hujan dan partikel bukan air hujan atau *clutter*. Proses ini, membuat model MLP hanya mengestimasi nilai reflektivitas yang diklasifikasikan sebagai partikel air hujan. Model MLP diatur dengan jumlah *hidden layers* 65 dalam pelatihan data, berdasarkan hasil percobaan rentang 5–100 *hidden layers* sebelumnya. Hasil pengujian data dari model ini memperoleh nilai *error* yang masih dalam kategori intensitas curah hujan ringan dalam kategori curah hujan harian. Selain itu, nilai bias yang diperoleh juga menunjukkan model cenderung hanya sedikit *underestimate*. Dibandingkan penelitian Waskita et al. (2020) dan Lazri et al. (2022), Model MLP dengan *hidden layers* 65 lebih optimal dalam mengestimasi curah hujan berdasarkan citra radar.

Adapun hasil pengujian data yang masih perlu perbaikan, yaitu meningkatkan nilai *skill* agar bernilai positif, dengan melakukan simulasi percobaan terlebih dahulu terhadap jenis pengaturan lainnya, misal *learning rate*, untuk menentukan skema pengaturan algoritma MLP terbaik. Tantangan baru juga ditemukan, yaitu mengatasi energi *pulse* radar yang tidak dapat sampai diterima oleh *receiver* radar sebab terhalang *noise* dan partikel air hujannya kecil pada jarak yang jauh dari pusat radar. Namun, model estimasi curah hujan MLP ini dapat digunakan untuk membantu operasi TMC, khususnya dalam meminimalisir bencana hidrometeorologi, sebab berfokus pada awan penghujan dengan nilai reflektivitas yang tinggi. Hal ini karena model MLP mampu mengestimasi intensitas curah hujan yang tinggi dengan akurasi yang cukup tepat, baik pada wilayah dengan jangkauan yang dekat dari radar, maupun yang jauh dari radar.

#### UCAPAN TERIMAKASIH

Ucapan terimakasih ditujukan kepada Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi, yang telah memberikan pendanaan riset dengan nomor kontrak induk 112/E5/PG.02.00.PL/2023 dan nomor kontrak turunan 1996/PKS/ITS/2023.

#### DAFTAR PUSTAKA

- Alpaydin, E. (2010). Introduction to machine learning. Massachusetts: Massachusetts Institute of Technology.
- Berne A., Delrieu, G., Andrieu, H., Creutin, J. D. (2003). Influence of the Vertical Profile of Reflectivity on Radar-Estimated Rain Rates at Short Time Steps. *Journal of Hydrometeorology*, 5, 296-310.
- BMKG, (2016), Pengamatan dan Pengolahan Data Iklim di Lingkungan Badan Meteorologi, Klimatologi, dan Geofisika. Peraturan Kepala BMKG Nomor 4 Tahun 2016, Jakarta.
- BNPB. (2023). Data Informasi Bencana Indonesia. (<https://dibi.bnpb.go.id/home/index2>).
- Ernvik, A. (2002). 3D Visualization of Weather Radar Data. Tesis. Linköping: Linköping University.
- Fulton, R. A., Breidenbach, J. P., Seo, D. J., Miller, D. A., O'Bannon, T. (1997). The WSR-88D Rainfall Algorithm. *Weather and Forecasting*, 13, 377-395.
- Gabella, M., Notarpietro. (2002). Ground Clutter Characterization and Elimination in Mountainous Terrain. *Proceedings of ERAD*, 305-311.
- Gordon, N., Shaykewich, J. (2000). TD No. 1023 Guidelines on Performance Assessment of Public Weather Services. Geneva: World Meteorological Organization.
- He, T., Einflat, T., Zhang, J., Hua, J., Cai, Y. (2019). New Algorithm for Rain Cell Identification and Tracking in Rainfall Event Analysis. *Atmosphere*, 10(532). doi:10.3390/atmos10090532
- Jacobi, S., Heistermann, M. (2016). Benchmarking Attenuation Correction Procedures for Six Years of Single-Polarised C-Band Weather Radar Observations in South-West Germany. *Geomat. Nat. Haz. Risk.*, 7(6), 1785-1799, doi:10.1080/19475705.2016.1155080.
- Kasebzadeh, P. (2020). Clutter Detection in Radar Applications. Tesis. Department of Computer and Information Science, Linköping University.
- Kosasih, A., Hartono, Jatmiko, R. J. (2021). Pengaruh Koreksi Atenuasi Radar Cuaca terhadap Perhitungan Estimasi Curah Hujan di Jawa Timur. *Jurnal Teknosains*, 10(2), 111-124. doi:10.22146/teknosains.53452
- Lazri, M., Ouallouch, F., Labadi, K., Ameer, S. (2022). Extreme Learning Machine versus Multilayer Perceptron for Rainfall Estimation from MSG. *Data E3S Web of Conferences*, 353, 01006. doi:10.1051/e3sconf/202235301006



- Marshall, J. S., Palmer, W. M. (1948). The distribution of raindrops with size. *J. Meteorol.* 5, 165–166.
- Müller, A. C., Guido, S. (2016). Introduction to Machine Learning with Python. California: O'Reilly Media.
- Prasetyo, B., Pusparini, N., Irwandi, Fitria, W. (2019). Aplikasi Radar Cuaca untuk Identifikasi Fluktuasi Kondisi Cuaca Ekstrem (Studi Kasus: Banjir di Kota Medan tanggal 5 Oktober 2018). *Jurnal Sains & Teknologi Modifikasi Cuaca*, 20(1), 13-21.
- Pyle, D. (1999). Data Preparation for Data Mining. 1 ed. Morgan Kaufmann.
- Renggono, F. (2015). Analisis Kemunculan Awan Hujan berdasarkan Jenisnya untuk Mendukung Kegiatan Modifikasi Cuaca. *Jurnal Sains & Teknologi Modifikasi Cuaca*, 16(2), 83-89.
- Seto, T. H., Sutrisno, Tikno, S., Widodo, F. H. (2013). Pemanfaatan Teknologi Modifikasi Cuaca untuk Redistribusi Curah Hujan dalam rangka Tanggap Darurat Banjir di Provinsi DKI Jakarta dan Sekitarnya. *Jurnal Sains & Teknologi Modifikasi Cuaca*, 14(1), 1-11.
- Shin, K., Song, J. J., Bang, W., Lee, G. W. (2021). Quantitative Precipitation Estimates Using Machine Learning Approaches with Operational Dual-Polarization Radar Data. *Remote Sensing*, 13 (694). doi:10.3390/rs13040694
- Stanley, T. A., Kirschbaum, D. B., Benz, G., Emberson, R. A., Amatya, P. M., Medwedeff, W., Clark, M. K. (2021). Data-Driven Landslide Nowcasting at the Global Scale. *Frontiers in Earth Science*, 9. doi:10.3389/feart.2021.640043
- Velasco, L. C. P., Serquina, R. P., Zamad, M. S. A. A., Juanico, B. F., Lomocso, J. C. (2019). Week-ahead Rainfall Forecasting Using Multilayer Perceptron Neural Network. *Procedia Computer Science* 161, 386-397. doi:10.1016/j.procs.2019.11.137
- Waskita, T. P., Saputro, A. H., Sopaheluwakan, A., Ryan, M. (2020). Machine Learning System for Rainfall Estimates from Single Polarization Radar. *Proceedings of the International Conferences on Information System and Technology (CONRIST 2019)*, 41-48. doi:10.5220/0009409400410048