

Klasifikasi Curah Hujan Menggunakan *Neuro-Fuzzy System* Melalui Citra Radar Cuaca

Bagaskara Ilham Abadi^{*1}, Raden Sumiharto²

¹Program Studi Elektronika dan Instrumentasi, FMIPA, UGM, Yogyakarta, Indonesia

²Departemen Ilmu Komputer dan Elektronika, FMIPA UGM, Yogyakarta, Indonesia

e-mail: ^{*1}bagaskara.i@mail.ugm.ac.id, ²r_sumiharto@ugm.ac.id

Abstrak

Intensitas curah hujan dapat diukur salah satunya melalui pembacaan nilai reflektivitas butir air hujan pada radar cuaca. Nilai reflektivitas direpresentasikan melalui warna pada visualisasi citra radar dua dimensi. Berdasarkan beberapa pendekatan metode klasifikasi kondisi cuaca melalui data radar yang telah berhasil dilakukan, dirancanglah sistem untuk melakukan klasifikasi curah hujan yang sesuai kondisi cuaca pada suatu wilayah dengan memanfaatkan citra radar cuaca.

Implementasi sistem dilakukan dalam beberapa tahapan, yaitu pra pengolahan, ekstraksi fitur dan pelabelan, serta klasifikasi. Pra pengolahan dilakukan untuk memvisualisasikan data radar dari Stasiun Klimatologi Yogyakarta ke dalam citra dua dimensi. Setelah dilakukan pengambilan fitur dengan metode RGB dan HSV serta pelabelan kelas hujan, kemudian dilakukan klasifikasi menggunakan algoritma Neuro-fuzzy dengan arsitektur Adaptive Neuro-fuzzy Inference System (ANFIS). Hasil penelitian menunjukkan bahwa algoritma Neuro-fuzzy System mampu mengklasifikasikan curah hujan lebih baik pada fitur RGB dengan akurasi 85,02% dan presisi 86,19%, sedangkan untuk fitur HSV dihasilkan akurasi 82,68%, presisi 86,67%.

Kata kunci—Pengolahan citra, radar cuaca, ANFIS, cross validation

Abstract

Rainfall intensity can be measured one of them through the reading of the reflectivity of raindrops on the weather radar. Reflectivity values are represented through colors in the visualization of two-dimensional radar images. Based on several approaches to the classification of weather conditions through radar data that has been successfully carried out, a system is designed to classify rainfall according to weather conditions in an area by utilizing weather radar imagery.

The system implementation is carried out in several stages, namely pre-processing, feature extraction and labeling, and classification. Pre-processing is done to visualize radar data from Yogyakarta Climatology Station into a two-dimensional image. After capturing features using the RGB and HSV methods and labeling the rain class, classification is performed using the Neuro-fuzzy algorithm with the Adaptive Neuro-fuzzy Inference System (ANFIS) architecture. The results showed that the Neuro-fuzzy System algorithm was able to classify rainfall better on the RGB feature with an accuracy of 85.02% and a precision of 86.19%, while for the HSV feature the accuracy was 82.68%, 86.67% precision.

Keywords—Image processing, weather radar, ANFIS, cross validation

1. PENDAHULUAN

Identifikasi cuaca sangat diperlukan untuk memberikan informasi tentang kondisi cuaca dalam kaitannya menunjang aktivitas manusia sehari-hari. Kondisi cuaca yang umum terjadi di daerah tropis yang hanya memiliki dua musim seperti Indonesia ialah hujan dan tidak hujan. Hujan sendiri dapat dikategorikan menjadi hujan ringan, sedang, dan lebat. Salah satu parameter yang digunakan untuk pengelompokan tersebut yaitu tingkat intensitas curah hujan. Selain dari alat penakar hujan, intensitas curah hujan juga bisa diperoleh dari pembacaan nilai reflektivitas butir air hujan pada radar cuaca. Salah satu merek radar cuaca yang digunakan oleh BMKG (Badan Meteorologi, Klimatologi, dan Geofisika) adalah radar merek Baron yang menyimpan nilai reflektivitas dalam format volumetrik [1].

Salah satu perangkat lunak *open source* yang dapat digunakan untuk mengolah data radar adalah Wradlib. Wradlib memiliki beberapa kemampuan untuk mengolah data radar cuaca dari berbagai produk radar, seperti membaca format data, mengonversi reflektivitas ke dalam intensitas curah hujan, hingga memvisualisasikan data [2]. Hasil pengolahan data yang diperoleh radar cuaca divisualisasikan ke dalam bentuk citra dua dimensi yang memuat informasi nilai reflektivitas, yang biasanya direpresentasikan melalui warna. Perbedaan warna pada citra radar cuaca yang menunjukkan perbedaan nilai reflektivitas butir air pada awan, dapat digunakan sebagai parameter untuk mengklasifikasikan curah hujan melalui pengolahan citra digital.

Penelitian mengenai klasifikasi terhadap beberapa hal yang berhubungan dengan kondisi cuaca melalui data radar cuaca telah banyak dilakukan menggunakan berbagai metode dengan performa yang bermacam-macam. [3] melakukan analisis terjadinya hujan berdasarkan klasifikasi jenis awan hujan yang muncul, yaitu awan konvektif dan *stratiform* di DAS Larona menggunakan metode *thresholding*. Hasil klasifikasi sistem tersebut lumayan baik, akan tetapi belum mampu untuk diterapkan pada data set awan yang banyak. Penelitian untuk mengklasifikasi curah hujan dengan metode Naïve Bayesian dilakukan oleh [4]. Curah hujan diklasifikasikan ke dalam tiga katagori yaitu ringan, normal, dan deras. Penentuan klasifikasi didasarkan pada lima fitur yaitu suhu minimum, suhu maksimum, kelembaban rata-rata, lama penyinaran, dan kecepatan angin. Penelitian tersebut menghasilkan tingkat akurasi klasifikasi curah hujan untuk katagori ringan, normal, dan deras berturut turut sebesar 79.5%, 40.9%, dan 86.4%.

Hal yang dilakukan oleh [5], klasifikasi *hydrometeor* menggunakan *neuro-fuzzy system* yang merupakan gabungan dari algoritma *fuzzy logic* dan *neural network*. Metode ini memiliki keunggulan lebih yaitu selain memiliki tingkat keakuratan klasifikasi yang tinggi dari *fuzzy logic*, metode ini juga mampu membuat sistem belajar dan meningkatkan performa pengklasifikasian berdasarkan data masa lalu melalui algoritma pembelajaran *neural network*. Hasil klasifikasi menggunakan metode ini menunjukkan tingkat keakuratan yang cukup tinggi ketika dibandingkan dengan data *in situ*. Keandalan *neuro fuzzy* juga dibuktikan oleh [6] untuk melakukan prediksi curah hujan dengan memanfaatkan data dasarian curah hujan, suhu udara, kelembapan udara, dan kecepatan angin. Metode *neuro fuzzy* yang digunakan berdasarkan arsitektur Adaptive Neuro Fuzzy Inference System (ANFIS) dengan memanfaatkan algoritme backpropagation steepest descent dan least square estimator (LSE) untuk proses pembelajaran. Hasil pengujian dari penelitian ini didapatkan nilai RMSE sebesar 1,88.

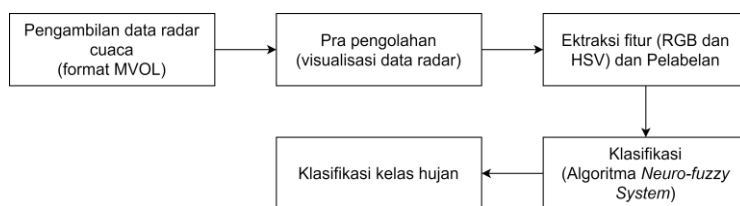
Melihat hasil klasifikasi dengan *neuro-fuzzy system* yang cukup baik dalam mengklasifikasikan *hydrometeor*, maka dirancanglah sistem klasifikasi curah hujan menggunakan algoritma *Neuro-fuzzy System* yang diterapkan pada citra radar cuaca.

2. METODE PENELITIAN

2.1 Analisis Kebutuhan Sistem

Pada penelitian ini data yang digunakan berupa data format MVOL yang berisi berbagai macam informasi hasil pengukuran radar. Data tersebut harus diolah terlebih dahulu untuk dapat menyajikan informasi yang bermanfaat. Informasi yang digunakan pada penelitian ini yaitu informasi nilai reflektivitas tangkapan radar. Pustaka Wradlib digunakan untuk mengolah data reflektivitas menjadi citra yang menampilkan informasi C-MAX [7]. Citra tersebut kemudian diolah menggunakan pustaka OpenCV untuk mendapatkan fitur warna yang memuat informasi parameter reflektivitas. Selanjutnya algoritma *Neuro-fuzzy System* akan mengklasifikasikan fitur warna ke dalam beberapa kategori hujan. Data yang digunakan sebagai pembandingan hasil klasifikasi adalah data CSV dari produk Maxdisplay yang berisi nilai C-MAX (reflektivitas maksimal) dengan ukuran 800x800. Data tersebut merupakan hasil keluaran dari komputer Stasiun Klimatologi Yogyakarta.

Keseluruhan program sistem ditulis menggunakan bahasa pemrograman Python untuk memudahkan pengembangan sistem karena pustaka Wradlib hanya tersedia pada bahasa pemrograman tersebut. Sistem ini dibagi ke dalam tiga tahapan utama, yaitu tahap pra pengolahan yang memanfaatkan pustaka Wradlib, tahap ekstraksi fitur yang memanfaatkan pustaka OpenCV [8], dan tahap klasifikasi *Neuro-fuzzy System* yang memanfaatkan pustaka TensorFlow. Alur rancangan sistem secara keseluruhan ditunjukkan melalui diagram blok rancangan sistem pada Gambar 1.



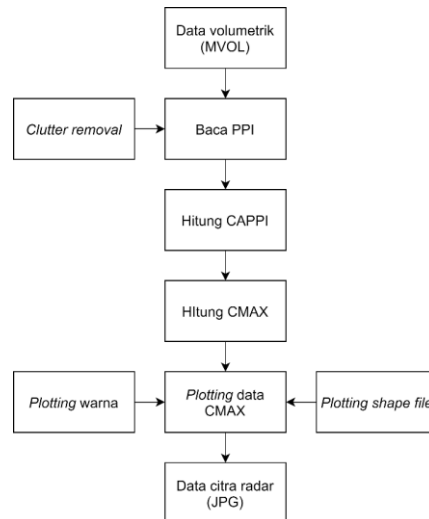
Gambar 1 Diagram blok rancangan sistem

2.2 Pengambilan data radar cuaca

Tahap awal penelitian ini adalah mendapatkan data *raw* hasil penginderaan radar cuaca. Data radar ini memiliki format data MVOL yang diperoleh dari radar cuaca merk Baron milik Stasiun Klimatologi Yogyakarta. Dari data ini diambil informasi reflektivitas yang merepresentasikan intensitas hujan.

2.3 Pra pengolahan

Tahap pra pengolahan memproses masukan data volumetrik menggunakan pustaka Wradlib untuk divisualisasikan dalam bentuk citra digital dua dimensi. Proses pengolahan tersebut ditunjukkan melalui diagram alur pada Gambar 2. Data volumetrik dari radar Stasiun Klimatologi Yogyakarta akan dibaca oleh Wradlib-python dengan format HDF5 untuk diambil informasi nilai reflektivitas (Z/dBZ) yang ditangkap radar. Data reflektivitas (Z/dBZ) dari radar akan dibaca dalam PPI (tampilan pada sudut kemiringan tertentu). Selanjutnya dilakukan proses pengoreksian *error* yang berupa *clutter removal* untuk menghapus *noise* yang disebabkan oleh faktor non-meteorologis seperti adanya objek lain di udara [9]. Data reflektivitas akan diubah ke bentuk CAPPI melalui fungsi *.CAPPI* pada Wradlib berdasarkan *gridding* tiga sumbu (xyz) kemudian diambil nilai maksimal CAPPI pada kolom ketinggian untuk ditampilkan sebagai CMAX yang akan di-*plot*. Format CMAX dipilih karena disesuaikan dengan format data Maxdisplay dari Stasiun Klimatologi Yogyakarta sebagai data acuan yang berisi data reflektivitas pada bentuk CAPPI-MAX (CMAX).




Gambar 2 Diagram alur pengolahan data radar dengan Wrادlib

Tahap selanjutnya yaitu melakukan *plotting* data dBZ (CMAX) dengan batas koordinat x dan y yang sesuai ukuran *gridding* pada data CMAX yaitu 800x800, dan memberi warna RGB untuk tiap rentang data dBZ yang ditampilkan. Selain itu, juga dilakukan *layering* dengan melakukan *plotting shape file* untuk memperjelas visualisasi batas antar wilayah kabupaten yang diamati. Hasil visualisasi citra radar tersebut disimpan dalam format gambar JPG untuk digunakan sebagai masukan sub proses berikutnya dari sistem yang dibuat.

2.4 Ekstraksi fitur dan pemberian label

Pada tahap ini, citra radar dua dimensi diekstrak untuk mendapatkan fitur warna yang memuat informasi nilai reflektivitas yang merepresentasikan tingkat curah hujan. Metode ekstraksi fitur yang digunakan pada penelitian ini adalah RGB (*Red, Green, Blue*) dan HSV (*Hue, Saturation, Value*). RGB dipilih karena merupakan model representasi warna yang paling umum digunakan. Selain itu, dalam pengisian warna sebagai representasi nilai dBZ pada data radar juga menggunakan metode RGB. Metode ini akan dibandingkan dengan metode HSV untuk mengetahui mana yang menghasilkan klasifikasi lebih baik. Model HSV sendiri dinilai mampu menampilkan warna dengan spektrum yang lebih luas yang mampu ditangkap mata manusia [10].



Gambar 3 Diagram alur ekstraksi fitur dan pemberian label

Selain mengekstrak fitur dari citra radar, pada tahap ini juga dilakukan pemberian label kelas hujan untuk setiap kombinasi fitur yang diekstrak pada tiap *dataset*. Label kelas tersebut didapatkan dari produk Maxdisplay dari Stasiun Klimatologi Yogyakarta yang berisi nilai reflektivitas (dBZ) dalam format CSV. Secara keseluruhan proses ekstraksi fitur dan pemberian label kelas hujan pada penelitian ini seperti ditunjukkan melalui blok diagram pada Gambar 3.

2.4.1 Ekstraksi fitur

Citra hasil pengolahan data radar (JPG) dibaca menggunakan pustaka OpenCV, lalu dipotong bagian pinggirnya hingga lingkaran yang berisi plot data berhimpitan dengan tepi gambar dan di-*resize* ke ukuran 800x800 *pixel* menyesuaikan bentuk dan ukuran data CSV produk Maxdisplay. Pada penelitian ini, wilayah yang masuk ke dalam daerah pengamatan hanyalah wilayah Daerah Istimewa Yogyakarta dan sekitarnya. Oleh karena itu, dibuat batas wilayah pengamatan sesuai dengan koordinat *pixel*. Guna meningkatkan performa sistem, maka dibuatlah jendela pengamatan yang lebih kecil di dalam daerah pengamatan. Jendela pengamatan ini dibuat dengan membagi jumlah *pixel* di dalam daerah pengamatan ke dalam wilayah yang lebih sempit dengan ukuran $n \times n$, dimana n bervariasi dari 3 hingga 16. Dengan jumlah data gambar dan batas keseluruhan wilayah pengamatan yang sama, tentunya ukuran jendela pengamatan yang semakin kecil akan menghasilkan total *dataset* yang lebih banyak, begitu pun sebaliknya.

Tahap selanjutnya yaitu merata-rata tiap fitur pada gambar sesuai panjang ukuran jendela pengamatan yang digunakan. Dikarenakan secara *default* OpenCV akan membaca file gambar sebagai model BGR, maka untuk ekstraksi dengan metode RGB tinggal menyesuaikan urutan fiturnya saja. Sementara untuk metode HSV perlu dilakukan konversi dari BGR ke HSV terlebih dahulu. Pada proses merata-rata ini warna putih dan hitam perlu dihilangkan terlebih dahulu agar tidak mempengaruhi hasil rata-rata, karena warna hitam berasal dari hasil *plotting shape file*. Proses pada tahap ini akan menghasilkan 1 data yang berisi 3 elemen RGB/HSV rata-rata untuk setiap 1 ukuran jendela pengamatan. Selanjutnya tiap elemen RGB/HSV untuk setiap data akan dikelompokkan sendiri-sendiri ke dalam masing-masing variabel.

2.4.2 Pelabelan

Proses pembuatan label dari file CSV Maxdisplay, dikerjakan dalam urutan langkah yang hampir sama dengan ekstraksi fitur, mulai dari membaca file CSV dengan nama yang sama dengan JPG, memilih data amat sesuai dengan ukuran jendela pengamatan dan koordinat *pixel* yang sama dengan yang digunakan pada gambar JPG, hingga merata-rata nilai dBZ sejumlah ukuran jendela pengamatan yang diterapkan. Berdasarkan ketentuan dari data Stasiun Klimatologi Yogyakarta, nilai dBZ yang dipakai hanyalah lebih atau sama dengan 5 dBZ, sehingga untuk daerah dengan nilai di bawah 5 dBZ akan dianggap bernilai 5 dBZ karena nilainya terlalu kecil. Selanjutnya hasil rata-rata nilai dBZ untuk setiap jendela pengamatan akan diklasifikasikan ke dalam 6 kelas berdasarkan klasifikasi hujan dari Stasiun Klimatologi Yogyakarta. Nilai yang telah berupa kelas hujan tersebut kemudian digabungkan dengan nilai masing-masing fitur warna RGB/HSV untuk index data yang sama membentuk sebuah tabel. Tabel tersebut lah yang berisi *dataset* untuk digunakan sebagai masukan proses klasifikasi.

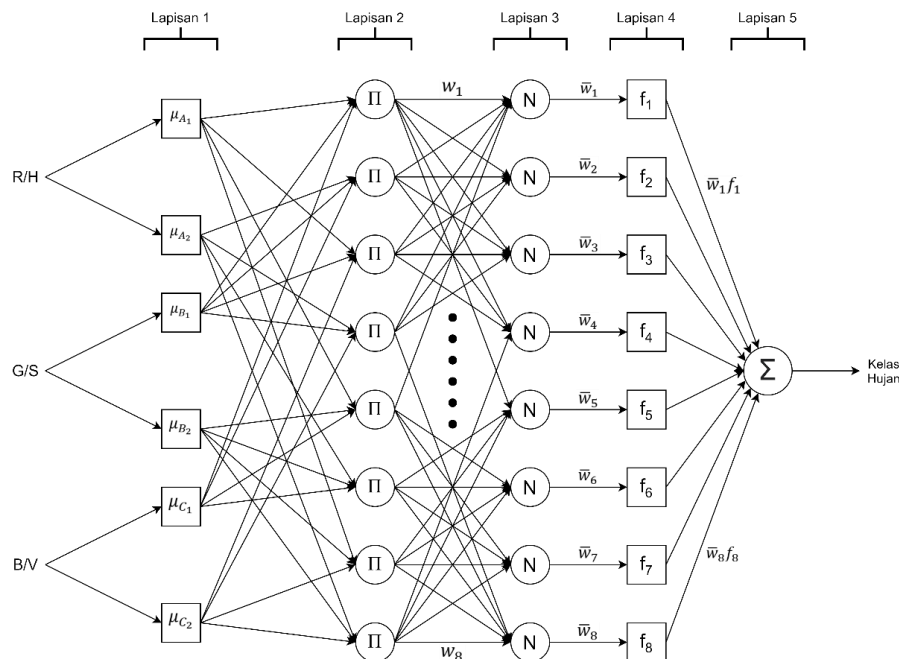
2.5 Klasifikasi

Pada tahap ini dilakukan pengklasifikasian curah hujan ke dalam beberapa kategori melalui pendekatan *Supervised Machine learning*. Pendekatan *supervised learning* menggunakan sebagian dari *dataset* untuk dijadikan data latih sebagai referensi awal untuk menentukan pola dari label, kemudian dilakukan validasi hasil proses dengan cara mengambil sebagian data dari data latih sebagai data uji [11]. Salah satu algoritma yang termasuk dalam pendekatan supervised learning adalah *Neuro-fuzzy System*. Arsitektur *neuro-fuzzy system* pada penelitian ini menggunakan arsitektur *Adaptive Neuro-fuzzy Inference System* (ANFIS) seperti yang digunakan oleh [12].

2.5.1 Arsitektur ANFIS

Arsitektur ANFIS menggunakan jenis inferensi fuzzy Takagi & Sugeno, sehingga keluaran dari setiap *rule* merupakan kombinasi linier dari variable input dengan suatu nilai konstanta, sedangkan keluaran akhir sistem merupakan bobot rata-rata dari tiap keluaran *rule* [12]. Arsitektur ANFIS pada penelitian ini menggunakan lima lapisan yang dapat dilihat seperti

pada Gambar 4. Pada arsitektur ini, lingkaran menandakan node tetap, sedangkan kotak menandakan node adaptif. Node-node dalam lapisan yang sama akan menjalankan fungsi yang identik dengan rincian seperti berikut.



Gambar 4 Arsitektur *Adaptive Neuro-fuzzy System* (ANFIS)

Lapisan 1: Semua node pada lapisan ini adalah node adaptif. Keluaran dari lapisan ini dinyatakan dengan fungsi pada Persamaan 1

$$\begin{aligned} O_i^1 &= \mu_{A_i}(x) \\ O_i^1 &= \mu_{B_i}(y) \\ O_i^1 &= \mu_{C_i}(z) \end{aligned} \quad (1)$$

dimana x adalah masukan untuk node i , dan A_i adalah batas keputusan (linguistik) untuk node i . Dengan kata lain, O_i^1 adalah fungsi keanggotaan A_i dengan derajat keanggotaan yang spesifik untuk masukan x . Lapisan ini disebut juga sebagai lapisan fuzzifikasi karena mengubah masukan x ke dalam fungsi keanggotaan. Fungsi keanggotaan yang digunakan adalah fungsi Gaussian karena dianggap akan menghasilkan distribusi nilai yang cenderung tidak kaku bila dilihat dari grafik fungsinya. Fungsi Gaussian dituliskan seperti pada Persamaan 2

$$\mu_{A_i}(x) = e^{-\frac{(x-m)^2}{2\sigma^2}} \quad (2)$$

dimana m adalah nilai *mean* dan σ adalah nilai standar deviasi. m dan σ merupakan parameter yang nilainya dapat berubah untuk menentukan bentuk fungsi keanggotaan. Parameter pada lapisan ini disebut sebagai parameter premis.

Lapisan 2: Setiap node pada lapisan ini adalah lingkaran (node tetap) yang dilambangkan dengan Π . Pada lapisan dilakukan operasi perkalian *cross product*. Setiap node pada lapisan ini akan menghitung kekuatan tembak (*firing strength*) dari tiap *rule* dengan mengalikan sinyal masukan dan mengeluarkan hasilnya. Keluaran pada lapisan ini dapat direpresentasikan seperti pada Persamaan 3.

$$O_i^2 = w_i = \mu_{A_i}(x) \times \mu_{B_i}(y) \times \mu_{C_i}(z), \quad i = 1, 2, 3, \dots, 8 \quad (3)$$

Lapisan 3: Node-node pada lapisan ini juga merupakan node tetap. Mereka dilambangkan dengan N, yang mengindikasikan bahwa mereka akan menjalankan fungsi normalisasi terhadap kekuatan tembak dari lapisan sebelumnya. Setiap node ke- i pada lapisan

ini akan menghitung rasio kekuatan tembak pada *rule* ke-*i* terhadap jumlah kekuatan tembak pada semua *rule* yang ditunjukkan melalui Persamaan 4.

$$O_i^3 = \bar{w}_i = \frac{w_i}{\sum_{i=1}^8 w_i} = \frac{w_i}{w_1 + w_2 + w_3 + \dots + w_8} \quad (4)$$

Lapisan 4: Lapisan ini berisi node-node adaptif. Keluaran dari setiap node pada lapisan ini adalah hasil operasi perkalian dari kekuatan tembak ternormalisasi dan polynomial orde fuzzy Sugeno. Pada penelitian ini menggunakan model fuzzy Sugeno orde nol ($f = \text{konstanta}$) dengan pertimbangan alasan kepraktisan komputasi, sehingga keluaran pada lapisan ini terlihat seperti pada Persamaan 5

$$O_i^4 = \bar{w}_i f_i, \quad i = 1, 2, 3, \dots, 8 \quad (5)$$

dimana f merupakan parameter pada lapisan ini yang disebut dengan parameter konsekuen.

Lapisan 5: Pada lapisan ini hanya terdapat sebuah node tetap yang dilambangkan dengan SIGMA. Node ini menjalankan proses untuk menghitung keseluruhan keluaran sebagai penjumlahan dari semua sinyal masukan, yang direpresentasikan melalui Persamaan 6.

$$O_i^5 = \sum_{i=1}^8 \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (6)$$

2.5.2 Pelatihan model sistem

Pelatihan model klasifikasi sistem dilakukan untuk mendapatkan hasil prediksi kelas hujan sebaik mungkin. Algoritma ANFIS akan memetakan fitur-fitur pada data latih ke dalam kategori kelas hujan dengan melakukan proses komputasi berdasarkan arsitektur ANFIS yang telah dipaparkan pada Sub Bab 2.5.1. Model klasifikasi sistem akan menghasilkan prediksi yang belum tentu tepat dengan kelas hujan yang seharusnya. Oleh karena itu, hasil prediksi sistem akan dibandingkan dengan label kelas aslinya, kemudian dihitung *cost function*-nya dengan metode *Hubber Loss*. Guna mendapatkan hasil prediksi sedekat mungkin dengan kelas sesungguhnya, maka dilakukan optimasi dengan metode *ADAM Optimizer* untuk meminimalkan nilai *cost function*. Proses optimasi ini akan mengubah nilai pada parameter premis dan konsekuen. Dengan demikian hasil keluaran ANFIS (prediksi kelas) akan berubah juga. Proses pelatihan ini akan terus dilakukan selama jumlah iterasi (*epoch*) yang ditentukan. Jumlah epoch pada inialisasi awal sistem yaitu 50, dan akan ditambah menjadi 100 dan 400 guna mencari hasil prediksi klasifikasi yang paling baik. Secara umum, semakin banyak *epoch* yang digunakan, maka akan semakin baik pula hasil klasifikasi.

3. HASIL DAN PEMBAHASAN

Pada Bab ini disajikan hasil dari sistem klasifikasi yang telah dirancang. Adapun pembahasan hasil dari penelitian ini meliputi beberapa pengujian sebagai berikut.

3.1 Hasil Pengujian Ukuran Jendela pengamatan *Pengamatan*

Penelitian dilakukan menggunakan lima data citra pilihan dari 500 data radar pada tanggal 4-7 Januari 2020. Setiap citra dibagi menjadi blok piksel dengan ukuran blok bervariasi sesuai dengan ukuran jendela pengamatan pada proses ekstraksi fitur, yaitu 3x3 hingga 16x16. Ukuran jendela pengamatan tersebut membagi citra menjadi blok-blok piksel masing-masing sejumlah 14.455, 8.140, 5.075, 3.480, 2.625, 1.980, 1.520, 1.190, 1.040, 840, 715, 600, 495, dan 495. Jumlah blok-blok piksel inilah yang digunakan sebagai dataset. Perbedaan jumlah *dataset* tersebut berpengaruh terhadap performa klasifikasi yang dihasilkan. Oleh karena itu, setiap variasi jendela pengamatan tersebut diujikan pada sistem klasifikasi untuk menentukan ukuran jendela pengamatan yang paling optimal dengan inialisasi awal *hyperparameter* yaitu jumlah *rule* 8, laju pembelajaran 0.005, dan jumlah *epoch* 50. Hasil pengujian setiap ukuran jendela pengamatan pada masing-masing jenis fitur RGB dan HSV ditunjukkan pada Tabel 1.

Tabel 1 Hasil pengujian ukuran jendela pengamatan

Ukuran jendela pengamatan	Jumlah <i>dataset</i> (blok piksel)	Jumlah kelas 4	Rata-rata akurasi (%)	
			RGB	HSV
3x3	14.455	82	76,7	73,11
4x4	8.140	38	77,44	73,44
5x5	5.075	18	80,93	72,57
6x6	3.480	12	79,63	72,13
7x7	2.625	10	80,15	69,29
8x8	1.980	2	74,19	69,7
9x9	1.520	0	74,8	72,24
10x10	1.190	1	74,87	74,12
11x11	1.040	1	76,73	70,77
12x12	840	2	74,4	73,45
13x13	715	0	73,71	71,47
14x14	600	0	76,83	68,33
15x15	495	0	73,13	68,08
16x16	495	0	75,96	69,7

Pada Tabel 1 menunjukkan bahwa dengan jumlah gambar yang sama (5 gambar) dan wilayah pengamatan yang sama (DIY dan sekitarnya) pada setiap gambar, maka semakin besar ukuran jendela pengamatan yang dipakai akan menghasilkan jumlah *dataset* yang semakin sedikit. Dengan demikian, tentunya komposisi data di dalamnya menjadi kurang baik karena jumlah setiap kelasnya juga semakin sedikit untuk keperluan pelatihan sistem. Hasil pengujian akurasi dengan *5-folds cross validation* menunjukkan ukuran jendela pengamatan 5x5 pada fitur RGB menghasilkan nilai akurasi tertinggi dengan 80,93 %. Sementara itu, akurasi tertinggi untuk fitur HSV ada pada jendela pengamatan 10x10 yang menghasilkan akurasi 74,12 %, dan diikuti jendela pengamatan 12x12 dengan akurasi 73,45 %.

Namun demikian, pada fitur HSV dengan ukuran jendela pengamatan 10x10 dan 12x12 hanya terdapat label hujan kelas 4 (Hujan Lebat) dengan jumlah masing-masing 1 dan 2. Hal ini dinilai kurang merepresentasikan sistem yang dibuat, karena dengan jumlah kelas 4 yang sangat sedikit untuk pelatihan, nantinya sistem akan kesulitan saat mengenali data baru dengan label kelas 4 yang cukup banyak. Label kelas 4 digunakan sebagai batas acuan karena memiliki distribusi jumlah data yang paling sedikit dibandingkan kelas lainnya.

Berdasarkan pemahaman yang telah dijelaskan di atas, maka dipilihlah jendela pengamatan yang menghasilkan akurasi tertinggi setelah jendela pengamatan 10x10 dan 12x12 yaitu jendela pengamatan 4x4. Jendela pengamatan ini menghasilkan nilai akurasi 73,44 % dengan jumlah data berlabel kelas 4 sebanyak 38. Jendela pengamatan ini dipilih sebagai ukuran jendela pengamatan paling optimal untuk fitur HSV, sedangkan jendela pengamatan paling optimal untuk fitur RGB yaitu jendela pengamatan 5x5.

3.2 Hasil Pengujian Pengaturan (Tunning) Hyperparameter

Jendela pengamatan terbaik dari masing-masing fitur RGB dan HSV dijadikan sebagai pedoman untuk melakukan variasi nilai *hyperparameter* guna meningkatkan performa klasifikasi sistem. Evaluasi dilakukan dengan menghitung akurasi melalui matriks konfusi yang dikerjakan dengan teknik *5-folds cross validation* untuk kemudian dirata-rata. Teknik ini dilakukan dengan membagi *dataset* menjadi lima bagian, saat bagian pertama menjadi data validasi, empat bagian lainnya menjadi data latih. Pada perulangan berikutnya *dataset* bagian kedua yang akan menjadi data validasi dan sisanya sebagai data latih, begitu seterusnya hingga lima kali, sehingga semua *dataset* pernah menjadi data latih maupun data validasi. Hasil pengujian terhadap variasi *hyperparameter* ditunjukkan melalui Tabel 2 untuk fitur RGB dan Tabel 3 untuk fitur HSV.

Tabel 2 Hasil pengujian variasi kombinasi *hyperparameter* pada fitur RGB

No.	Jumlah rule	Laju pembelajaran	Epoch	Rata-rata akurasi (%)	Waktu komputasi (detik)
1	8	0,005	50	80,93	1,087
2	8	0,005	100	85,12	1,997
3	8	0,005	400	86,66	7,333
4	8	0,01	50	84,32	1,037
5	8	0,01	100	86,32	1,975
6	8	0,01	400	87,21	7,324
7	8	0,1	50	87,47	1,039
8	8	0,1	100	88	1,98
9	8	0,1	400	88,02	7,334
10	27	0,005	50	83,78	2,89
11	27	0,005	100	87,23	5,43
12	27	0,005	400	88	21,495
13	27	0,01	50	86,9	2,882
14	27	0,01	100	87,43	5,518
15	27	0,01	400	87,78	22,227
16	27	0,1	50	87,88	2,91
17	27	0,1	100	88,04	5,669
18	27	0,1	400	87,88	21,526

Tabel 3 Hasil pengujian variasi kombinasi *hyperparameter* pada fitur HSV

No.	Jumlah rule	Laju pembelajaran	Epoch	Rata-rata akurasi (%)	Waktu komputasi (detik)
1	8	0,005	50	73,44	1,552
2	8	0,005	100	81,57	2,754
3	8	0,005	400	87,73	10,782
4	8	0,01	50	79,02	1,502
5	8	0,01	100	85,85	2,815
6	8	0,01	400	87,97	10,583
7	8	0,1	50	87,65	1,441
8	8	0,1	100	87,57	2,952
9	8	0,1	400	88,03	10,707
10	27	0,005	50	83,62	4,725
11	27	0,005	100	86,76	9,029
12	27	0,005	400	88,21	35,831
13	27	0,01	50	86,53	4,778
14	27	0,01	100	87,64	9,037
15	27	0,01	400	88,12	35,759
16	27	0,1	50	87,9	4,732
17	27	0,1	100	88,23	8,954
18	27	0,1	400	88,07	35,681

Dari Tabel 2 maupun Tabel 3, dapat dilihat bahwa secara umum penambahan jumlah *rule* yang digunakan menyebabkan peningkatan performa sistem klasifikasi. Hal ini dikarenakan semakin banyak *rule* yang terbentuk, maka semakin banyak pula pilihan kombinasi masukan untuk dikatakan masuk ke dalam suatu kelas. Pengaruh laju pembelajaran terhadap sistem baik pada fitur RGB maupun HSV secara garis besar juga menunjukkan peningkatan performa seiring nilai laju pembelajaran yang semakin besar. Hal ini senada dengan pemahaman bahwa

laju pembelajaran yang besar akan melakukan perubahan terhadap variabel secara besar, sehingga solusi optimal dapat dicapai dengan lebih cepat. Akan tetapi, pemahaman tersebut juga tidak selalu benar, karena terkadang penggunaan laju pembelajaran yang terlalu besar akan menyebabkan perubahan yang besar pula, sehingga menyebabkan dilewatkannya solusi optimal yang diinginkan. Hal ini terlihat pada kombinasi parameter nomor 12, 15, dan 18 baik pada fitur RGB ataupun HSV.

Pada variasi parameter yang dilakukan untuk fitur RGB maupun HSV, secara umum dengan bertambahnya jumlah *epoch* yang dipakai pada proses pembelajaran maka hasil klasifikasi juga semakin meningkat. Proses pembelajaran yang berulang-ulang bertujuan untuk mencapai konvergensi nilai bobot, sehingga semakin bertambahnya jumlah *epoch*, maka semakin banyak pula nilai bobot yang berubah dan hasilnya akan semakin baik. Namun demikian, jumlah *epoch* juga terkait dengan keberagaman data yang dipakai, sehingga berbeda *dataset* maka berbeda pula jumlah *epoch* yang dibutuhkan, tidak bisa semata-mata menghasilkan nilai paling optimal dengan terus menambah jumlah *epoch*. Hal ini terlihat pada kombinasi variasi parameter nomor 16, 17, dan 18 di kedua fitur RGB dan HSV.

Adapun secara keseluruhan, kombinasi variasi parameter yang paling optimal untuk menghasilkan akurasi tertinggi baik untuk RGB maupun HSV yaitu kombinasi nomor 17 dengan jumlah *rule* 27, laju pembelajaran 0.1, dan jumlah *epoch* 100. Kombinasi tersebut menghasilkan rata-rata akurasi sebesar 88,04 % untuk RGB, sedangkan untuk HSV rata-rata akurasi sebesar 88,23 %.

3.3 Hasil Evaluasi Performa Klasifikasi

Pengukuran lebih jauh terhadap performa sistem klasifikasi dilakukan dengan pengujian menggunakan data uji terhadap model klasifikasi yang telah terbentuk. Ukuran jendela pengamatan yang dipakai disesuaikan dengan jendela pengamatan optimal pada masing-masing fitur. Ukuran jendela pengamatan 5x5 pada fitur RGB menghasilkan *dataset* untuk data uji sejumlah 1.015, sedangkan jendela pengamatan 4x4 pada fitur HSV menghasilkan *dataset* untuk data uji sejumlah 1.628. Hasil penghitungan matriks konfusi serta evaluasi performa klasifikasi ditunjukkan melalui Tabel 4 untuk RGB dan Tabel 5 untuk HSV.

Tabel 4 Evaluasi performa klasifikasi fitur RGB

Matriks konfusi						
		Prediksi				
		0	1	2	3	4
Target	0	545	55	1	0	0
	1	6	132	46	3	0
	2	0	1	125	24	0
	3	0	0	10	61	0
	4	0	0	0	6	0
Data						
Jumlah <i>dataset</i>	1.015					
Jumlah benar	863					
Jumlah salah	152					
Evaluasi						
Akurasi (%)	85,02					
Presisi (%)	86,19					

Pada Tabel 4 dapat dilihat bahwa dari total 1.015 data yang dimasukkan ke sistem, 863 data berhasil diklasifikasikan dengan benar, sedangkan 152 lainnya masuk pada kelas yang salah. Dari hasil evaluasi didapatkan nilai akurasi sebesar 85,02 % dengan presisi 86,19 %. Sementara itu, untuk fitur HSV pada Tabel 5 berhasil mengklasifikasikan 1346 data dengan benar dari total 1.628 data, sedangkan jumlah data yang salah diklasifikasikan sebanyak 282

data. Tingkat akurasi yang didapatkan dari hasil tersebut sebesar 82,68 %, dan untuk presisinya sebesar 86,67 %.

Dari hasil evaluasi performa klasifikasi Sub Bab 3.3, penggunaan fitur RGB mendapatkan hasil yang lebih baik daripada fitur HSV. Hal ini menunjukkan bahwa penggunaan fitur RGB pada sistem klasifikasi berbasis *Neuro-fuzzy* lebih dapat merepresentasikan curah hujan sebenarnya dibandingkan fitur HSV. Dengan hasil yang didapatkan dari pengujian ini, sistem klasifikasi yang telah dibuat dapat dikatakan telah berhasil untuk mengklasifikasikan data citra radar dengan performa yang cukup bagus, terutama pada ruang warna RGB.

Tabel 5 Evaluasi performa klasifikasi fitur HSV

Matriks konfusi						
		Prediksi				
		0	1	2	3	4
Target	0	884	106	1	0	0
	1	9	230	44	0	0
	2	0	11	171	42	3
	3	0	0	5	55	59
	4	0	0	0	2	6
Data						
Jumlah dataset	1.628					
Jumlah benar	1346					
Jumlah salah	282					
Evaluasi						
Akurasi (%)	82,68					
Presisi (%)	86,67					

4. KESIMPULAN

Dari penelitian yang telah dilakukan dapat disimpulkan bahwa metode *Neuro-fuzzy System* telah berhasil mengklasifikasikan curah hujan melalui citra radar cuaca yang diolah dari data radar Stasiun Klimatologi Yogyakarta. Ukuran jendela pengamatan yang paling optimal untuk fitur RGB adalah 5x5 dan untuk fitur HSV adalah 4x4. Kombinasi parameter optimal yang menghasilkan klasifikasi terbaik yaitu jumlah *rule* 27, laju pembelajaran 0.1, dan jumlah *epoch* 100. Hasil evaluasi performa klasifikasi *Neuro-fuzzy* menunjukkan hasil yang lebih baik pada fitur RGB dengan tingkat akurasi 85,02% dan presisi 86,19%, sedangkan untuk fitur HSV dihasilkan akurasi 82,68%, presisi 86,67%.

5. SARAN

Saran-saran yang dapat diterapkan untuk pengembangan penelitian ini, diantaranya penggunaan metode pemilihan fitur terbaik untuk meningkatkan hasil akurasi sistem, penggunaan fungsi keanggotaan fuzzy selain fungsi Gaussian untuk membandingkan performa yang dihasilkan, serta perlu adanya peningkatan pada proses pra pengolahan, ekstraksi fitur, dan algoritma klasifikasi untuk meningkatkan performa sistem klasifikasi.

DAFTAR PUSTAKA

- [1] A. Prakasa and F. D. Utami, "Sistem Informasi Radar Cuaca Terintegrasi BMKG," p. 11, 2019.
- [2] D. S. Permana, T. D. F. Hutapea, A. S. Praja, and L. F. Muzayanah, "Pengolahan Multi Data Format Radar Cuaca Menggunakan Wradlib Berbasis Python," vol. 17, no. 3, p. 8, 2016.
- [3] F. Renggono, "Analisis Kemunculan Awan Hujan Berdasarkan Jenisnya untuk Mendukung Kegiatan Modifikasi Cuaca," *J. Sains Teknol. Modif. Cuaca*, vol. 16, no. 2, p. 83, Dec. 2015, doi: 10.29122/jstmc.v16i2.1050.
- [4] I. G. A. Gunadi and A. A. K. Dewi, "Klasifikasi Curah Hujan di Provinsi Bali Berdasarkan Metode Naïve Bayesian," *J. Mat.*, vol. 12, no. 1, p. 12, 2018.
- [5] H. Liu and V. Chandrasekar, "Classification of Hydrometeors Based on Polarimetric Radar Measurements: Development of Fuzzy Logic and Neuro-Fuzzy Systems, and In Situ Verification," *J. ATMOSPHERIC Ocean. Technol.*, vol. 17, p. 25, 2000.
- [6] M. I. Azhar and W. F. Mahmudy, "Prediksi Curah Hujan Menggunakan Metode Adaptive Neuro Fuzzy Inference System (ANFIS)," p. 8, 2018.
- [7] N. Faridatussafura and D. A. Rivai, "PEMANFAATAN PRODUK REFLECTIVITY RADAR CUACA DOPPLER C-BAND DI PANGKALPINANG UNTUK ESTIMASI CURAH HUJAN MENGGUNAKAN RELASI Z-R MARSHALL-PALMER DAN Z-R ROSENFELD TROPICAL," p. 19, 2015.
- [8] Hadriansa and D. Prayogi, "Pengenalan Citra Bola Robot BlueHuman G8," *Sebatik*, vol. 22, no. 2, pp. 188–193, Dec. 2018.
- [9] C. Z. van de Beek, H. Leijnse, P. Hazenberg, and R. Uijlenhoet, "Close-range radar rainfall estimation and error analysis," *Atmospheric Meas. Tech.*, vol. 9, no. 8, pp. 3837–3850, Aug. 2016, doi: 10.5194/amt-9-3837-2016.
- [10] J. F. Fauzi, H. Tolle, and R. K. Dewi, "Implementasi Metode RGB To HSV pada Aplikasi Pengenalan Mata Uang Kertas Berbasis Android untuk Tuna Netra," p. 7, 2018.
- [11] M. Afrizal, "Klasifikasi Kondisi Lalu Lintas Menggunakan Algoritme Naïve Bayes Berbasis Data Twitter," p. 55, Apr. 2018.
- [12] V. T. Tran, B.-S. Yang, M.-S. Oh, and A. C. C. Tan, "Fault Diagnosis of Induction Motor Based on Decision Trees and Adaptive Neuro-fuzzy Inference," *Expert Syst. Appl.*, vol. 36, no. 2, pp. 1840–1849, Mar. 2009, doi: 10.1016/j.eswa.2007.12.010.