



Pengembangan Aplikasi Android untuk Rekomendasi Penyiraman Cerdas Berbasis IoT dengan Metode Fuzzy C-Means dan Jaringan Saraf Tiruan

Received : April 17, 2026; Revised : April 23, 2026; Accepted : Jul 13, 2026; Published : Sep 15, 2026

Syafei Karim^{1*}, Dian Ahkam Sani²

¹Teknologi Rekayasa Perangkat Lunak, Politeknik Pertanian Negeri Samarinda,
Jalan Samratulangi Samarinda Seberang 75131, Samarinda, INDONESIA
syfei.karim@gmail.com

²Informatika, Fakultas Teknologi Informasi, Universitas Merdeka Pasuruan
Jalan Ir. H. Juanda No.68, Tapaan, Kec. Bugul Kidul, Pasuruan, INDONESIA
dian.ahkam@unmerpas.ac.id

*Corresponding Author

Abstrak:

Pengelolaan irigasi yang efisien sangat penting untuk mengoptimalkan penggunaan air dan menjaga kondisi tanah yang mendukung pertumbuhan tanaman. Meskipun banyak model kecerdasan buatan telah dikembangkan, sistem konvensional kerap kesulitan menggeneralisasi rekomendasi karena mengabaikan ambiguitas dan tumpang tindih (*overlapping*) pola data lingkungan. Penelitian ini secara eksplisit berkontribusi pada pengembangan sistem rekomendasi penyiraman hibrida (*hybrid*) berbasis *edge-computing*, yang mengintegrasikan pelabelan otomatis *Fuzzy C-Means* (FCM) dengan prediksi Jaringan Saraf Tiruan (JST) pada aplikasi Android. Sistem ini memproses kumpulan dataset berjumlah 96.547 sampel yang diperoleh dari empat parameter sensor yaitu intensitas cahaya, suhu udara, kelembapan udara, dan kelembapan tanah. Melalui metode FCM, data lingkungan tersebut diurai secara objektif ke dalam empat kelas kondisi, yaitu: 0, 1, 2, dan 3. Untuk memastikan keandalan model, tahap evaluasi dilakukan menggunakan metode *Confusion Matrix* dalam skema pengujian *5-Fold Cross Validation* ($k=5$). Pada setiap iterasi pengujiannya, dataset dibagi menjadi 80% data latih dan 20% data uji. Hasil eksperimen menunjukkan performa model yang luar biasa stabil dengan rata-rata akurasi sebesar 98,85%, presisi 98,23%, *recall* 97,48%, dan *F1-Score* 97,78%. Setelah hasil pengujian model, model JST dikonversi menjadi *TensorFlow Lite* (TFLite) dan diintegrasikan secara *real-time* ke dalam aplikasi perangkat seluler Android. Secara praktis, sistem ini memetakan keempat prediksi kelas lingkungan tersebut ke dalam tiga perilaku penyiraman: tanpa penyiraman (menggabungkan kelas 0 dan 3 yang memiliki karakteristik kebutuhan air serupa), penyiraman volume sedang, dan penyiraman volume tinggi. Hasil penelitian ini membuktikan bahwa pendekatan hibrida FCM dan JST yang diusulkan sangat efisien sebagai sistem pendukung keputusan irigasi dalam pertanian presisi. Penelitian lanjutan dapat difokuskan pada perluasan volume dataset serta integrasi langsung terhadap perangkat keras penyiraman berbasis *Internet of Things* (IoT).

Kata Kunci:

Fuzzy c-means, Jaringan syaraf tiruan, TensorFlow, Internet of things, Android.

Abstract:

Efficient irrigation management is crucial for optimizing water usage and maintaining soil conditions that support plant growth. Although many artificial intelligence models have been developed, conventional systems often struggle to generalize recommendations because they ignore the ambiguity and overlapping patterns of environmental data. This research explicitly contributes to the development of an edge-computing-based hybrid watering recommendation system, which



This work is licensed under a [Creative Commons Attribution-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-sa/4.0/). Allows readers to read, download, copy, distribute, print, search, or link to the full texts of its articles and allow readers to use them for any other lawful purpose.

integrates Fuzzy C-Means (FCM) automatic labeling with Artificial Neural Network (ANN) predictions in an Android application. The system processes a dataset of 96,547 samples obtained from four sensor parameters, namely light intensity, air temperature, air humidity, and soil moisture. Through the FCM method, the environmental data is objectively clustered into four condition classes: 0, 1, 2, and 3. To ensure model reliability, the evaluation phase was conducted using the Confusion Matrix method within a 5-Fold Cross-Validation scheme ($k=5$). In each testing iteration, the dataset was divided into 80% training data and 20% testing data. Experimental results demonstrated an exceptionally stable model performance, achieving an average accuracy of 98.85%, a precision of 98.23%, a recall of 97.48%, and an F1-Score of 97.78%. Following the model evaluation, the ANN model was converted into TensorFlow Lite (TFLite) format and integrated in real-time into an Android mobile application. Practically, the system maps the four environmental class predictions into three watering behaviors: no watering (combining classes 0 and 3, which share similar water requirement characteristics), medium-volume watering, and high-volume watering. The findings of this study prove that the proposed hybrid FCM and ANN approach is highly efficient as an irrigation decision support system in precision agriculture. Future research can focus on expanding the dataset volume and directly integrating the system with Internet of Things (IoT)-based watering hardware.

Keywords:

Fuzzy c-means, Neural network, TensorFlow, Internet of things, Android.

1. Pendahuluan

Kebutuhan sistem pertanian yang efisien dan berkelanjutan semakin meningkat seiring dengan pertumbuhan penduduk global dan tantangan perubahan iklim [1]. Aspek krusial dari pertanian presisi adalah pengelolaan irigasi yang tepat, karena dapat mempengaruhi hasil panen dan penggunaan sumber daya air [2]. Produktivitas pertanian sangat bergantung pada penggunaan air yang efisien, terutama di daerah dengan kondisi iklim yang berfluktuasi [3]. Penggunaan air yang kurang dapat menyebabkan penurunan hasil panen sedangkan kelebihan penggunaan air menyebabkan pemborosan sumber daya. Sistem irigasi cerdas yang memanfaatkan teknologi sensor dan kecerdasan buatan telah dikembangkan untuk mengoptimalkan penggunaan air dengan memberikan rekomendasi irigasi berbasis data [4]-[6].

Kemajuan dalam teknologi sensor dan kecerdasan buatan menawarkan solusi yang menjanjikan untuk mengatasi tantangan ini. Dalam beberapa tahun terakhir, metode kecerdasan buatan seperti logika fuzzy, *machine learning*, dan jaringan saraf tiruan telah banyak digunakan dalam pengembangan sistem irigasi cerdas untuk memaksimalkan penggunaan air dan meningkatkan efisiensi irigasi. Sensor yang digunakan dapat mengumpulkan data lingkungan dan tanah secara *real-time*, seperti kelembapan tanah, suhu udara, dan kelembapan udara. Data sensor yang dikumpulkan ini menjadi informasi penting yang dapat dianalisis untuk memahami kondisi spesifik tanaman dan lingkungannya. Salah satu metode yang populer adalah logika fuzzy karena kemampuannya untuk memanfaatkan data sensor untuk membuat keputusan [7]-[9].

Meskipun banyak model yang telah diusulkan, tinjauan kritis terhadap literatur yang ada menunjukkan kelemahan mendasar pada studi-studi sebelumnya. Ketergantungan yang sangat tinggi pada penggunaan data sensor mentah secara langsung ke dalam jaringan prediktif, tanpa melakukan karakterisasi variasi lingkungan di tahap awal [10]. Kumpulan data agrikultur pada dasarnya bersifat sangat dinamis, tidak pasti, dan memiliki Batasan tumpang tindih (*overlapping*) yang dipengaruhi oleh cuaca serta karakteristik tanah. Karena tidak dilakukannya proses ekstraksi pola lingkungan (*clustering*) sebelum prediksi, model-model konvensional terbukti kesulitan untuk melakukan generalisasi secara akurat di berbagai skenario pertanian. Akibatnya, sistem sering kali gagal menginterpretasikan nilai

inheren dari kombinasi suhu dan kelembapan secara kontekstual sehingga rekomendasi yang dihasilkan menjadi bias.

Berdasarkan dari kelemahan tersebut, terdapat kesenjangan penelitian mengenai apa yang masih minim dilakukan yaitu pengintegrasian yang utuh antara metode *unsupervised learning* untuk mengurai ambiguitas kondisi lingkungan dengan *supervised learning* untuk rekomendasi keputusan [11]. Sebagian besar sistem irigasi menggunakan jaringan saraf tiruan yang langsung menggunakan data mentah. Tanpa membuat hasil klaster lingkungan yang mencerminkan berbagai situasi irigasi. Akibatnya, nilai yang melekat pada kelembapan tanah, suhu, dan kondisi iklim mungkin tidak memberikan hasil dengan benar dalam proses pengambilan keputusan.

Dalam konteks ini, teknik pengelompokan sangat penting untuk mengidentifikasi pola dan kelompok dengan data sensor yang mewakili kondisi lingkungan yang berbeda [12]. Salah satu algoritma pengelompokan yang populer dan efektif untuk menangani ketidakpastian dan ambiguitas data adalah Fuzzy C-Means (FCM) [13]. FCM memungkinkan setiap titik data menjadi anggota dari beberapa klaster dengan derajat keanggotaan yang berbeda, sehingga lebih cocok untuk data sensor yang sering memiliki transisi yang tidak jelas antar kondisi. Pendekatan pengelompokan seperti Fuzzy C-Means (FCM) telah terbukti efektif dalam mengelompokkan data untuk menentukan klaster data [14], [15]. Penelitian ini menerapkan pendekatan FCM untuk mengelompokkan data sensor berdasarkan parameter kelembapan tanah, suhu udara, kelembapan udara, dan intensitas cahaya. Setelah data sensor dikelompokkan menggunakan FCM, diperlukan model prediktif untuk memetakan karakteristik klaster dengan kebutuhan irigasi. Jaringan saraf tiruan yang diimplementasikan dengan kerangka kerja TensorFlow telah terbukti efektif dalam memodelkan hubungan non-linier yang kompleks dalam data [16], [17]. Kemampuan belajar dan generalisasi jaringan saraf tiruan menjadikannya pilihan yang tepat untuk memprediksi rekomendasi irigasi berdasarkan pola yang diidentifikasi dalam hasil pengelompokan FCM.


Selain itu, agar sistem rekomendasi penyiraman ini dapat memberikan dampak yang signifikan bagi petani, maka sistem ini perlu diimplementasikan pada platform yang mudah diakses dan digunakan. Aplikasi berbasis Android menawarkan solusi yang ideal karena popularitas perangkat seluler dan kemudahan akses bagi sebagian besar pengguna [18].

Studi ini mengusulkan sistem rekomendasi penyiraman berdasarkan pengelompokan Fuzzy C-Means dan jaringan saraf tiruan untuk mengatasi kekurangan tersebut. Model jaringan saraf tiruan digunakan untuk memberikan rekomendasi penyiraman berdasarkan pola yang dikelompokkan dan teknik Fuzzy C-Means digunakan untuk mengelompokkan kondisi lingkungan ke dalam kelompok fuzzy yang mencerminkan berbagai skenario penyiraman. Metode yang diusulkan bertujuan untuk meningkatkan ketepatan dan fleksibilitas sistem pendukung keputusan penyiraman dalam pertanian presisi dengan menggabungkan pemodelan prediktif berdasarkan karakterisasi lingkungan berbasis pengelompokan.

2. Metode

Bagian ini membahas alur kerja untuk melakukan penelitian ini dengan mengumpulkan data, mengelompokkan data sensor menggunakan fuzzy C-means, dan kemudian memberikan rekomendasi menggunakan jaringan saraf tiruan. Gambar 1 menunjukkan alur sistem yang diajukan oleh penulis. Dataset terdiri dari data sensor intensitas cahaya, kelembapan tanah, kelembapan udara, dan suhu udara. Dataset ini kemudian akan digunakan sebagai data utama dalam penerapan metode

pengelompokan dengan algoritma Fuzzy C-Means. Setelah itu, dataset yang telah dikelompokkan diproses lebih lanjut oleh jaringan saraf tiruan untuk mendapatkan target rekomendasi penyiraman yang sesuai dengan data sensor.



Gambar 1: Alur sistem penelitian

2.1. Dataset Penelitian

Data utama pada penelitian ini dengan mengumpulkan data secara *real-time* di lingkungan sekitar dengan mengukur intensitas cahaya (lux) menggunakan RS485 Waterproof Ambient Light Sensor, kelembapan tanah menggunakan Gravity: IP65 Capacitive Soil Moisture Sensor, kelembapan udara, dan suhu udara menggunakan Air Quality Monitor (PM 2.5, Temperature & Humidity Sensor). Sensor-sensor ini ditempatkan di lahan tanaman cabai (*Capsicum annuum* L.) seperti yang ditunjukkan pada Gambar 2. Penempatan sensor diletakkan hanya pada satu titik dengan jarak sekitar satu meter dari lahan cabai. Data dikumpulkan secara berkala selama 19 hari dengan dua periode pengumpulan data setiap hari, yaitu: pagi hari pukul 07.00 hingga 10.00 dan sore hari pukul 15.00 hingga 18.00. Proses pengumpulan data ini menghasilkan 105.660 data yang dijadikan dataset. Jumlah dataset ini menunjukkan banyaknya data yang sangat penting untuk memastikan kualitas dan akurasi dalam proses analisis, pengelompokan, dan prediksi dengan model pembelajaran mesin yang digunakan dalam penelitian ini.



Gambar 2: Lahan pertanian cabai

2.2. Fuzzy C-Means

Fuzzy C-Means Clustering (FCM) adalah algoritma pengelompokan yang banyak digunakan dalam *machine learning* dan analisis data yang memungkinkan titik data untuk termasuk ke dalam beberapa kluster dengan berbagai tingkat keanggotaan. Tidak seperti metode pengelompokan tradisional seperti K-Means, yang menetapkan setiap titik data ke satu kluster tunggal. FCM memberikan pendekatan yang lebih fleksibel dan bernuansa dengan memperkenalkan konsep keanggotaan fuzzy. Hal ini membuatnya sangat berguna untuk menangani kluster yang ambigu atau tumpang tindih dalam dataset [19]. Konsep dasar FCM menentukan langkah awal untuk pusat kluster, yang mewakili lokasi rata-rata setiap kluster. Pada awalnya, pusat kluster ini tidak diposisikan secara akurat. Setiap titik data memiliki derajat keanggotaan pada setiap kluster. Melalui proses iteratif yang melibatkan penyesuaian pusat kluster dan nilai keanggotaan titik data, pusat kluster secara bertahap konvergen menuju lokasi yang lebih akurat. Proses iteratif ini didorong oleh minimisasi fungsi tujuan, yang mencerminkan jarak antara setiap titik data dan pusat kluster, dengan bobot derajat keanggotaan titik data yang bersangkutan [20]. Prosedur dasar algoritma Fuzzy C-Means ditunjukkan sebagai berikut.

- Langkah pertama: masukkan data yang akan dikelompokkan dalam bentuk matriks $n \times m$, kemudian tentukan jumlah kluster c ($1 \leq c \leq N$), partisi matriks, pangkat w , iterasi maksimum, error terkecil yang diharapkan $\varepsilon > 0$, fungsi tujuan awal $P_0 = 0$, dan iterasi pertama $t = 1$
- Langkah kedua: tetapkan nilai acak (μ_{ik}) sebagai elemen awal matriks partisi U . Hitung total untuk setiap kolom yang dirumuskan dalam (1) dan (2):

$$Q_i = \sum_{k=1}^c \mu_{ik} \quad (1)$$

$$\mu_{ik} = \frac{\mu_{ik}}{Q_i} \quad (2)$$

- Langkah ketiga: menghitung pusat kluster k : V_{kj} yang dirumuskan dalam (3).

$$V_{kj} = \frac{\sum_{i=1}^n ((\mu_{ik})^w * X_{ij})}{\sum_{i=1}^n (\mu_{ik})^w} \quad (3)$$

- Langkah keempat: menghitung fungsi tujuan pada iterasi ke- t , yang dirumuskan dalam (4).

$$P_t = \sum_{i=1}^n \sum_{k=1}^c ([\sum_{j=1}^m (x_{ij} - V_{kj})^2] (\mu_{ik})^w) \quad (4)$$

- Langkah kelima: hitung perubahan partisi matriks yang dirumuskan dalam (5).

$$\mu_{ik} = \frac{[\sum_{j=1}^m (x_{ij} - V_{kj})^2]^{-\frac{1}{w-1}}}{\sum_{k=1}^c [\sum_{j=1}^m (x_{ij} - V_{kj})^2]^{-\frac{1}{w-1}}} \quad (5)$$

- Langkah keenam: periksa kondisi berhenti dengan pernyataan (6).

$$\text{if: } (|P_t - P_{t-1}| < \varepsilon) \text{ or } (t > \text{MaxIter}), \text{ then stop, else if: } t + 1, \text{ repeat step four} \quad (6)$$


Hasil yang dihasilkan oleh algoritma Fuzzy C-Means terdiri dari sekumpulan kluster pusat beserta berbagai tingkat keanggotaan yang diberikan kepada setiap titik data.

2.3. Jaringan Saraf Tiruan

Penelitian ini menggunakan Jaringan Saraf Tiruan (JST) untuk memberikan rekomendasi penyiraman tanaman melalui tahapan seperti yang ditunjukkan pada Gambar 3. Proses dimulai dari pengumpulan dataset yang telah diberi label menggunakan Fuzzy C-Means Clustering. FCM memiliki keunggulan dalam menangani ambiguitas dan ketidakpastian data melalui derajat keanggotaan, yang terbukti lebih

optimal dibandingkan metode klastering konvensional pada data pertanian [21]. Setelah dataset diberi label, tahap selanjutnya itu melakukan oleh rekayasa fitur, termasuk normalisasi data, penanganan nilai yang hilang, dan deteksi serta pembersihan data anomali. Dataset kemudian dibagi menjadi set pelatihan, set validasi, dan set pengujian. Dalam tahap pembangunan model, arsitektur JST dirancang dengan *input layer* berkapasitas 64 neuron yang menggunakan fungsi aktivasi *Rectified Linier Unit* (ReLU). Pada *output layer* memiliki 4 neuron yang merepresentasikan jumlah klaster pada variabel target dengan menggunakan fungsi aktivasi *Softmax* untuk menghasilkan distribusi probabilitas klasifikasi multi-kelas. Proses optimalisasi model dilakukan menggunakan *Adam Optimizer* dengan *learning rate* bawaan sebesar 0,001, dan model dilatih menggunakan *batch size* sebesar 16 setiap iterasinya.

Model yang telah mencapai akurasi terbaik ini kemudian ke format TFLite untuk diimplementasikan dalam aplikasi Android. Pada sistem ini, prediksi dilakukan secara *real-time* berdasarkan *input* sensor (suhu udara, kelembapan udara, kelembapan tanah, dan intensitas cahaya). Walaupun model mengklasifikasikan data kedalam empat klaster, sistem memberikan rekomendasi penyiraman dalam tiga pilihan: tidak disiram, volume sedang, dan volume besar sehingga menciptakan solusi penyiraman inovatif yang tepat dan efisien.



Gambar 3: Alur machine learning

Tahap selanjutnya setelah memperoleh model JST yang optimal adalah melakukan evaluasi kinerja. Evaluasi ini diukur melalui metrik akurasi, presisi, *recall*, dan *F1-Score* yang diekstraksi dari *Confusion Matrix* untuk menganalisis distribusi data yang berhasil diprediksi secara tepat maupun yang mengalami kesalahan klasifikasi. Bentuk dasar dari *Confusion Matrix* ditunjukkan pada Tabel 1.

Tabel 1: Confusion matrix

		Aktual	
		True	False
Prediksi	True	TP (True Positive)	FP (False Positive)
	False	FN (False Negative)	TN (True Negative)

Berdasarkan *Confusion Matrix*, evaluasi kinerja model dihitung menggunakan komponen *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Penjelasan untuk masing-masing metrik evaluasi adalah sebagai berikut:

- Akurasi: Merupakan metrik yang mengukur rasio total prediksi yang benar (positif dan negatif) terhadap keseluruhan data yang dievaluasi. Akurasi menunjukkan sejauh mana model mampu mengklasifikasikan data secara keseluruhan dengan tepat. Evaluasi akurasi didapatkan menggunakan formula (7).

$$akurasi = \frac{TP+TN}{TP+TN+FP+FN} \quad (7)$$

- Presisi: Menggambarkan tingkat ketepatan antara informasi yang diprediksi positif oleh model dengan nilai target yang sebenarnya. Metrik ini sangat penting untuk melihat kemampuan model dalam meminimalkan prediksi positif yang salah (*False Positive*). Evaluasi presisi ini dihitung menggunakan formula (8).

$$presisi = \frac{TP}{TP+FP} \quad (8)$$

- Recall: Dikenal juga sebagai *True Positive Rate*, metrik ini mengukur proporsi data pada kelas positif yang berhasil diidentifikasi dengan benar oleh model dibandingkan dengan total data yang sebenarnya bernilai positif. *Recall* berfokus pada minimalisasi *False Negative*. *Recall* dirumuskan menggunakan formula (9).

$$recall = \frac{TP}{TP+FN} \quad (9)$$

- F1-Score: Merupakan rata-rata harmonik (*harmonic mean*) dari presisi dan *recall*. Metrik ini digunakan untuk mencari keseimbangan antara presisi dan *recall* serta menjadi indikator evaluasi yang lebih komprehensif dan objektif. Metrik ini dirumuskan menggunakan formula (10).

$$F1 - Score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall} \quad (10)$$

3. Hasil dan Pembahasan

3.1. Pra-Pemrosesan Data

Pada tahap awal penelitian, informasi yang dikumpulkan masih mentah dan belum siap untuk digunakan langsung dalam proses analitik. Oleh karena itu, dilakukan pembersihan data terlebih dahulu seperti duplikasi data, nilai yang hilang, dan variabel yang tidak konsisten. Tujuan pembersihan data ini adalah untuk menjamin kualitas data sehingga data yang diproses benar-benar baik dan dapat dipercaya. Dataset yang digunakan terdiri dari 105.660 entri. Setelah dilakukan pra-pemrosesan data menghasilkan total 96.547 entri, seperti yang ditunjukkan pada Gambar 4. Terdapat empat indikator yang digunakan untuk pengelompokan data, yaitu intensitas cahaya (lux), suhu udara, kelembapan udara, dan kelembapan tanah.


	lux	temperature	humidity	soil_moisture
0	9445.83	24.1	73.3	84.78
1	9445.83	24.1	73.3	84.78
2	9333.33	24.1	73.3	84.78
3	9333.33	24.1	73.3	84.78
4	9333.33	24.1	73.3	84.78
...	...	...	...	...
105655	0.00	21.8	89.9	89.35
105656	0.00	21.7	89.9	89.57
105657	0.00	21.7	89.9	89.57
105658	0.00	21.7	89.8	89.57
105659	0.00	21.7	89.9	89.57

96547 rows x 5 columns

Gambar 4: Dataset

Mengidentifikasi *outlier* dalam data adalah langkah pertama sebelum pengelompokan. Pendekatan *Box Plot* digunakan dalam penelitian ini untuk memeriksa data terhadap outlier. Gambar 4 menunjukkan bahwa setiap indikator memiliki outlier berdasarkan hasil *Box Plot*. Tahap pra-pemrosesan data memiliki dampak yang sangat krusial terhadap peningkatan performa dan stabilitas model JST. Tahapan ini diawali dengan proses pembersihan data anomali (*outliers*) menggunakan metode *Interquartile Range* (IQR) yang telah menghapus sekitar 8,62% data. Kehadiran *outliers* yang signifikan pada parameter *lux*, suhu, dan kelembapan udara berpotensi menyebabkan pergeseran gradien komputasi dan menyatukan penarikan pola pada JST. Oleh karena itu, tahapan pembersihan data (*data cleaning*) mutlak diperlukan. Penghapusan nilai ekstrem ini mencegah distorsi pada proses pembelajaran sehingga model dapat berfokus pada pengenalan pola data yang valid.

Tahap pra-pemrosesan krusial selanjutnya yang diimplementasikan pada dataset adalah transformasi rentang nilai melalui teknik normalisasi. Normalisasi penting untuk menjamin semua data berada pada skala yang sama, karena rentang nilai setiap variabel sangat bervariasi. Studi ini menggunakan metode *Min-Max Scaler* yang mentransformasikan nilai setiap variabel berdasarkan nilai minimum dan maksimumnya. Hasilnya, semua nilai berada dalam rentang [0, 1] yang mempermudah proses analisis selanjutnya yaitu pelatihan model. Berdasarkan hasil ringkasan statistik pasca pra-pemrosesan yang disajikan pada Gambar 5, dapat diamati bahwa seluruh parameter input yaitu intensitas cahaya (*lux*), suhu udara (*temperature*), kelembapan udara (*humidity*), dan kelembapan tanah (*soil moisture*) telah diskalakan ulang agar memiliki rentang nilai komputasi yang seragam.



Gambar 5: Data outliers

	lux	temperature	humidity	soil_moisture
count	96547.000000	96547.000000	96547.000000	96547.000000
mean	0.245025	0.395907	0.620455	0.648036
std	0.225639	0.200040	0.207710	0.297477
min	0.000000	0.000000	0.000000	0.000000
25%	0.051927	0.254902	0.482051	0.337772
50%	0.200321	0.379085	0.620513	0.754439
75%	0.370547	0.516340	0.752137	0.903551
max	1.000000	1.000000	1.000000	1.000000


Gambar 6: Hasil normalisasi data

3.2. Hasil Fuzzy C-Means (FCM)

Hasil FCM membagi kelompok menjadi empat klaster utama dengan karakteristik lingkungan yang berbeda, seperti yang ditunjukkan oleh distribusi data dan posisi centroid yang ditampilkan untuk setiap pasangan variabel pada Gambar 7.

Gambar 7 menyajikan representasi hasil FCM pada parameter sensor yang mewakili intensitas cahaya, suhu udara, kelembapan udara, dan kelembapan tanah. Visualisasi antar variabel digunakan untuk mengidentifikasi pola hubungan antar parameter dan karakteristik dari setiap klaster yang terbentuk.

- Klaster 0: Klaster ini mewakili kondisi dengan intensitas cahaya rendah, suhu udara normal hingga hangat, kelembapan udara tinggi, dan kelembapan tanah tinggi. Kondisi ini menunjukkan lingkungan lembap dengan cahaya minimal.
- Klaster 1: Klaster ini mewakili kondisi dengan intensitas cahaya sedang hingga tinggi, suhu udara hangat hingga panas, tingkat kelembapan udara normal, dan tanah yang relatif lembap.
- Klaster 2: Klaster ini menunjukkan kondisi dengan intensitas cahaya sangat tinggi, suhu udara tinggi, kelembapan udara rendah, dan kelembapan tanah rendah. Ini mencerminkan kondisi lingkungan yang panas dan kering.
- Klaster 3: Klaster ini menunjukkan kondisi dengan intensitas cahaya sedang, suhu udara normal, kelembapan udara tinggi, dan kelembapan tanah tinggi. Klaster ini menggambarkan lingkungan lembap dengan paparan cahaya sedang, yang biasanya terjadi selama cuaca berawan atau hujan.



Gambar 7: Hasil pengelompokan Fuzzy C-Means

a. Hubungan antara Intensitas Cahaya (Lux) dan Suhu Udara (Temperature)

Hasil pengelompokan antara variabel lux dan suhu memiliki kecenderungan tren positif dengan peningkatan intensitas cahaya, terjadi peningkatan suhu yang sesuai. Hal ini mencerminkan bagaimana radiasi cahaya menghasilkan pemanasan di lingkungan.

b. Hubungan antara Kelembapan Udara (Humidity) dan Kelembapan Tanah (Soil Moisture)

Hubungan antara kelembapan udara dan kelembapan tanah menunjukkan tren positif yang disertai dengan distribusi titik data yang relatif luas. Kelembapan tanah umumnya meningkat seiring dengan meningkatnya kelembapan udara, meskipun hubungannya tidak sepenuhnya linier. Pengamatan ini menunjukkan bahwa kelembapan tanah dipengaruhi tidak hanya oleh kondisi atmosfer tetapi juga oleh faktor-faktor tambahan, termasuk sifat fisik tanah dan proses hidrologi. Klaster yang dihasilkan mewakili kondisi lingkungan kering, transisi, dan lembap, dengan titik pusat yang menggambarkan karakteristik berbeda yang terkait dengan setiap kategori.

c. Hubungan antara Intensitas Cahaya (Lux) dan Kelembapan Tanah (Soil Moisture)

Visualisasi variabel lux dan kelembapan tanah ini dengan jelas menunjukkan hubungan negatif. Di tempat dengan intensitas cahaya tinggi, tingkat kelembapan tanah lebih rendah. Oleh karena itu, hal ini mencerminkan peningkatan laju penguapan setiap kali terjadi peningkatan paparan cahaya. Secara umum, kelompok yang ditandai dengan nilai lux rendah dikaitkan dengan tingkat kelembapan tanah yang lebih tinggi, sedangkan kelompok dengan nilai lux tinggi sebagian besar didominasi oleh tingkat kelembapan yang rendah.

d. Hubungan antara Suhu Udara (Temperature) dan Kelembapan Udara (Humidity)

Pasangan variabel suhu udara-kelembaban udara menunjukkan korelasi negatif yang jelas dan hampir linier, di mana peningkatan suhu secara konsisten dikaitkan dengan penurunan kelembaban udara. Prosedur pengelompokan secara jelas membedakan kondisi lingkungan menjadi keadaan suhu rendah/kelembaban tinggi, keadaan suhu tinggi/kelembaban rendah, dan kondisi transisi menengah. Posisi centroid yang selaras dengan tren menurun ini, semakin menegaskan koherensi hasil pengelompokan dengan struktur intrinsik data.

e. Evaluasi Fuzzy C-Means

Penerapan algoritma Fuzzy C-Means memungkinkan suatu instance data memiliki derajat keanggotaan yang berbeda untuk beberapa kluster dengan kondisi lingkungan yang lebih representatif, yang pada dasarnya kontinu dan dinamis. Hasil pengelompokan yang diperoleh akan dievaluasi menggunakan *Silhouette Score*, yang menangkap kohesi intra-kluster dan pemisahan antar-kluster. Metrik ini berkisar dari -1 hingga 1. Nilai yang mendekati 1 sesuai dengan kluster yang terdefinisi dengan baik dan terpisah dengan baik, nilai yang mendekati 0 mencerminkan batas kluster yang tumpang tindih atau ambigu, sedangkan nilai negatif menunjukkan kesalahan klasifikasi. *Silhouette Score* dihitung sesuai dengan formulasi yang diberikan dalam rumus (11).

$$s(i) = \frac{b(i) - a(i)}{\max \{a(i), b(i)\}} \quad (11)$$

Hasil evaluasi memberikan *Silhouette Score* sebesar 0,429, yang menunjukkan bahwa struktur kluster yang terbentuk termasuk dalam kategori kualitas yang cukup baik. Nilai ini berarti bahwa titik data dalam setiap kluster lebih mirip satu sama lain daripada titik-titik dalam kluster yang berbeda dengan beberapa tumpang tindih yang tersisa antar kluster. Secara keseluruhan, *Silhouette Score* yang dihasilkan menunjukkan bahwa pengelompokan tersebut cukup kuat untuk menganalisis pola dan mengkarakterisasi kondisi lingkungan.

3.3. Hasil Jaringan Saraf Tiruan (JST)

Setelah proses pengelompokan, dataset diberi label berdasarkan hasil pengelompokan FCM. Jumlah data yang diberi label disajikan pada Tabel 2.

- Kelas 0 dan 3: Tidak perlu penyiraman.
- Kelas 1: Perlu penyiraman dengan jumlah air yang sedang.
- Kelas 2: Perlu penyiraman dengan jumlah air yang banyak.

Tabel 2: Jumlah data setiap kelas

Kelas	Jumlah
0	37789
1	34465
2	5104
3	19189

Untuk memastikan kemampuan model JST yang dibangun, evaluasi performa tidak hanya bergantung pada satu kali pembagian data uji secara statis, melainkan menerapkan skema validasi silang atau *K-Fold Cross-Validation* dengan parameter $k=5$. Dalam skema pembagian data ini, keseluruhan dataset dibagi secara acak ke dalam lima sub-sampel atau *folds* yang berukuran proporsional. Proses pelatihan dan evaluasi model kemudian diulang sebanyak lima iterasi. Pada setiap iterasinya, empat *fold* merepresentasikan 80% dari total data digabungkan sebagai data pelatihan


(*training set*), sementara satu *fold* tersisa merepresentasikan 20% data dialokasikan sebagai data pengujian (*testing set*).


Hasil evaluasi metrik kinerja model JST yang divalidasi disajikan pada Tabel 3. Berdasarkan tabel tersebut, model menunjukkan tingkat keberhasilan yang sangat tinggi dan konsisten pada setiap *fold* pengujian. Secara keseluruhan, model mencapai rata-rata akurasi sebesar 98,85%, rata-rata presisi sebesar 98,23%, rata-rata *recall* sebesar 97,48%, dan rata-rata *F1-Score* sebesar 97,78%. Performa tertinggi dicatat pada Fold 3 dengan tingkat akurasi mencapai 99,18% dan *recall* 99,04%. Di sisi lain, meskipun Fold 2 mencatatkan akurasi terendah dengan akurasi sebesar 98,63%, rentang selisih metrik antar *fold* sangatlah kecil. Variasi performa yang sangat sempit ini merupakan bukti bahwa arsitektur JST yang dibangun memiliki stabilitas yang luar biasa dan terhindar dari indikasi *overfitting* maupun bias pembagian data. Selain itu, nilai *F1-Score* yang sangat tinggi berada di atas 97% merepresentasikan keseimbangan yang sangat baik antara presisi dan *recall*.

Tabel 3: Hasil metrik evaluasi model

Fold Number	Akurasi (%)	Presisi (%)	<i>Recall</i> (%)	<i>F1-Score</i> (%)
1	98.83	98.98	95.84	97.24
2	98.63	98.44	96.03	97.14
3	99.18	98.35	99.04	98.69
4	98.96	98.87	97.68	98.24
5	98.65	96.52	98.82	97.57
Rata-rata	98.85	98.23	97.48	97.78

Hasil evaluasi dari kelima iterasi *Cross-Validation* tersebut divisualisasikan melalui *Confusion Matrix* yang ditunjukkan pada Gambar 8. Keberhasilan model terlihat dengan jelas dari konsentrasi distribusi data yang sangat dominan pada area diagonal utama di setiap matriks dengan tingkat *True Positive* yang tinggi. Sebaliknya, nilai-nilai di luar diagonal utama yang mengindikasikan tingkat kesalahan klasifikasi (*False Positive* dan *False Negative*) berada pada angka yang sangat minim secara merata di semua *fold*. Hal ini mengonfirmasi bahwa model tidak hanya akurat secara komprehensif, tetapi juga sangat andal dan presisi dalam membedakan keempat kluster target tanpa mengabaikan kelas minoritas, sehingga sangat layak diimplementasikan sebagai inti sistem cerdas rekomendasi penyiraman irigasi.






Gambar 8: Hasil *confusion matrix*


3.4. Implementasi Aplikasi Android

Model TFLite yang telah dilatih, diimplementasikan pada aplikasi berbasis Android dengan data *real-time* data sensor yang diperoleh langsung dari lapangan. Hasil prediksi kemudian digunakan untuk menghasilkan rekomendasi penyiraman bagi petani. Seperti yang diilustrasikan pada Gambar 9, model mengklasifikasikan data masukan sebagai Kelas 3, yang menunjukkan bahwa penyiraman tidak diperlukan. Rekomendasi ini disebabkan oleh tingginya kelembapan tanah akibat curah hujan sebelumnya pada hari itu.




Gambar 9: Hasil kelas 3

Gambar 10 menyajikan prediksi Kelas 2 yang menunjukkan bahwa penyiraman dengan volume air yang tinggi sangat diperlukan. Pengukuran sensor yang sesuai menunjukkan kelembapan tanah sedang, suhu udara tinggi, kelembapan udara rendah, dan intensitas cahaya tinggi. Dalam kondisi lingkungan ini, peningkatan radiasi matahari mempercepat penguapan kelembapan tanah. Oleh karena itu, penyiraman yang cukup diperlukan untuk mencegah kekeringan tanah dan mengurangi risiko kekurangan air pada tanaman.



Gambar 10: Hasil kelas 2

Gambar 11 menunjukkan data sensor dengan nilai lux yang sangat rendah, disertai dengan ikon yang menunjukkan kondisi langit berawan. Meskipun tingkat kelembapan tanah sedang, rekomendasi yang diberikan diklasifikasikan sebagai Kelas 1 yang menyarankan penyiraman dengan jumlah air yang sedang. Rekomendasi ini diberikan karena cuaca berawan menunjukkan potensi curah hujan, yang dapat meningkatkan tingkat kelembapan tanah lebih lanjut.



Gambar 11: Hasil kelas 1

4. Kesimpulan

Penelitian ini membuktikan bahwa integrasi algoritma Fuzzy C-Means (FCM) dan Jaringan Syaraf Tiruan (JST) mampu menghasilkan sistem rekomendasi irigasi yang presisi dan efisien. Studi ini memberikan implikasi penting pada literatur pertanian presisi dengan menggunakan pendekatan FCM secara signifikan mampu mengatasi ambiguitas dan tumpang tindih data lingkungan sebelum pemodelan prediktif dilakukan. Keberhasilan model menunjukkan performa yang luar biasa stabil dengan rata-rata akurasi sebesar

98,85%, presisi 98,23%, *recall* 97,48%, dan *F1-Score* 97,78%. Selain itu, sistem ini terbukti optimal diimplementasikan pada aplikasi Android dengan mengkonversi model ke format *TensorFlow Lite* (TFLite).

Sistem yang dibangun ini masih bersifat pendukung keputusan dan belum mencakup aktuasi perangkat keras. Oleh karena itu, penelitian selanjutnya diharapkan dapat memperluas cakupan dataset pada variasi jenis tanah dan iklim yang lebih heterogen, serta mengintegrasikan aplikasi android ini dengan sistem mikrokontroler Internet of Things (IoT) untuk mewujudkan sistem irigasi cerdas yang sepenuhnya otonom.

Pustaka

- [1] Food and Agriculture Organization of the United Nations (FAO), *The Future of Food and Agriculture - Trends and Challenges*. Rome, 2017.
- [2] M. E. Gabr, A. Awad, and H. N. Farres, "Irrigation Water Management in a Water-Scarce Environment in the Context of Climate Change," *Water Air Soil Pollut.*, vol. 235, no. 2, p. 127, Feb. 2024, doi: 10.1007/s11270-024-06934-8.
- [3] E. Bwambale, F. K. Abagale, and G. K. Anornu, "Data-Driven Model Predictive Control for Precision Irrigation Management," *Smart Agricultural Technology*, vol. 3, p. 100074, Feb. 2023, doi: 10.1016/j.atech.2022.100074.
- [4] M. Anil Chougule and A. S. Mashalkar, "A Comprehensive Review of Agriculture Irrigation using Artificial Intelligence for Crop Production," in *Computational Intelligence in Manufacturing*, Elsevier, 2022, pp. 187–200. doi: 10.1016/B978-0-323-91854-1.00002-9.
- [5] A. Younes, Z. E. A. El Assad, O. El Meslouhi, D. E. A. El Assad, and E. Abdel Majid, "The Application of Machine Learning Techniques for Smart Irrigation Systems: A Systematic Literature Review," *Smart Agricultural Technology*, vol. 7, p. 100425, Mar. 2024, doi: 10.1016/j.atech.2024.100425.
- [6] J. Angelin Blessy and A. kumar, "Smart Irrigation System Techniques using Artificial Intelligence and IoT," in *2021 Third International Conference on Intelligent Communication Technologies and Virtual Mobile Networks (ICICV)*, IEEE, Feb. 2021, pp. 1355–1359. doi: 10.1109/ICICV50876.2021.9388444.
- [7] I. W. Widayat, A. A. Arsyad, A. J. Mantau, Y. Adhitya, and M. Köppen, "Fuzzy Methods in Smart Farming: A Systematic Review," *Informatica*, pp. 1–37, Dec. 2024, doi: 10.15388/24-INFOR579.
- [8] M. Benzaouia, B. Hajji, A. Mellit, and A. Rabhi, "Fuzzy-IoT Smart Irrigation System for Precision Scheduling and Monitoring," *Comput. Electron. Agric.*, vol. 215, p. 108407, Dec. 2023, doi: 10.1016/j.compag.2023.108407.
- [9] R. S. Krishnan *et al.*, "Fuzzy Logic based Smart Irrigation System using Internet of Things," *J. Clean. Prod.*, vol. 252, p. 119902, Apr. 2020, doi: 10.1016/j.jclepro.2019.119902.
- [10] A. A. Baradaran and M. S. Tavazoei, "Fuzzy System Design for Automatic Irrigation of Agricultural Fields," *Expert Syst. Appl.*, vol. 210, Dec. 2022, doi: 10.1016/j.eswa.2022.118602.
- [11] M. Del-Coco, M. Leo, and P. Carcagnì, "Machine Learning for Smart Irrigation in Agriculture: How Far along Are We?," *Information*, vol. 15, no. 6, May 2024, doi: 10.3390/info15060306.
- [12] A. K. Jain, "Data Clustering: 50 Years Beyond K-Means," *Pattern Recognit. Lett.*, vol. 31, no. 8, pp. 651–666, Jun. 2010, doi: 10.1016/j.patrec.2009.09.011.
- [13] J. C. Bezdek, R. Ehrlich, and W. Full, "FCM: The Fuzzy C-Means Clustering Algorithm," *Comput. Geosci.*, vol. 10, no. 2–3, pp. 191–203, Jan. 1984, doi: 10.1016/0098-3004(84)90020-7.

- [14] A. M. Anter, A. E. Hassenian, and D. Oliva, “An Improved Fast Fuzzy C-Means using Crow Search Optimization Algorithm for Crop Identification in Agricultural,” *Expert Syst. Appl.*, vol. 118, pp. 340–354, Mar. 2019, doi: 10.1016/j.eswa.2018.10.009.
- [15] Y.-P. Huang, T.-H. Wang, and H. Basanta, “Using Fuzzy Mask R-CNN Model to Automatically Identify Tomato Ripeness,” *IEEE Access*, vol. 8, pp. 207672–207682, 2020, doi: 10.1109/ACCESS.2020.3038184.
- [16] Y. LeCun, Y. Bengio, and G. Hinton, “Deep Learning,” *Nature*, vol. 521, no. 7553, pp. 436–444, May 2015, doi: 10.1038/nature14539.
- [17] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge: The MIT Press, 2016.
- [18] N. Kumar, “Android Usage Statistics 2025: Devices & Market Share.” Accessed: Apr. 05, 2025. [Online]. Available: <https://www.demandsage.com/android-statistics/>
- [19] Z. Lin and Y. Chen, “A Novel Multi-view Fuzzy Clustering Algorithm Based on Fuzzy C-Means,” 2023, pp. 47–60. doi: 10.1007/978-981-99-7869-4_4.
- [20] V. S. Reddy Poli, “Fuzzy C-Means and Fuzzy K-Means Algorithms using Fuzzy Functional Dependencies,” in *2022 International Conference on Fuzzy Theory and Its Applications (iFUZZY)*, IEEE, Nov. 2022, pp. 1–5. doi: 10.1109/iFUZZY55320.2022.9985227.
- [21] B. Choudhary and V. Saxena, “Clustering of Agriculture Data through Fuzzy C-Means Technique,” *African Journal of Biological Sciences BanshidharChoudhary/Afr.J.Bio.Sc*, vol. 6, no. 13, pp. 3312–3329, 2024, doi: 10.48047/AFJBS.6.13.2024.