



Extreme Learning Machine Untuk Memprediksi Curah Hujan Dalam Penentuan Jadwal Tanam Padi

Indah Pratiwi^{1*}, Dimas Bachtiar², Achmad Jauhari³, Muhammad Yusuf⁴, Fifin Ayu Mufarroha⁵, Devie Rosa Anamisa⁶

^{1,2,3,4,5,6} Prodi Teknik Informatika, Fakultas Teknik, Universitas Trunojoyo Madura, Indonesia

Info Artikel	ABSTRAK
Riwayat Artikel: Diterima : 16 November 2024 Direvisi : 22 November 2024 Diterbitkan : 10 Juni 2025	Perubahan iklim dan pola curah hujan yang tidak menentu menjadi tantangan serius bagi pertanian, terutama dalam menentukan waktu yang tepat untuk tanam padi. Penelitian ini bertujuan untuk memodelkan curah hujan sebagai penentu jadwal tanam padi di Kabupaten Bangkalan, Madura. Pulau Madura merupakan pulau terbesar di Jawa Timur dengan total lahan kering seluas 77.999,64 ha di Kabupaten Bangkalan. Pertanian lahan kering sangat bergantung pada curah hujan sehingga memerlukan perencanaan tanam yang tepat untuk efisiensi penggunaan air. Metode Extreme Learning Machine (ELM) dipilih dalam penelitian ini karena dipilih karena kecepatan pelatihan yang tinggi dan kemampuan generalisasi yang baik. Data yang diolah terdiri dari 1.643 data curah hujan harian yang diperoleh dari BMKG Stasiun Meteorologi Perak I Surabaya, dengan rentang waktu dari Januari 2020 hingga Juni 2024. Dari hasil pengolahan data, diperoleh pengujian terbaik dengan rasio data latih dengan data uji sebesar 90:10, menggunakan satu hidden neuron, yang menghasilkan MAPE sebesar 2.489, MAE sebesar 0.0448, dan MSE sebesar 0.0086. Berdasarkan kriteria jadwal tanam padi, dapat disimpulkan bahwa jadwal tanam padi bisa dimulai pada bulan Oktober, karena curah hujan mencapai 150 mm dan mencapai lebih dari 100 mm pada tiga bulan setelahnya di tiap bulannya.
Kata Kunci: Prediksi; Curah Hujan; Metode; Extreme Learning Machine; Penjadwalan Tanam Padi;	ABSTRACT <i>Climate change and unpredictable rainfall patterns are serious challenges for agriculture, especially in determining the right time to plant rice. This study aims to model rainfall as a determinant of rice planting schedules in Bangkalan Regency, Madura. Madura Island is the largest island in East Java with a total dry land area of 77,999.64 ha in Bangkalan Regency. Dry land farming is highly dependent on rainfall, thus requiring proper planting planning for efficient water use. The Extreme Learning Machine (ELM) method was chosen in this study because it was chosen because of its high training speed and good generalization ability. The processed data consists of 1,643 daily rainfall data obtained from BMKG Perak I Surabaya Meteorological Station, with a time span from January 2020 to June 2024. From the results of data processing, the best test was obtained with a ratio of training data and test data of 90:10, using one hidden neuron, which produced a MAPE of 266.3639301, MAE of 0.044828816, and MSE of 0.008593062. Based on the rice planting schedule criteria, it can be concluded that the rice planting schedule can start in October, because rainfall reaches 150 mm and reaches more than 100 mm in the following three months in each month.</i>
Keywords: Prediction; Rainfall; Metode; Extreme Learning Machine; Rice Planting Scheduling;	
Penulis Korespondensi: Indah Pratiwi, Program Studi Teknik Informatika Universitas Trunojoyo Madura Email: indhpratw@gmail.com	This is an open access article under the CC BY-SA license



1. PENDAHULUAN

Sebagai negara agraris, Indonesia memiliki lokasi geografis dan iklim yang sangat mendukung untuk melakukan kegiatan pertanian. Mayoritas penduduk Indonesia bekerja sebagai petani yang mana mendukung untuk pengembangan sektor pertanian. Namun, meskipun potensi pertanian di Indonesia sangat besar, produktivitas sektor ini masih bergantung pada faktor-faktor lingkungan, terutama curah hujan. Curah hujan yang cukup dan memadai sangat mempengaruhi Produktivitas serta kualitas pada. Hal ini dibuktikan dengan kondisi dimana petani yang berada di daerah kekeringan cenderung mengalami gagal panen, sedangkan petani yang berada di daerah basah sering terjadi banjir yang mengakibatkan padi terendam sehingga gagal panen. Tanaman padi tumbuh optimal di lingkungan dengan suhu hangat dan kelembapan tinggi, terutama jika rata-rata curah hujan mencapai 200 mm per bulan atau lebih [1]. Sebagai negara tropis, Indonesia hanya mengalami dua musim, yakni musim kemarau dan musim hujan. Namun, perubahan iklim global membuat Indonesia rentan terhadap cuaca ekstrem seperti kekeringan berkepanjangan atau hujan lebat yang menyebabkan banjir. Selain itu, perubahan iklim juga dapat memicu meningkatnya serangan hama serta penyusutan lahan pertanian yang akan mengurangi hasil panen [2].

Pulau Madura merupakan pulau terbesar di Jawa Timur dengan area lahan kering yang cukup luas. Pertanian di lahan kering pada umumnya ditandai dengan minimnya kebutuhan air serta sangat bergantung pada curah hujan. Di Kabupaten Bangkalan, terdapat 77.999,64 hektare lahan kering. Tanaman pangan yang dibudidayakan di lahan tegalan dan ladang menjadi bentuk pemanfaatan lahan kering yang paling umum di wilayah ini. Kondisi lahan seperti ini menuntut adanya perencanaan tanam yang tepat, terutama dalam menentukan jadwal tanam padi yang akurat agar penggunaan air menjadi lebih efisien [3]. Di era digital saat ini, penerapan teknologi seperti *machine learning* dalam sektor pertanian dapat membantu petani menghindari kegagalan tanam padi dan memaksimalkan hasil panen dengan memberikan prediksi yang lebih akurat terkait waktu tanam.


Penelitian mengenai pemodelan curah hujan sebagai penentu jadwal tanam padi telah banyak dilakukan. Pada tahun 2019, Andi Nurfadly [4] menggunakan data curah hujan di Kabupaten Bulukumba tahun 2008 – 2017. Penelitian ini menerapkan metode Backpropagation dan Regresi Linear yang menghasilkan RMSE yakni 3,752777 dan MSE sebesar 14,08333. Pada tahun yang sama, Rich Juniadi Domitri Simamora [5] melakukan prediksi curah hujan menggunakan metode *Extreme Learning Machine* dengan data curah hujan di wilayah Poncokusumo selama periode 2002 hingga 2015 menghasilkan nilai MAPE terkecil sebesar 3,6852%. Pada tahun 2022, Rafi Prayoga [6] menggunakan data curah hujan Kabupaten Trenggalek selama periode 2019 hingga 2021. Penelitian ini menerapkan model Arima musiman dengan kriteria terbaik yakni ARIMA (0,1,1)(0,1,0) yang menghasilkan RMSE yakni 7.650013 dan MAE sebesar 4.876057. Meski begitu model ARIMA pada dasarnya berupa *short forecast* yang mana akan mengikuti pola musiman yang ada sebelumnya membatasi tingkat fluktuasi pada hasil peramalan model. Hal ini mengakibatkan akurasi model cenderung lebih tinggi. Pada tahun 2023, Yusrah Habibah Laily [7] menggunakan data curah hujan bulanan dari Januari 2017 hingga Desember 2021. Penelitian ini menerapkan metode hibrid Fuzzy Time Series dengan proses stokastik rantai markov (markov chain) yang menghasilkan MAPE 4,30%.

Berdasarkan paparan beberapa peneliti sebelumnya, pada penelitian ini peneliti akan melakukan prediksi dengan menggunakan pendekatan *Extreme Learning Machine* (ELM). ELM digunakan karena unggul dalam proses kecepatan pelatihan serta kemampuan generalisasinya. Pengembangan sistem prediksi ini diharapkan mampu mendukung pemerintah Kabupaten Bangkalan dalam merumuskan kebijakan secara tepat dan cepat di masa mendatang guna mendukung penentuan jadwal tanam padi yang lebih akurat.

2. METODE PENELITIAN

2.1. Rancangan Penelitian

Jenis pendekatan dalam penelitian ini menggunakan metode kuantitatif, karena dalam penelitian ini akan disajikan dengan menggunakan statistik dalam bentuk angka.



Gambar 1. Rancangan Penelitian Untuk Memprediksi Curah Hujan

2.2. Dataset

Data didapatkan dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG). Kabupaten Bangkalan tidak memiliki stasiun pengamatan cuaca, sehingga data yang diolah berasal dari stasiun pengamatan cuaca terdekat, yaitu Stasiun Meteorologi Perak I Surabaya. Data yang diolah merupakan data curah hujan harian periode Januari 2020 – Juli 2024 sebanyak 1643 data.

Tabel 1. Dataset Curah Hujan

Header	Header
01-01-2022	8888
01-01-2022	1.3
01-01-2022	0
01-01-2022	1.8
...	...
27-06-2024	0
28-06-2024	0
29-06-2024	1.4
30-06-2024	0


2.3. Preprocessing

Pada tahap ini, dilakukan pengolahan data agar siap digunakan dalam model prediksi. Tujuan dari pre-processing antara lain untuk menyelaraskan dataset sehingga lebih mudah diolah. Pada penelitian ini, *pre-processing* mencakup beberapa langkah, antara lain data imputation, transformasi data, *lag feature*, dan normalisasi data. Data imputation merupakan proses mengisi missing values dalam dataset. Untuk menjaga konsistensi data, nilai yang hilang (seperti data curah hujan yang kosong) biasanya diisi dengan nilai 0 atau metode lain, sehingga tidak mempengaruhi prediksi. Transformasi data dilakukan untuk mengubah nilai data yang tidak relevan atau anomali, seperti mengganti nilai ekstrem (contohnya, 8888) dengan 0. *Lag feature* adalah proses menambahkan fitur-fitur baru berdasarkan nilai curah hujan pada beberapa periode waktu sebelumnya (misalnya, curah hujan 1 hari sebelumnya, 7 hari sebelumnya, dst.) [5]. Ini membantu model mempelajari pola curah hujan berdasarkan waktu. Normalisasi digunakan untuk menyamakan skala data curah

hujan. Menggunakan skala yang sama membantu model dalam proses pelatihan dan prediksi agar tidak bias terhadap rentang nilai yang berbeda-beda [5].

2.4. Extreme Learning Machine (ELM)

Extreme Learning Machine (ELM) merupakan salah satu metode dari jaringan saraf tiruan (JST) yang menggunakan *Single Hidden Layer Feedforward Neural Networks* (SLFNs). ELM unggul dalam kecepatan proses pembelajaran dibandingkan dengan metode JST konvensional lainnya. Hal ini dikarenakan bobot masukan pada ELM diperoleh secara acak, sedangkan pada JST konvensional diperoleh dari proses pelatihan. ELM memiliki struktur yang simpel dengan langkah-langkah pelatihan yang ringkas, sehingga dapat menghindari masalah seperti *overfitting*, *underfitting*, atau kesalahan dalam penentuan *learning rate* [8]. Arsitektur ELM terdiri dari tiga lapisan, yaitu lapisan input, lapisan tersembunyi, dan lapisan output seperti yang tampak pada gambar 2.



Gambar 2. Arsitektur ELM

Algoritma ELM dibagi menjadi dua tahap, yaitu tahapan pelatihan untuk mendapatkan pola data pada data latih dan tahap pengujian untuk menguji hasil pembelajaran dari tahap pelatihan yang telah dilakukan. Langkah – langkah algoritme ELM sebagai berikut [9].

A. Tahap Pelatihan

1. Inisialisasi secara acak nilai untuk matriks bobot masukan (W_{jk}) dengan rentang nilai -1 sampai 1 berukuran j (*hidden neuron*) $\times$ k (*neuron masukan*) dan matriks bias dalam rentang nilai 0 sampai 1 berukuran $1 \times j$.
2. Melakukan perhitungan matriks pada lapisan tersembunyi (H_{init}) pada persamaan (1).

$$H_{init} = x_{train} * W_{jk} + b_j \quad (1)$$

Keterangan :

- H_{init} adalah hasil dari matriks keluaran pada lapisan tersembunyi
 - x_{train} adalah nilai pada fitur dari data training
 - W_{jk} adalah nilai untuk matriks bobot masukan
 - b_j adalah nilai bias
3. Melakukan perhitungan fungsi aktivasi dari matriks pada lapisan tersembunyi (H_{init}) pada persamaan (2).

$$H = \frac{1}{1 + e^{-H_{init}}} \quad (2)$$

Keterangan :

- H adalah nilai hasil fungsi aktivasi
- H_{init} adalah hasil dari matriks keluaran *hidden layer*

4. Melakukan perhitungan *Moore-Penrose Generalized Invers* (H^+) pada persamaan (3)

$$H^+ = (H^T * H)^{-1} * H^T \quad (3)$$

Keterangan :

- H^+ adalah nilai hasil *Moore-Penrose*
 - $(H^T * H)^{-1}$ adalah *inverse* dari perkalian matriks
 - H^T adalah nilai hasil tranpose dari fungsi aktivasi
5. Menghitung matriks bobot keluaran pada persamaan (4)

$$\beta = H^+ * Y \quad (4)$$

Keterangan :

- β adalah nilai hasil matriks bobot keluaran
- Y adalah target ternormalisasi

B. Tahap Pengujian

1. Inisialisasi nilai bobot masukan dan bias dari proses training
2. Melakukan perhitungan matriks pada lapisan tersembunyi (H_{init}) pada persamaan (5)

$$H_{init} = x_{testing} * W_{jk} + b_j \quad (5)$$

Keterangan :

- H_{init} adalah hasil dari matriks pada lapisan tersembunyi
 - $x_{testing}$ adalah nilai pada fitur dari data testing
 - W_{jk} adalah nilai untuk matriks bobot masukan
 - b_j adalah nilai bias
3. Melakukan perhitungan fungsi aktivasi dari matriks keluaran *hidden layer* (H_{init}) pada persamaan (2).
 4. Menghitung matriks bobot keluaran pada persamaan (4)
 5. Menghitung hasil prediksi data uji pada persamaan (6)

$$y = H * \beta \quad (6)$$

Keterangan :

- Y adalah nilai hasil dari output layer
- H adalah nilai hasil fungsi aktivasi data testing
- β adalah nilai hasil matriks bobot keluaran data training

2.5. Evaluasi

Evaluasi merupakan tahap penting dalam pemrosesan data yang bertujuan untuk mengukur kesalahan dalam peramalan suatu model. Ada beberapa metrik yang umum digunakan untuk menilai kinerja model prediksi, antara lain.

A. Mean Absolute Percentage Error (MAPE)

MAPE mengukur rata-rata kesalahan dalam bentuk persentase dari nilai yang sebenarnya. Nilai MAPE yang lebih kecil menunjukkan kualitas model yang lebih baik. MAPE dihitung menggunakan persamaan (7).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (7)$$

B. Mean Squared Error (MSE)

MSE mengukur rata-rata kuadrat kesalahan dalam prediksi. Nilai MSE yang lebih kecil menunjukkan bahwa kualitas model yang digunakan semakin baik. Nilai MSE dihitung menggunakan persamaan (8).

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (8)$$


C. Mean Absolute Error (MAE)

MAE mengukur rata-rata kesalahan absolut pada prediksi. Nilai MSE yang lebih kecil menunjukkan bahwa kualitas model yang digunakan semakin baik. Nilai MAE dihitung menggunakan persamaan (9).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (9)$$

3. HASIL DAN ANALISIS

Setelah mengumpulkan dataset, langkah selanjutnya adalah melakukan uji prediksi menggunakan *Extreme Learning Machine* (ELM). Pengujian dilakukan untuk mencari *neuron* terbaik berdasarkan perbandingan rasio antara data latih dengan data uji. Lalu untuk mengevaluasi performa prediksi akan digunakan MAPE, MSE dan MAE.



Gambar 3. Hasil Pengujian Berdasarkan MAPE, MAE dan MSE

Grafik di atas merupakan hasil evaluasi dari pelatihan algoritma *Extreme Learning Machine* untuk pencarian hidden *neuron* terbaik berdasarkan ratio data latih dengan data uji dari 70:30, 80:20 dan 90:100. Untuk penjelasan lebih rinci sebagai berikut.

3.1. Pengujian Rasio 70% Data Latih dan 30% Data Uji

Tabel 1. Hasil pengujian menggunakan rasio data latih : data uji 70:30

Jumlah Neuron	MAPE	MAE	MSE
1	3.919999617	0.043641884	0.004773006
2	4.056508473	0.043932895	0.004796174
3	4.191657625	0.038061089	0.004444171
4	4.405800956	0.037694372	0.004403502
5	4.46298063	0.035701563	0.004215856
6	4.385316028	0.033963488	0.00425224
7	4.359055793	0.036233617	0.00438924
8	4.486412187	0.03474962	0.00428524
9	4.435681111	0.034196268	0.004186613
10	4.21424332	0.035154928	0.004327228

Pada tabel 1 di atas, hasil dari pengujian untuk perbandingan 70:30 menunjukkan *neuron* 1 hingga 5 menghasilkan MAE dan MSE yang semakin menurun, pada *neuron* 6 hingga 10 menghasilkan MAE dan MSE yang stabil di kisaran 0.034–0.035, menunjukkan bahwa penambahan *neuron* sudah tidak memberikan peningkatan signifikan. Namun meski begitu, Nilai MAPE yang dihasilkan cukup tinggi karena adanya nilai 0, yang menyebabkan hasilnya menjadi tak terbatas atau tidak terdefinisi (undefined). Pengujian terbaik pada *neuron* 7.

3.2. Pengujian Rasio 80% Data Latih dan 20% Data Uji

Tabel 2. Hasil pengujian menggunakan rasio data latih : data uji 80:20

Jumlah Neuron	MAPE	MAE	MSE
1	2.863826333	0.043140802	0.005358544
2	2.975135139	0.039649262	0.0050441
3	2.704109421	0.04246787	0.00538309
4	2.878057377	0.04061441	0.005392041
5	2.99629245	0.034531408	0.004915421
6	3.034972817	0.035708819	0.004996854
7	3.034228894	0.034045139	0.004915282
8	2.911060833	0.035124625	0.005077141
9	2.906481136	0.03423786	0.005190902
10	3.009180146	0.033619201	0.00511812

Pada tabel 2 di atas, hasil dari pengujian untuk perbandingan 80:20 juga menunjukkan *neuron* 1 hingga 5 menghasilkan MAE dan MSE yang semakin menurun, pada *neuron* 6 hingga 10 menghasilkan MAE dan MSE yang stabil di kisaran 0.033–0.036, menunjukkan bahwa penambahan *neuron* sudah tidak memberikan peningkatan signifikan. Pada pengujian ini juga, MAPE yang dihasilkan juga cukup tinggi.

3.3. Pengujian Rasio 90% Data Latih dan 10% Data Uji

Tabel 3. Hasil pengujian menggunakan rasio data latih : data uji 90:10

Jumlah Neuron	MAPE	MAE	MSE
1	2.489050265	0.044844771	0.008601054
2	2.696901648	0.043592572	0.008252208
3	3.034685277	0.042045429	0.008169881
4	2.902009186	0.043720994	0.00894626
5	3.191188776	0.042195809	0.0085399
6	3.110968392	0.039569099	0.008030573
7	3.32753994	0.041802553	0.00843282
8	3.180502431	0.041069576	0.008248012
9	3.277807243	0.041544988	0.008563487
10	3.328935846	0.040561583	0.008448337

Pada tabel 3 di atas, hasil dari pengujian untuk perbandingan 80:20 juga menunjukkan *neuron* 1 hingga 4 menghasilkan MAE dan MSE yang semakin menurun, pada *neuron* 5 hingga 10 menghasilkan MAE dan MSE yang tidak stabil dan naik turun, menunjukkan bahwa penambahan *neuron* tidak memberikan peningkatan signifikan. Pada pengujian ini juga, MAPE yang dihasilkan juga cukup tinggi, Pengujian terbaik pada *neuron* 4.

Dari hasil pengujian, dapat disimpulkan bahwa jumlah *neuron* 1 hingga 5 memberikan hasil yang cukup baik dengan penurunan MAE dan MSE signifikan. Penambahan *neuron* lebih dari 5 tidak meningkatkan akurasi model secara signifikan, sehingga jumlah *neuron* 1 hingga 5 sudah optimal untuk prediksi. Selain itu, MAPE yang dihasilkan juga sangat tinggi. Hal ini dikarenakan data yang digunakan memiliki nilai 0 yang menandakan hari tidak hujan sehingga hasilnya menjadi tak terbatas atau tidak terdefinisi (undefined) [10].

3.4. Evaluasi Model

Dari 3 hasil pengujian data di atas, diperoleh hasil terbaik pada penggunaan rasio 90% data latih dan 10% data uji serta jumlah hidden *neuron*nya 1.

Tabel 4. Hasil pengujian terbaik


Rasio training : testing	Jumlah Neuron	MAPE	MAE	MSE
90 : 10	1	2.489050265	0.044844771	0.008601054

Dari best parameter di atas, akan dilakukan prediksi untuk 365 hari kedepan (1 tahun ke depan), setelahnya akan dilakukan pengelompokan sesuai bulannya dan diperoleh hasil pada Gambar 4. Masa tanam padi memiliki beberapa kriteria agar waktu penanaman bisa dilakukan. Kriteria ini hanya diterapkan untuk satu periode masa tanam. Masa tanam padi harus memenuhi kriteria sebagai berikut (Basani et al., 2023):

- Curah hujan pada bulan pertama harus melebihi 150 mm per bulan.

- b. Curah hujan selama tiga bulan berikutnya harus lebih dari 100 mm per bulan.

Berdasarkan grafik di atas, dapat disimpulkan bahwa jadwal tanam padi bisa dimulai bulan Oktober karena curah hujan mencapai 150 mm dan pada 3 bulan setelahnya curah hujan mencapai lebih dari 100 mm di tiap bulannya.



Gambar 4. Hasil Prediksi Curah Hujan

4. KESIMPULAN

Berdasarkan hasil pengujian dari 1643 data curah hujan harian, diperoleh pengujian terbaik dengan rasio data latih dengan data uji sebesar 90:10, menggunakan satu hidden *neuron*, yang menghasilkan MAPE sebesar 2.4890502648066573, MAE sebesar 0.0448447709219787, dan MSE sebesar 0.008601053693751005. MAPE yang dihasilkan cukup besar dikarenakan data yang digunakan memiliki nilai 0 yang menandakan hari tidak hujan yang mana menyebabkan hasilnya menjadi tak terbatas atau tidak terdefinisi (undefined). Berdasarkan hasil pengujian terbaik, dilakukan prediksi curah hujan bulanan untuk periode satu tahun berikutnya. Berdasarkan kriteria jadwal tanam padi, dapat disimpulkan bahwa jadwal tanam padi bisa dimulai pada bulan Oktober, karena curah hujan mencapai 150 mm dan mencapai lebih dari 100 mm pada tiga bulan setelahnya di tiap bulannya.

Saran untuk penelitian selanjutnya adalah mempertimbangkan pengujian *lag feature* untuk menangkap pola ketergantungan temporal yang lebih baik. Penambahan *lag feature* dapat membantu model dalam memanfaatkan informasi dari nilai curah hujan sebelumnya. Selain itu, dataset yang digunakan dapat berupa data curah hujan dalam format dasarian atau bulanan. Dapat dilakukan pula modifikasi dengan menambahkan metode optimasi untuk mengatasi kekurangan dari *Extreme Learning Machine* dalam penentuan bobot.

UCAPAN TERIMAKASIH

Dalam kesempatan ini penulis mengucapkan terimakasih kepada Universitas Trunojoyo Madura, Fakultas Teknik, Program Studi Teknik Informatika, serta kepada Badan Meteorologi, Klimatologi, dan Geofisika (BMKG).

REFERENSI

- [1] A. L. Zahra, S. Tiara, R. Ada, and A. F. Ardini, "Implementasi Clustering Algoritma K-Means Pada Produksi Beras di Provinsi Jawa Timur Tahun 2022," *Journal of Computer and Information Systems Ampera*, vol. 5, no. 3, pp. 2775–2496, 2024, [Online]. Available: <https://journal-computing.org/index.php/journal-cisa/index>
- [2] L. Dinar, C. Faradilla, and E. Marsudi, "Analisis Faktor-Faktor Yang Mempengaruhi Impor Beras Di Indonesia," *Jurnal Ilmiah Mahasiswa Pertanian*, vol. 8, no. 3, pp. 136–151, 2023, [Online]. Available: www.jim.unsyiah.ac.id/JFP
- [3] D. Eswin Wijayanti, "Potential And Prospects Of Dry Land Usage On Supporting Food Security In Bangkalan Residence," *Prosiding Semnas Politani Pangkep*, vol. 2, 2021.
- [4] A. N. Keamanan, S. Informasi, and P. Nusantara Makassar, "Prediksi Curah Hujan Dengan Metode Backpropagation Dan Regresi Linear Dalam Penentuan Jadwal Tanam Padi," *Jurnal Teknologi Informasi dan Komunikasi*, vol. 9, no. 2, pp. 127–136, 2019.

- [5] R. Juniadi Domitri Simamora, Tibyani, and Sutrisno, "Peramalan Curah Hujan Menggunakan Metode Extreme Learning Machine," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 3, no. 10, pp. 9670–9676, 2019, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [6] R. Prayoga Dhenanta and I. B. Kholifah, "Prediksi Curah Hujan Bulanan Kabupaten Trenggalek Tahun 2022 dan 2023 Menggunakan Metode ARIMA," in *Seminar Nasional Official Statistics*, 2022, pp. 1135–1143.
- [7] Y. Habibah Laily, F. Rakhmawati, and I. Husein, "Penerapan Metode Fuzzy Time Series-Markov Chain Dalam Peramalan Curah Hujan Sebagai Jadwal Tanaman Padi," *Lebesgue: Jurnal Ilmiah Pendidikan Matematika, Matematika dan Statistika*, vol. 4, no. 1, pp. 162–174, 2023, doi: 10.46306/lb.v4i1.
- [8] A. Nurdiansyah, M. T. Furqon, and B. Rahayudi, "Prediksi Harga Bitcoin Menggunakan Metode Extreme Learning Machine (ELM) dengan Optimasi Artificial Bee Colony (ABC)," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 3, no. 6, pp. 5531–5539, 2019, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [9] T. D. Sukma, I. Cholissodin, and E. Santoso, "Penerapan Metode Extreme Learning Machine (ELM) dengan Optimasi Particle Swarm Optimization (PSO) untuk memprediksi Harga Cabai Keriting di Kota Malang," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 5, no. 9, pp. 3941–3949, 2021, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [10] Trivusi, "Perbedaan MAE, MSE, RMSE, dan MAPE pada Data Science," Trivusi. Accessed: Nov. 11, 2024. [Online]. Available: <https://www.trivusi.web.id/2023/03/perbedaan-mae-mse-rmse-dan-mape.html>