

IMPLEMENTASI ELM MENGGUNAKAN SIGMOID BINER UNTUK PREDIKSI HARGA CABAI RAWIT DI PROVINSI KEPULAUAN BANGKA BELITUNG

Adam Indra Sakti

Program Studi Matematika, Fakultas Sains dan Teknik, Universitas Bangka Belitung

Desy Yuliana Dalimunthe

Program Studi Matematika, Fakultas Sains dan Teknik, Universitas Bangka Belitung

e-mail: desydalimunthe2@gmail.com

Izma Fahria

Program Studi Matematika, Fakultas Sains dan Teknik, Universitas Bangka Belitung

Abstrak

Cabai rawit merupakan salah satu komoditas hortikultura yang mempunyai nilai ekonomi dan harga jual tinggi serta mendapat perhatian serius dari pemerintah dan pelaku usaha. Melonjaknya harga cabai yang tidak menentu menyebabkan para petani dan pelaku distribusi kesulitan dalam mempersiapkan cadangan produksi untuk memenuhi permintaan, dan menjadi komoditas yang berkontribusi signifikan terhadap penyebab inflasi di Provinsi Kepulauan Bangka Belitung. Penelitian ini bertujuan untuk membangun model prediksi harga cabai rawit menggunakan algoritma Extreme Learning Machine (ELM) berdasarkan data historis mingguan dari Januari 2021 hingga Mei 2025. Hasil penelitian didapatkan dengan model terbaik yaitu 4-18-1 dengan menggunakan fungsi aktivasi Sigmoid Biner dengan akurasi MAPE pelatihan sebesar 0.6756192% dan akurasi pengujian sebesar 0.159652% dimana pada tabel kategori MAPE dikatakan sangat baik. Sehingga hal ini menunjukkan bahwa algoritma Extreme Learning Machine (ELM) cocok digunakan untuk memprediksi harga cabai rawit di Provinsi Kepulauan Bangka Belitung.

Kata Kunci: Cabai Rawit, ELM, Sigmoid Biner, MAPE .

Abstract

Cayenne pepper is one of the horticultural commodities that has high economic value and selling price and has received serious attention from the government and business actors. The soaring price of chili that is uncertain causes farmers and distributors to have difficulty in preparing production reserves to meet demand, and becomes a commodity that contributes significantly to the cause of inflation in the Bangka Belitung Islands Province. This study aims to build a prediction model for the price of cayenne pepper using the Extreme Learning Machine (ELM) algorithm based on weekly historical data from January 2021 to May 2025. The results of the study were obtained with the best model, namely 4-18-1 using the Binary Sigmoid activation function with a training MAPE accuracy of 0.6756192% and a testing accuracy of 0.159652% where in the MAPE category table it is said to be very good. So this shows that the Extreme Learning Machine (ELM) algorithm is suitable for predicting the price of cayenne pepper in the Bangka Belitung Islands Province.

Keywords: cayenne pepper, ELM, binary sigmoid, MAPE.

PENDAHULUAN

Indonesia merupakan negara kepulauan dengan sebagian masyarakatnya bermata pencaharian pada sektor pertanian. Sebagai negara agraris, sektor pertanian menjadi andalan dalam penopang struktur ekonomi negara dan sebagai sumber mata pencaharian bagi sebagian besar masyarakatnya. Salah satu sub sektor yang memiliki prospek

pengembangan yang baik dan cukup menjanjikan yaitu sub sektor hortikultura dikarenakan memiliki nilai ekonomis yang tinggi dan berpotensi pada pasar yang luas. (Susanti *et al.*, 2022.).

Cabai merupakan salah satu komoditas hortikultura yang penting bagi sebagian besar daerah di Indonesia (Dwi Zahara *et al.*, 2021). Pada Provinsi Kepulauan Bangka Belitung, komoditas ini memiliki peran strategis dalam perekonomian

daerah baik sebagai bahan pangan yang banyak dibutuhkan masyarakat maupun sebagai sumber pendapatan bagi petani. Selain itu, cabai juga berkontribusi terhadap inflasi di daerah tersebut. Melonjaknya harga cabai yang tidak menentu menyebabkan kesulitan dalam mempersiapkan pasokan menjadikan cabai komoditas yang berkontribusi signifikan terhadap penyebab inflasi di Provinsi Kepulauan Bangka Belitung.

Cabai memiliki varietas yang beragam, salah satu jenis cabai yang populer dan paling sering dijumpai adalah cabai rawit. Cabai rawit (*Capsicum frutescens* L) adalah komoditas yang mempunyai nilai ekonomi dengan harga jual yang tinggi dan mendapat perhatian serius dari pemerintah dan pelaku usaha.

Harga cabai rawit sering mengalami fluktuasi harga di Provinsi Kepulauan Bangka Belitung selama 4 tahun terakhir. Perkembangan harga cabai rawit yang fluktuatif ini tidak terlepas dari resiko rendahnya produksi dan terjadinya gagal panen yang berpengaruh terhadap ketersediaan pasokan (Vivi *et al.*, 2024), serta permintaan cabai rawit yang terus mengalami peningkatan setiap tahun seperti saat menjelang perayaan hari-hari besar, tingkat permintaan dan konsumsi cabai rawit cenderung meningkat dan terkadang melebihi stok ketersediaan itu (Stevanus *et al.*, 2021). Selain itu, menurut Aprionis (2023) Provinsi Kepulauan Bangka Belitung masih memiliki tingkat ketergantungan yang cukup tinggi terhadap pasokan pangan dari luar seperti komoditas cabai yang didatangkan dari Pulau Jawa dan Sumatera untuk memenuhi ketersediaan pasokan sehingga menyebabkan harga cabai sering melonjak.

Kondisi ini menjadikan harga cabai rawit di Provinsi Kepulauan Bangka Belitung sangat rentan terhadap gejolak, baik dari sisi produksi maupun distribusi. Ketergantungan terhadap pasokan luar daerah, ditambah dengan faktor musiman dan fluktuasi permintaan, menciptakan pola harga yang tidak stabil dari tahun ke tahun. Berdasarkan data Badan Pusat Statistik Provinsi Kepulauan Bangka Belitung, produksi cabai rawit tercatat 4.869,2 ton pada tahun 2023, dan meningkat menjadi 5.132,6 ton pada tahun 2024. Kenaikan produksi ini menunjukkan upaya untuk memenuhi permintaan yang terus meningkat dan mengurangi ketergantungan terhadap pasokan luar daerah (Hanifah & Setiawan, 2024).

Penelitian ini menggunakan algoritma *Extreme Learning Machine* (ELM). ELM digunakan untuk memprediksi fluktuasi harga cabai rawit di Provinsi Kepulauan Bangka Belitung, penggunaan pendekatan prediktif berbasis algoritma seperti ELM menjadi sangat relevan karena mampu menangkap pola kompleks yang sulit dijelaskan secara linier.

Tujuan dari penelitian ini adalah untuk mengetahui model arsitektur terbaik dari prediksi harga cabai rawit di Provinsi Kepulauan Bangka Belitung dengan algoritma *Extreme Machine Learning* (ELM) dan mengetahui tingkat akurasi model terbaik dari prediksi harga cabai rawit di Provinsi Kepulauan Bangka Belitung dengan algoritma *Extreme Machine Learning* (ELM).

KAJIAN TEORI

NORMALISASI DAN DENORMALISASI DATA

Normalisasi data adalah metode mengatur atau mengubah nilai data mentah ke dalam skala yang lebih seragam sehingga selisih jarak dalam rentang yang tidak terlalu jauh sehingga data dapat dianalisis dengan lebih efektif dan efisien (Bagus Adiatmaja *et al.*, 2019). Adapun metode normalisasi data yang digunakan yaitu *min-max normalization* rentang [0,1] dengan persamaan sebagai berikut:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2.1)$$

Denormalisasi merupakan kebalikan dari proses normalisasi. Jika pada proses normalisasi data aktual ditransformasi ke dalam rentang tertentu, maka proses denormalisasi mentransformasi kembali nilai ke rentang aslinya. Persamaan denormalisasi data sebagai berikut:


$$x = x'(x_{max} - x_{min}) + x_{min} \quad (2.2)$$

JARINGAN SYARAF TIRUAN

Jaringan syaraf tiruan biasa disingkat JST atau dalam bahasa inggris dikenal sebagai *Artificial Neural Network* (ANN) merupakan teknik yang digunakan untuk membangun program yang cerdas dengan pemodelan yang mensimulasikan cara kerja jaringan syaraf pada otak manusia. JST menggunakan konsep kerja dari syaraf otak manusia untuk menyelesaikan perhitungan pada komputer (Fikriya *et al.*, 2017).

Lapisan-lapisan penyusun JST yang berbentuk *neuron-neuron* tersebut terkumpul dalam lapisan yang dinamakan arsitektur. Menurut *neuron* (Bhakti, 2019) Lapisan pada model tersebut terbagi menjadi

tiga kategori yaitu *input layer* yang berfungsi sebagai menerima data *input*, *hidden layer* berfungsi memproses informasi lebih lanjut setelah menerima *input* dari *neuron input*, dan *output layer* berfungsi menghasilkan hasil akhir atau prediksi dari jaringan syaraf.



Gambar 1. Arsitektur Jaringan Syaraf Tiruan

EXTREME LEARNING MACHINE (ELM)

Extreme Learning Machine (ELM) adalah algoritma pembelajaran dalam jaringan saraf berbasis model yang inovatif menggunakan jaringan *Single-hidden Layer FeedForward Networks* (SLFNs) untuk menghasilkan solusi untuk bobot *output* (Kasliono et al., 2023). *Single-hidden Layer FeedForward Networks* (SLFNs) adalah jenis jaringan saraf tiruan yang memiliki satu lapisan tersembunyi (*hidden layer*) di antara lapisan *input* dan lapisan *output*. SLFNs dimaksudkan untuk mengatasi kelemahan jaringan syaraf tiruan *FeedForward*, khususnya proses *learning speed* yang cepat dibandingkan metode prediksi tradisional (Wang et al., 2022).

FUNGSI AKTIVASI

Fungsi aktivasi merupakan fungsi yang digunakan untuk menentukan nilai keluaran suatu *neuron*. Fungsi aktivasi menghitung nilai keluaran lapisan tersembunyi berdasarkan *input* dan bobot pada *neuron* (Kurniasih et al., 2020). Fungsi aktivasi yang digunakan adalah *sigmoid biner* yaitu fungsi aktivasi yang melakukan proses pada suatu output jaringan dan sesuai nilai target dengan jangkauan nilai $[0,1]$. Fungsi *sigmoid* memiliki persamaan sebagai berikut:

$$f(x) = \frac{1}{1+e^{H_{init}}} \quad (2.3)$$

PROSES PELATIHAN

Proses *training* atau pelatihan merupakan proses tahapan pada ELM dengan tujuan untuk untuk

melatih model. Rincian proses *training* adalah sebagai berikut:

1. Menginisialisasi bobot awal dan bias ke *neuron* tersembunyi dengan bilangan acak dalam interval $[-1, 1]$ menggunakan distribusi *uniform*. Distribusi *uniform* adalah distribusi probabilitas di mana semua nilai dalam rentang tertentu memiliki probabilitas yang sama dan memastikan bahwa model memiliki bobot awal yang seimbang dan acak (Amaliah, 2022).
2. Setelah nilai bobot dan bias didapatkan, dilanjutkan dengan menghitung keluaran lapisan tersembunyi (H_{init}). Proses perhitungan menggunakan persamaan sebagai berikut:

$$H_{init\ ij} = x_i \cdot w_j + b_j \quad (2.4)$$

3. Setelah didapatkan nilai keluaran lapisan tersembunyi, selanjutnya menghitung nilai tersebut dengan fungsi aktivasi. Fungsi aktivasi yang dipakai pada penelitian ini adalah fungsi aktivasi *Sigmoid Biner*. Fungsi aktivasi dioperasikan dengan hasil keluaran dari perhitungan H_{init} seperti pada persamaan (2.5):

$$H = \frac{1}{1+e^{H_{init}}} \quad (2.5)$$

4. Melakukan transpose dari hasil keluaran lapisan tersembunyi dengan fungsi aktivasi (H), lalu melakukan perkalian antara matriks hasil transpose (H^T) tersebut dengan hasil keluaran lapisan tersembunyi dengan fungsi aktivasi *sigmoid* (H). Setelah itu melakukan proses invers matriks pada hasil perkalian matrik H^T dan H dimana hasil dari invers tersebut disimbolkan dengan $(H^T H)^{-1}$. Hasil matriks invers $(H^T H)^{-1}$ dikalikan dengan matriks keluaran lapisan tersembunyi dengan fungsi aktivasi yang telah di transpose H^T . Hasil dari perkalian tersebut disebut matriks *Moore-Penrose Invers* (H^+) yang didefinisikan dalam rumus berikut:

$$H^+ = (H^T H)^{-1} H^T$$

PROSES PENGUJIAN

Pada proses *testing* atau pengujian bertujuan untuk mengevaluasi model yang dihasilkan dari proses *training*. Proses *testing* dilakukan dengan menggunakan data uji. Tahapan proses *testing* hampir sama dengan proses *training*. Tahapan pada proses *testing* adalah sebagai berikut:

1. Menginisialisasi bobot *input* dan bias yang diperoleh dari proses *training*.

2. Menghitung matriks keluaran *hidden neuron* (H_{init}) dengan persamaan (2.5).
3. Menghitung nilai keluaran lapisan tersembunyi yang dihitung dengan fungsi aktivasi dengan rumus yang digunakan pada persamaan (2.6) untuk *Sigmoid Biner*.
4. Setelah didapatkan matriks keluaran dari *hidden neuron* untuk data pengujian atau *testing* ($H_{(test)}$), selanjutnya melakukan perhitungan nilai prediksi (lapisan *output*) menggunakan nilai bobot *output* dari proses *training* (β) dikalikan dengan nilai *hidden neuron* fungsi aktivasi *Sigmoid Biner* pada data pengujian atau *testing* ($H_{(test)}$). Perhitungan dilakukan untuk masing fungsi aktivasi dengan persamaan sebagai berikut:

$$Y_{pred} = H_{(test)} \cdot \beta$$

MEAN ABSOLUTE PERCENTAGE ERROR

Pada penelitian ini, evaluasi pengukuran menggunakan MAPE (*Mean Absolute Percentage Error*) sebagai evaluasi performa model. MAPE dihitung menggunakan kesalahan absolut pada tiap periode dibagi nilai observasi yang sedang terjadi pada periode itu, kemudian, merata-rata kesalahan persentase absolut tersebut. MAPE dinyatakan dalam bentuk persentase, yang membuatnya mudah dipahami dan mudah diinterpretasikan. Rumus MAPE adalah sebagai berikut (Kurniasih *et al.*, 2020):

$$MAPE = \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{n} \cdot 100\%$$


Interpretasi parameter nilai MAPE dapat dilihat dalam Tabel 1.:

MAPE (%)	Interpretasi
$MAPE < 10\%$	Sangat baik
$10 \leq MAPE < 20\%$	Baik
$20 \leq MAPE < 50\%$	Layak/ Cukup
$MAPE \geq 50\%$	Buruk

METODE


Data yang digunakan bersumber dari *website* Pusat Informasi Harga Pangan Strategis Nasional yaitu <https://www.bi.go.id/hargapangan>. Data yang digunakan merupakan data harga cabai rawit mingguan Provinsi Kepulauan Bangka Belitung dimulai dari periode Januari 2021 sampai Mei 2025.

Diagram alur berikut ini menyajikan tahapan yang dilakukan dalam menganalisis data menggunakan algoritma *Extreme Learning Machine* (ELM) untuk melakukan prediksi harga cabai rawit Provinsi Kepulauan Bangka Belitung.



HASIL DAN PEMBAHASAN

Berikut ini disajikan grafik data harga cabai rawit mingguan Provinsi Kepulauan Bangka Belitung periode Januari 2021 sampai Mei 2025.



Gambar 2. Plot Data Harga Cabai Rawit

Berdasarkan Gambar 1, harga tertinggi cabai rawit pada Provinsi Kepulauan Bangka Belitung berada pada angka Rp. 116.600,00 pada minggu kedua Bulan Juli 2022, sedangkan harga terendah berada pada angka Rp. 32.900,00 pada minggu pertama Bulan Juni 2021. Rata-rata dari data harga cabai rawit sebesar Rp. 63.240,00 dengan standar deviasi sebesar Rp. 16.134,00, dari data tersebut dapat dinyatakan bahwa penyebaran data cukup besar, ini menunjukkan data cukup bervariasi dan keragaman atau fluktuasi harga cabai rawit yang tinggi.

PENYUSUNAN POLA DATA

Penyusunan pola data bertujuan untuk merancang arsitektur awal jaringan yang akan digunakan dimana data akan dibagi menjadi data *input* dan data target. Data *input* yang digunakan adalah 4 *lag* atau 4 data sebelumnya dan target adalah 1 sebagai data berikutnya atau data yang digunakan sebagai acuan prediksi.

PELATIHAN MODEL

Pada tahap ini model akan dilatih dengan menggunakan rasio data yang sesuai dengan pembagian data dimana rasio data yang digunakan pada penelitian kali ini adalah 70% untuk pelatihan dan 30% untuk pengujian. Rasio ini memberikan keseimbangan yang baik antara jumlah data yang cukup untuk melatih model dan data yang memadai untuk mengevaluasi kinerjanya. Dengan 70% data untuk pelatihan, model memiliki cukup informasi untuk mempelajari pola-pola dalam data dan 30% data untuk pengujian memungkinkan evaluasi yang baik terhadap kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya.

Penggunaan 30% data untuk pengujian dan sisanya untuk pelatihan sering kali menghasilkan performa model yang optimal. Hal ini membantu dalam menghindari *overfitting* dan memastikan bahwa model tidak hanya menghafal data pelatihan,

tetapi juga dapat menggeneralisasi dengan baik pada data baru (Adinugroho, 2022). Dalam pelatihan juga ditentukan beberapa parameter yang digunakan untuk melatih model yaitu sebagai berikut:

Tabel 2. Parameter Model

No	Parameter	
1	Fungsi Aktivasi	<i>Sigmoid Biner</i>
2	<i>Hidden Neuron</i>	1-20
3	Bobot <i>input</i> dan bias	Distribusi <i>Uniform</i> [-1,1]
4	Evaluasi Pengukuran	MAPE


Dari tabel yang disajikan, ditunjukkan parameter yang digunakan yaitu fungsi aktivasi *Sigmoid Biner*, *hidden neuron* yang digunakan dari 1 sampai 20, bobot *input* dan bias diinisiasi dari rentang [-1,1], dan evaluasi pengukuran menggunakan MAPE untuk mencari model yang terbaik.

Proses pelatihan bertujuan agar dapat mengenal serta mengidentifikasi pola data yang nantinya akan diekstrapolasi polanya kedalam data yang baru untuk dilakukan pengujian serta untuk peramalan. Pada proses ini dilihat *Mean Absolute Percentage Error* (MAPE) terkecil berdasarkan berdasarkan pembagian data serta jumlah *hidden neuron*. Model yang sudah dilatih selanjutnya memasuki tahap pengujian untuk melihat kemampuan model dalam menggeneralisasi data yang belum pernah dilihat sebelumnya.


PENGUJIAN MODEL

Setelah model dilatih, selanjutnya model diuji dengan menggunakan data *testing* sebanyak 30% dari total data, dimana data ini berisi data harga yang tidak dilibatkan dalam pelatihan, sehingga dapat digunakan untuk melihat kemampuan model dalam memprediksi data baru. Hasil prediksi dari proses pelatihan dan pengujian ini nantinya akan dilihat akurasi evaluasinya menggunakan MAPE untuk melihat seberapa baik model yang dihasilkan dalam memprediksi untuk dapat mengikuti data aktual.

Dari proses pelatihan dan pengujian model yang dilakukan, didapatkan model terbaik yaitu 4 *input neuron*, 18 *hidden neuron*, dan 1 *output neuron* dengan MAPE pelatihan sebesar 0.6756192% dan MAPE pengujian sebesar 0.159652%. Grafik perbandingan data aktual dan hasil prediksi ditunjukkan oleh gambar berikut:




Gambar 3. Perbandingan Target dan Prediksi Proses Pelatihan



Gambar 5. Denormalisasi Proses Pelatihan



Gambar 4. Perbandingan Target dan Prediksi Proses Pengujian



Gambar 6. Denormalisasi Proses Pengujian

Garis merah pada tiap grafik menandakan data aktual dan garis biru pada tiap grafik menandakan hasil prediksi. Dari grafik yang ditunjukkan baik dari proses pelatihan maupun proses pengujian, terlihat bahwa hasil prediksi mengikuti pola pergerakan data aktual, baik dari proses pelatihan maupun proses pengujian model. Dari hasil akurasi yang ditunjukkan juga yaitu MAPE pelatihan sebesar 0.6756192% dan MAPE pengujian sebesar 0.159652% menandakan bahwa hasil akurasi dikategorikan sangat baik.

Dari hasil akurasi yang dihasilkan juga, dapat dilihat bahwa tidak adanya gejala *overfitting* dari model terbaik yang dihasilkan. Dilihat dari nilai MAPE pengujian yang lebih baik dari MAPE pelatihan serta perbedaan nilai akurasi yang tidak terlalu jauh dari kedua proses menandakan bahwa model terbaik yang diperoleh yaitu 4-18-1 mampu melakukan pembelajaran dan prediksi yang baik dan terbebas dari kondisi *overfitting*.

DENORMALISASI DATA

Setelah didapatkan hasil prediksi dan model terbaik, tahap terakhir adalah melakukan denormalisasi data untuk mengubah rentang nilai hasil prediksi ke rentang data aktual. Grafik hasil denormalisasi dapat dilihat pada gambar berikut:

PENUTUP

SIMPULAN

Setelah melakukan analisis dan pembahasan mengenai penerapan dari algoritma *Extreme Learning Machine* (ELM) untuk meramalkan harga cabai rawit di Provinsi Kepulauan Bangka Belitung menggunakan fungsi aktivasi *Sigmoid Biner*, ditemukan bahwa model arsitektur terbaik yang digunakan dalam proses pelatihan yaitu menggunakan sebanyak 1 *neuron* pada lapisan keluarannya, sedangkan untuk lapisan masukan sebanyak 4 *neuron* dan lapisan tersembunyi masing-masing sebanyak 12 dan 18 *neuron*.

Dengan rasio pembagian data untuk pelatihan 70% dan pengujian 30%. Dengan menggunakan arsitektur jaringan 4-18-1, diperoleh *Mean Absolute Percentage Error* (MAPE) pada tahap pelatihan sebesar 0.6756192% serta sebesar 0.159652% untuk tahapan pengujianya. Sehingga dari model terbaik yang dihasilkan, dapat disimpulkan bahwa model dapat belajar dengan baik dan memprediksi dengan sangat akurat dibuktikan dengan MAPE yang kecil serta model terbebas dari kondisi *overfitting*.

SARAN

Bagi penelitian selanjutnya, disarankan dapat menggunakan fungsi aktivasi yang lainnya. Lalu dikarenakan hasil akurasi ELM sudah baik disarankan dapat dibandingkan dengan metode atau algoritma lainnya untuk melihat model manakah yang memiliki hasil yang lebih akurat. Untuk meningkatkan performa ELM, disarankan dapat melakukan modifikasi atau *hybrid* seperti dengan metode *Differential Evolution* (DE-ELM), *Optimally Pruned* (OP-ELM), *Empirical Mode Decomposition* (EMD-ELM) dan lain lain agar dapat menghasilkan nilai prediksi dan performa yang lebih baik.

DAFTAR PUSTAKA

- Adinugroho, R. (2022). Perbandingan Rasio Split Data Training Dan Data Testing Menggunakan Metode Lstm Dalam Memprediksi Harga Indeks Saham Asia. Universitas Islam Negeri Syarif Hidayatullah Jakarta.
- Amaliah, F. L. U. (2022). Analisis Jumlah Klaim Agregasi Berdistribusi Negative Binomial Dan Besar Klaim Berdistribusi Discrete Uniform Dengan Menggunakan Metode Konvolusi. Universitas Islam Negeri Walisongo Semarang.
- Aprionis. (2023, February 10). PT Timah - TAM kembangkan cabai di Babel kurangi impor pangan. ANTARA 2025.
- Bagus Adiatmaja, P., Darma Setiawan, B., & Wihandika, R. C. (2019). Peramalan Harga Cabai Merah Besar Wilayah Jawa Timur Menggunakan Metode Extreme Learning Machine (Vol. 3, Issue 6). <http://j-ptiik.ub.ac.id>
- Bhakti, H. D. (2019). Aplikasi Artificial Neural Network (ANN) untuk Memprediksi Masa Studi Mahasiswa Program Studi Teknik Informatika Universitas Muhammadiyah Gresik. *Eksplora Informatika*, 9(1), 88-95. <https://doi.org/10.30864/eksplora.v9i1.234>
- Dwi Zahara, A. T., Susantinah Wisnujati, N., Siswati, E., & Endang Siswati, dan. (2021). Analisis Produksi dan Produktivitas Cabai Rawit (*Capsicum frutescens* L) di Indonesia (Vol. 21, Issue 1).
- Fikriya, Z. A., Irawan, M. I., & Soetrisno. (2017). Implementasi Extreme Learning Machine untuk Pengenalan Objek Citra Digital. *Jurnal Sains Dan Seni Its*, A19-A23.
- Hanifah, R., & Setiawan, I. (2024). Persepsi Konsumen Terhadap Citra "Pasar Tradisional Ratu Tunggal" Di Kota Pangkalpinang. *Enviagro, Jurnal Pertanian Dan Lingkungan*, 10(2), 1-45.
- Kasliono, K., Candraningrum, N., & Sari, K. (2023). Pemodelan Prediksi Harga Ethereum (Atribut: Open, High dan Low) dengan Algoritma Extreme Learning Machine. *Building of Informatics, Technology and Science (BITS)*, 5(1). <https://doi.org/10.47065/bits.v5i1.3567>
- Kurniasih, I. H., Furqon, M. T., & Adinugroho, S. (2020). Prediksi Pertumbuhan Penduduk di Kota Malang menggunakan Metode Extreme Learning Machine (ELM). *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 4(2), 509-516. <http://j-ptiik.ub.ac.id>
- Stevanus, H., Wahyuni, D., Razaf Eriko Simbolon, Y., Ririn Amelia (2021). Peramalan Harga Cabai Rawit Pada Masa Pandemi COVID-19 di Pangkalpinang Provinsi Kepulauan Bangka Belitung, Jurusan Matematika, Universitas Bangka Belitung Kampus Terpadu UBB, Bangka, Kepulauan Bangka Belitung, Seminar Penelitian Dan Pengabdian Nasional Pada Masyarakat 2021, 101.
- Susanti, L., Pririzki, S. J., Zeleansi, Z., Desy, D., Dalimunthe, Y., (2022). Prediksi Harga Cabai Rawit Merah Sebagai Kebutuhan Pangan Masyarakat di Kota Pangkalpinang, Jurusan Matematika, Universitas Bangka Belitung Kampus Terpadu UBB, Bangka, Kepulauan Bangka Belitung, Seminar Penelitian Dan Pengabdian Nasional Pada Masyarakat 2022, 140.
- Vivi, M. M. B., Alfandi Suhardi, P., & Dionesius Budiman, N. (2024). Strategi Pengembangan Usahatani Cabai Rawit (*Capsicum Frutescens* L). *Paradigma Agribisnis*, 7(1), 41-62.
- Wang, J., Lu, S., Wang, S. H., & Zhang, Y. D. (2022). A review on extreme learning machine. *Multimedia Tools and Applications*, 81(29), 41611-41660. <https://doi.org/10.1007/s11042-021-11007-7>