

Penerapan Algoritma *Extreme Learning Machine* dalam Proses Prediksi Kebakaran Hutan dan Lahan di Indonesia

1st Muhammad Rizky Pradhitia

Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

rizkypradhitia@student.telkomuniversit
y.ac.id

2nd Casi Setianingsih

Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

setiacasie@telkomuniversity.ac.id

3rd Meta Kalista

Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

metakalista@telkomuniversity.ac.id

Abstrak — Algoritma *Extreme Learning Machine* (ELM) digunakan untuk memprediksi kebakaran hutan dan lahan di Indonesia berdasarkan data historis cuaca seperti *temperature*, *rainfall*, *humidity*, dan *windspeed*. Algoritma ini memanfaatkan jaringan syaraf lapisan tunggal pada hidden layer dengan waktu pelatihan yang cepat. Proses prediksi dilakukan melalui tahapan pengumpulan data, pembersihan data, normalisasi, dan penanganan outlier. Hasil prediksi dan *forecast* menunjukkan performa yang bervariasi untuk setiap parameter cuaca dengan evaluasi menggunakan metrik *mean absolute error* (MAE), *mean squared error* (MSE), *mean absolute percentage error* (MAPE), dan *R-Squared*. ELM terbukti efektif dalam beberapa parameter seperti *rainfall* namun memiliki kelemahan pada parameter *windspeed*

Kata kunci : *Extreme Learning Machine*, *forecast*, Kebakaran hutan, prediksi cuaca, *machine learning*

I. PENDAHULUAN

Indonesia merupakan negara dengan hutan terbesar kedelapan di dunia dan sering disebut sebagai salah satu paru-paru dunia karena kontribusinya dalam menghasilkan oksigen yang penting untuk keberlangsungan makhluk hidup. Hutan-hutan tersebut menyerap karbon dioksida dan menghasilkan oksigen yang sangat penting bagi ekosistem dan makhluk hidup. Namun, luas hutan di Indonesia semakin menurun, dan keanekaragaman hayati semakin berkurang, salah satu penyebab utamanya adalah kebakaran hutan dan lahan.

Salah satu aspek yang sangat terdampak oleh kebakaran hutan adalah kesehatan masyarakat. Asap dari kebakaran hutan yang mengandung zat berbahaya lainnya yang dapat berdampak negatif pada kesehatan manusia. Ancaman bencana kekeringan dan kebakaran hutan semakin meningkat selama periode musim kemarau. Musim kemarau yang berkepanjangan menjadi pemicu terjadinya kebakaran hutan di beberapa daerah yang cukup rentan, dan mengakibatkan penyebaran asap yang semakin sulit dikendalikan[1].

Dengan menggunakan *machine learning*, Upaya mitigasi kebakaran hutan dapat ditingkatkan. Algoritma *machine*

learning dapat digunakan untuk memprediksi area yang berisiko tinggi terhadap kebakaran hutan berdasarkan data historis seperti *temperature*, *rainfall*, *humidity*, dan *windspeed*. Teknik ini memungkinkan adanya tindakan pencegahan yang lebih efektif dalam menangani kebakaran hutan yang terjadi.

II. KAJIAN TEORI

Dalam memprediksi sebuah fenomena, diperlukan pemahaman lebih mendalam terkait konsep-konsep dasar yang melandasi fenomena tersebut. Data time series dapat menjadi sebuah analisis untuk memprediksi tren sepanjang waktu. Dengan menggunakan data time series dan algoritma *extreme learning machine*, dapat meramalkan dan memprediksi lebih akurat terhadap perubahan. Selain itu, untuk memahami dan menilai risiko kebakaran, dapat menggunakan *fire weather index* sebagai standar dalam mengevaluasi potensi bahaya kebakaran hutan dan lahan.

A. *Extreme Learning Machine*

Algoritma ini merupakan lapisan tunggal yang tersembunyi dan memiliki istilah Single Hidden Layer Feedforward Neural Network (SLFN), dengan beberapa parameter neuron yang tersembunyi, seperti: bobot untuk lapisan ganda perseptron yang disebut sebagai Multilayer Perceptron (MLP). Waktu training metode ini sangatlah cepat dan memiliki performa yang sangat baik, tetapi ada juga beberapa kekurangan, yaitu dapat terjadinya overfitting terhadap model, dapat melemahkan kapasitas kontrol karena metode ini menghitung secara langsung solusi kuadrat terkecil norma minimum, dan dapat memberikan akurasi yang tidak sempurna[2]. Persamaan dasar ELM dinyatakan sebagai berikut:

$$\sum_{i=1}^n \beta_i G(w_i \cdot x_j + b_i) = y_j, j = 1, \dots, N$$

(1)

Keterangan:

G : Fungsi aktivasi

w_i : Vektor bobot yang menghubungkan input neuron ke hidden neuron
 x_j : Input data ke-j
 β_i : Vektor bobot yang menghubungkan hidden neuron ke output neuron
 b_i : Vektor bias menuju l ke-i
 y_j : Vektor target

B. Fire Weather Index

Fire Weather Index (FWI) adalah indeks yang digunakan dalam menilai potensi tingkat bahaya kebakaran hutan berdasarkan masukan data cuaca harian. Indeks ini dikembangkan oleh Canadian Forest Service, lembaga penelitian di Kanada yang bertanggung jawab atas manajemen dan penelitian sumber daya hutan. Dalam melakukan perhitungan FWI, terdapat berbagai komponen penyusun dari FWI seperti FFMFC (Fine Fuel Moisture Code), DMC (Duff Moisture Code), DC (Drought Code), ISI (Initial Spread Index), dan BUI (Buildup Index).

C. Data Time Series


Data *time series* adalah kumpulan observasi yang dilakukan dalam interval waktu tertentu. Data ini dapat membantu dalam mengidentifikasi pola, tren, dan siklus yang terjadi seiring waktu. Data *time series* dapat mencakup variable seperti *temperature*, *rainfall*, *humidity*, dan *windspeed*.

III. METODE

Berikut merupakan flow penerapan data *preprocessing* dan Algoritma *Extreme Learning Machine* dalam melakukan prediksi kebakaran hutan dan lahan.

A. Data preprocessing

Tahapan data preprocessing merupakan tahapan penting sebelum melakukan pemrosesan oleh model machine learning yang akan digunakan. Proses ini melibatkan perubahan data yang mentah menjadi bentuk yang terstruktur. Berikut ini adalah alur dari data *preprocessing*:



GAMBAR 3.1
Flowchart Data Preprocessing

Berdasarkan flowchart di atas terdapat beberapa alur utama dalam melakukan data preprocessing sebelum dilakukan proses modeling menggunakan algoritma machine learning. Berikut ini detail tiga tahapan dalam data preprocessing:

1. Pengumpulan Data

Tahap ini dilakukan dengan mengumpulkan data cuaca dari 1 Januari 2019 hingga 3 Juli 2024 dengan total sebanyak 2015 data. Data tersebut diperoleh dari website Badan Meteorologi Klimatologi dan Geofisika (BMKG) dengan

penentuan data berdasarkan provinsi dan stasiun yang akan dipilih. Berikut ini adalah tampilan pengumpulan data melalui situs web BMKG:

Tanggal	Temperature	Humidity	Rainfall	Windspeed
01-01-2019	28	79	0	3
02-01-2019	31	74	13.5	8
03-01-2019	30.6	76	0.8	7
04-01-2019	30.8	69	0	5
05-01-2019	31.7	70	0	5
06-01-2019	30.4	74	0	5
07-01-2019	29.8	79	0	2
08-01-2019	29.6	84	32.2	4
09-01-2019	28.8	85	18.9	4
10-01-2019	29.2	82	5.1	5
11-01-2019	30.2	85	4.7	5
12-01-2019	30.4	82	2.5	5
13-01-2019	29.2	87	21	5
14-01-2019	26.6	85	83.3	4
15-01-2019	29.4	82	4.4	5
16-01-2019	28	78	3.3	6
17-01-2019	28.8	76	0	6
18-01-2019	29.4	83	4.5	6

GAMBAR 3.1
Data BMKG


2. Data Cleaning

Tahapan pembersihan data merupakan tahapan untuk mendeteksi data yang tidak lengkap, relevan, dan tidak akurat. Proses penanganan data yang tidak valid dapat dilakukan dengan mengidentifikasi data yang tidak akurat dan menjaga kualitas data. Proses ini membantu memastikan bahwa model dapat belajar dari pola yang sebenarnya dalam data dan menghasilkan prediksi yang lebih akurat dan berguna.

3. Handling Outlier

Tahap handling outlier merupakan tahapan mengidentifikasi titik data yang menyimpang secara signifikan. Data outlier dapat mempengaruhi dan mempengaruhi proses training model machine learning yang menyebabkan nilai prediksi tidak akurat. Dalam penanganan outlier, terdapat berbagai metode yang dapat digunakan seperti metode IQR (Interquartile Range), Z - Score, dan boxplot untuk mendeteksi outlier.

B. Penerapan Algoritma



GAMBAR 3.2
Flow Penerapan Algoritma Extreme Learning Machine

Model *Extreme Learning Machine* (ELM) diawali dengan menentukan beberapa parameter yang ada seperti hidden unit layer, activation function, data input serta output. Model ini memiliki nilai bobot (W) dan bias (b) antara hidden layers dan input diinisialisasi secara acak sesuai dengan tipe inisialisasi (normal atau He). Setelah memberikan input beberapa parameter dalam model, tahapan selanjutnya adalah melakukan proses training, dengan menampilkan output dari hidden layer. Setelah training model, prediksi dibuat menggunakan metode predict terhadap data uji. Kinerja model dievaluasi menggunakan metode score, yang 52 menghitung berbagai metrik seperti Mean Absolute Error (MAE), Mean Squared Error (MSE), R-Squared (R^2), dan Mean Absolute Percentage Error (MAPE) menggunakan data uji.

1. Inisialisasi Model

Tahapan awal dari prediksi dan *forecasting* adalah dengan menginisialisasikan algoritma *Extreme Learning Machine* dengan parameter seperti jumlah *hidden unit*, *activation function*, dan jenis inisialisasi bobot. Model ELM memiliki berbagai jenis *activation function* seperti *Sigmoid*, *ReLU*, *Tanh*, dan *Leaky ReLU*. Fungsi aktivasi *sigmoid* menghasilkan *output* antara 0 dan 1 yang cocok untuk model probabilitas. *ReLU* (*Rectified Linear Unit*) merupakan jenis fungsi aktivasi yang bersifat non-linier dimana pengaktifan *neuron* tidak dilakukan secara bersamaan, dan hanya ketika *output* dari transformasi linier bernilai nol [3]. Fungsi aktivasi *Tanh* (*Hyperbolic Tangent*) adalah fungsi yang menghasilkan fungsi diantara -1 dan 1. Inisialisasi bobot dan bias akan dilakukan secara random sesuai dengan jenis distribusi (He atau normal).

2. Pembagian data

Sebelum melakukan proses prediksi, biasanya data terbagi menjadi dua bagian yaitu *train set* dan *test set* dengan rasio yang telah ditentukan. Pembagian data diperlukan bagi model untuk mempelajari data dari *train set* dan akan dilakukan pengujian pada data yang belum pernah dilihat untuk memeriksa kemampuan prediksi.

3. Normalisasi Data

Normalisasi yang digunakan pada langkah ini, yaitu menggunakan *StandardScaler*. *StandardScaler* merupakan fungsi yang digunakan untuk menormalisasi skala nilai variabel. Penggunaan *StandardScaler* akan menyesuaikan distribusi data sehingga memiliki rata-rata 0 dan variansi 1. Hal tersebut dapat dilakukan dengan mengurangi rata-rata dari setiap fitur dan membaginya dengan standar deviasi.

$$X_{scaled} = \frac{x - mean(x)}{std(x)} \quad (2)$$

Keterangan:

$mean(x)$: rata-rata dari semua nilai fitur x dalam *dataset*.

$std(x)$: standar deviasi dari semua nilai fitur x dalam *dataset*.

4. prediksi

Tahapan ini akan melakukan proses prediksi dengan menggunakan model *Extreme Learning Machine* dan telah disesuaikan untuk proses prediksi. Prediksi akan membuat variabel baru dari data aktual. Prediksi ini dibuat berdasarkan data aktual yang diberikan dan diharapkan mendekati nilai aktual.

5. Forecast

Tahapan *forecast* merupakan teknik peramalan dengan memproyeksikan nilai di masa depan yang belum ada dengan menggunakan data historis. *Forecast* digunakan dalam memprediksi nilai yang akan terjadi dimasa mendatang, dalam konteks ini adalah memprediksi nilai parameter.

6. Denormalisasi

Denormalisasi merupakan proses terbalik dari normalisasi atau mengembalikan data ke data asli sebelum dinormalkan [4]. Denormalisasi berguna ketika hasil dari model prediksi perlu dikembalikan ke skala asli untuk

interpretasi yang lebih mudah dalam memahami data. Rumus denormalisasi pada *range* 0 dan 1 adalah sebagai berikut:

$$X_{original} = X_{scaled} + std(x) + mean(x) \quad (3)$$

7. Evaluasi model

Setelah melakukan proses prediksi dan *forecasting*, diperlukan langkah evaluasi untuk memberikan penilaian terkait hasil kinerja model peramalan. Evaluasi dilakukan dengan cara menghitung nilai MAE, MSE, R-Squared, dan MAPE. Dengan melakukan proses evaluasi ini, dapat memberikan penilaian terkait model sehingga dapat dilakukan penyempurnaan model dimasa mendatang. Berikut ini penjelasan lebih detail dari beberapa matriks evaluasi:

a. Mean Absolute Error (MAE)

Mean Absolute Error (MAE) merupakan suatu metode yang digunakan untuk mengukur tingkat keakuratan suatu model *forecasting*. Nilai MAE merepresentasikan rata-rata kesalahan (*error*) absolut antara hasil prediksi dengan nilai aktual [5]. Berikut ini adalah rumus perhitungan dari nilai MAE:

$$MAE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

Keterangan:

y_i : nilai aktual

$\hat{y}_i$: nilai prediksi

n : jumlah observasi atau titik data

b. Mean Squared Error

Mean Squared Error (MSE) adalah metode yang menghitung rata-rata dari kuadrat kesalahan antara nilai aktual dan nilai prediksi dari model. MSE akan memberikan gambaran seberapa baik model dalam menyesuaikan data. Semakin rendah nilai MSE yang dihasilkan, maka akan semakin baik hasil kinerja model dalam memprediksi data. Berikut ini adalah rumus perhitungan dari nilai MSE:

$$MSE = \frac{\sum (y_i - \hat{y}_i)^2}{n} \quad (5)$$

Keterangan:

y_i : nilai aktual

$\hat{y}_i$: nilai prediksi

n : jumlah observasi atau titik data

c. R Squared

R-Squared atau koefisien determinasi adalah metrik evaluasi dalam mengukur seberapa baik variabel independen menjelaskan variasi dalam variabel dependen. Nilai terbaik dari *R-Squared* adalah 1 dan semakin rendah nilai akan menjadi buruk.

$$R - \text{Squared} = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y})^2} \quad (6)$$

Keterangan:

y_i : nilai aktual

$\hat{y}_i$: nilai prediksi

n : jumlah observasi atau titik data

d. Mean Absolute Percentage Error

Mean Absolute Percentage Error (MAPE) adalah suatu metode yang digunakan dalam mengukur kinerja model peramalan. Metode MAPE ini menghitung persentase rata-rata kesalahan absolut antara nilai aktual dan nilai prediksi dari model. Metode ini akan memberikan gambaran tingkat persentase akurasi model dalam melakukan prediksi data. Berikut adalah rumus perhitungan *Mean Absolute Percentage Error (MAPE)*:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_i - \hat{y}_i}{\hat{y}_i} \right| \times 100\%$$

(7)

Keterangan:

y_i : nilai aktual

$\hat{y}_i$: nilai prediksi


n : jumlah observasi atau titik data

IV. HASIL DAN PEMBAHASAN

A. Pengujian Prediksi

Pengujian Prediksi dilakukan dengan menggunakan dataset dari Badan Meteorologi, Klimatologi, dan Geofisika. Proses ini akan membandingkan data aktual dan hasil prediksi untuk mendapatkan hasil evaluasi. Pengujian akan dilakukan dengan sejumlah dataset dari Kabupaten Malang, Jawa Timur sebanyak 2015 data. Pengujian prediksi akan dilakukan dengan keempat parameter yaitu temperature, humidity, rainfall, dan windspeed. Setelah dilakukan proses prediksi, kemudian akan dilakukan proses perhitungan beberapa metrik evaluasi seperti MAE, MSE, MAPE, dan R-Squared.

1. Temperature




GAMBAR 4. 1

Grafik prediksi nilai temperature

Gambar di atas merupakan hasil dari pengujian prediksi pada data *temperature*. Grafik diatas merupakan perbandingan hasil antara data aktual dan prediksi *temperature*.

2. Humidity




GAMBAR 4. 2

Grafik prediksi nilai humidity

Gambar di atas merupakan hasil dari pengujian prediksi pada data *humidity*. Grafik diatas merupakan perbandingan hasil antara data aktual dan prediksi *humidity*.

3. Rainfall




GAMBAR 4. 3

Grafik prediksi nilai rainfall

Gambar di atas merupakan hasil dari pengujian prediksi pada data *rainfall*. Grafik diatas merupakan perbandingan hasil antara data aktual dan prediksi *rainfall*.

4. Windspeed



GAMBAR 4. 4


Grafik prediksi nilai windspeed

Gambar di atas merupakan hasil dari pengujian prediksi pada data *windspeed*. Grafik diatas merupakan perbandingan hasil antara data aktual dan prediksi *windspeed*.

B. Pengujian Forecast

Pengujian forecast dilakukan dengan menggunakan dataset dari Badan Meteorologi, Klimatologi, dan Geofisika. Proses ini akan membandingkan data aktual dan hasil forecast. Pelaksanaan forecast dilakukan pada saat tanggal 1 Juli – 7 Juli 2024 dengan bertujuan untuk menguji kemampuan model forecasting dalam periode tertentu.

1. Temperature




GAMBAR 4. 5

Grafik forecasting nilai temperature

Gambar di atas menunjukkan perbandingan antara *temperature forecast* dan *temperature* aktual dari tanggal 1 Juli 2024 hingga 7 Juli 2024. Garis biru mewakili

temperature aktual, sedangkan garis merah mewakili *temperature forecast*.


2. Humidity



GAMBAR 4. 6
Grafik forecasting nilai humidity

Grafik di atas menunjukkan perbandingan antara *humidity forecast* dan *humidity* aktual. Garis biru mewakili *humidity* aktual, sedangkan garis merah mewakili *humidity forecast*.


3. Rainfall



GAMBAR 4. 7
Grafik forecasting nilai rainfall

Grafik di atas menunjukkan perbandingan antara *rainfall forecast* dan *rainfall* aktual. Garis biru mewakili *rainfall* aktual, sedangkan garis merah mewakili *rainfall forecast*.

4. Windspeed



GAMBAR 4. 8
Grafik forecasting nilai windspeed

Grafik di atas menunjukkan perbandingan antara *windspeed forecast* dan *windspeed* aktual. Garis biru mewakili *windspeed* aktual, sedangkan garis merah mewakili *windspeed forecast*.

C. Evaluasi Matriks

Evaluasi matriks merupakan cara untuk melihat seberapa baik model prediksi dan *forecast* yang digunakan bekerja dengan menggunakan beberapa metrik. Dalam penelitian ini, beberapa metrik yang digunakan untuk mengukur akurasi dan performa model Extreme Learning Machine (ELM) adalah

Mean Absolute Error (MAE), Mean Squared Error (MSE), R-Squared (R^2), dan Mean Absolute Percentage Error (MAPE).

TABEL 4. 1
evaluasi matriks prediksi

	MAE	MSE	R^2	MAPE
<i>Temperature</i>	0.97	1.53	0.3	2.47
<i>Humidity</i>	4.37	30.5	0.41	5.15
<i>Rainfall</i>	0.19	0.08	1	25.44
<i>Windspeed</i>	0.96	1.52	0.04	6.58

pada tabel prediksi, dapat dilihat bahwa model prediksi untuk masing-masing parameter cuaca memiliki variasi performa yang berbeda. model prediksi untuk *rainfall* memiliki nilai R^2 yang bagus, menunjukkan bahwa model ini sangat akurat dalam memprediksi *rainfall*. untuk parameter *windspeed*, nilai R^2 yang sangat rendah (0.04) menunjukkan bahwa model ini kurang akurat dalam memprediksi *windspeed*.

TABEL 4. 2
evaluasi matriks forecast

	MAE	MSE	R^2	MAPE
<i>Temperature</i>	0.83	0.93	2.16	0.00
<i>Humidity</i>	6.21	45.02	7.33	-0.68
<i>Rainfall</i>	1.83	4.91	17.68	0.41
<i>Windspeed</i>	0.83	0.87	5.17	0.11

Pada tabel *forecast*, dapat dilihat bahwa nilai MAE, MSE, R^2 , dan MAPE juga menunjukkan performa yang bervariasi untuk masing-masing parameter cuaca. model forecast untuk *temperature* menunjukkan nilai MAE yang lebih rendah (0.83) dibandingkan dengan prediksi, serta nilai MSE yang lebih rendah (0.93). Namun, model forecast untuk *humidity* menunjukkan performa yang lebih buruk dengan nilai MSE yang lebih tinggi (45.02) dan nilai R^2 yang lebih rendah (7.33).

V. KESIMPULAN

Penerapan algoritma Extreme Learning Machine (ELM) dalam proses prediksi kebakaran hutan dan lahan di Indonesia memberikan hasil yang beragam tergantung pada parameter cuaca yang digunakan. Prediksi dan forecast yang dilakukan menggunakan data historis *temperature*, *humidity*, *rainfall*, dan *windspeed* menunjukkan performa yang cukup baik di beberapa parameter. Secara khusus, model ini berhasil memprediksi parameter *rainfall* dengan akurasi yang sangat baik, ditunjukkan oleh nilai R -Squared yang tinggi. Namun, untuk parameter *windspeed*, performa model kurang akurat, ditandai dengan nilai R -Squared yang rendah.

Penggunaan ELM dalam prediksi kebakaran hutan dan lahan memperlihatkan potensi besar dalam upaya mitigasi bencana. Dengan kemampuan untuk memproses data dalam jumlah besar dan menghasilkan prediksi yang cepat, ELM memungkinkan adanya tindakan pencegahan yang lebih efektif. Model ini memanfaatkan data time series untuk mengidentifikasi pola dan tren yang dapat mengindikasikan risiko kebakaran hutan di masa mendatang.

Selain itu, evaluasi menggunakan metrik *mean absolute error* (MAE), *mean squared error* (MSE), dan *mean absolute percentage error* (MAPE), menunjukkan bahwa ELM dapat digunakan untuk memprediksi kebakaran hutan dan lahan, meskipun perlu peningkatan lebih lanjut untuk parameter tertentu seperti *windspeed*.

REFERENSI

- [1] E. Heriyanto dan D. E. Nuryanto, "Prediksi Sebaran Asap Kebakaran Hutan/Lahan Menggunakan WRF/CHEM," *Jurnal Meteorologi dan Geofisika*, vol. 15, no. 1, hlm. 51–58, 2014, doi: 10.31172/jmg.v15i1.172.
- [2] W. Deng, Q. Zheng, dan L. Chen, "Regularized Extreme Learning Machine," dalam *2009 IEEE Symposium on Computational Intelligence and Data Mining*, Mar 2009, hlm. 389–395. doi: 10.1109/CIDM.2009.4938676.
- [3] I. Firmansyah dan B. H. Hayadi, "Komparasi Fungsi Aktivasi Relu Dan Tanh Pada Multilayer Perceptron," *JIKO (Jurnal Informatika dan Komputer)*, vol. 6, no. 2, hlm. 200–206, Sep 2022, doi: 10.26798/jiko.v6i2.600.
- [4] K. Dewi, P. P. Adikara, dan S. Adinugroho, "Prediksi Indeks Harga Konsumen (IHK) Kelompok Perumahan, Air, Listrik, Gas Dan Bahan Bakar Menggunakan Metode Support Vector Regression," 2018. [Daring]. Tersedia pada: <http://j-ptiik.ub.ac.id>
- [5] A. A. Suryanto, "PENERAPAN METODE MEAN ABSOLUTE ERROR (MEA) DALAM ALGORITMA REGRESI LINEAR UNTUK PREDIKSI PRODUKSI PADI," *SAINTEKBU*, vol. 11, no. 1, hlm. 78–83, Feb 2019, doi: 10.32764/saintekbu.v11i1.298.