



Peramalan Luas Area Kebakaran Menggunakan Metode *Particle Swarm Optimization Extreme Learning Machine*

Latifa Alifa Maura¹, Fatkhurokhman Fauzi², Ali Imron³

^{1, 2, 3}Program Studi Statistika, Universitas Muhammadiyah Semarang

¹mauralatisa@gmail.com

²fatkhurokhmanf@unimus.ac.id

³aliimron@unimus.ac.id

Corresponding author email: mauralatisa@gmail.com

Abstract: Forest and land fires are a national disaster in Indonesia. In 2023, South Kalimantan recorded the largest burned area reaching 190,394.58 hectares. Fires tend to spread more rapidly under high temperatures and wind speeds also when humidity and rainfall are low. This study applies the PSO-ELM method, where Particle Swarm Optimization (PSO) is used to improve the accuracy of the Extreme Learning Machine (ELM) by optimizing initial weights and biases. The aim is to evaluate the PSO-ELM model's performance in forecasting burned area in South Kalimantan. The data show significant fluctuations, ranging from 2 to 137,446 hectares. The Mean Absolute Percentage Error (MAPE) from the training and testing datasets is 4.37% and 2.09%, respectively, indicating high prediction accuracy. The final model consists of 4 input neurons, 7 hidden neurons, a population size of 60, learning factors $C_1 = 2$ and $C_2 = 1$, inertia weights between 0.4 and 0.9, and a maximum of 1000 iterations. The forecast indicates that the burned area in 2024 will peak in July at approximately 49,236.45 hectares, while no burned area is expected in January and October.

Keywords: Climate, Extreme Learning Machine, Forest and Land Fires, Particle Swarm Optimization, Forecast

Abstrak: Kebakaran hutan dan lahan merupakan bencana nasional di Indonesia. Pada tahun 2023, Kalimantan Selatan tercatat sebagai kebakaran hutan dan lahan tertinggi di Indonesia dengan luas kebakaran mencapai 190394,58 hektar. Karhutla akan meluas saat temperatur dan kecepatan angin tinggi serta kelembaban dan curah hujan rendah. Penelitian ini menggunakan metode PSO-ELM, yang mana PSO digunakan untuk mengatasi kelemahan ELM dalam penentuan bobot dan *bias* sehingga akurasi meningkat. Tujuan penelitian ini adalah untuk mengevaluasi kinerja model PSO-ELM dalam melakukan peramalan luas area kebakaran di Kalimantan Selatan. Data menunjukkan terjadi fluktuasi yang signifikan dengan rentang sebesar 2 ha hingga 137446 ha. Nilai MAPE hasil pemrosesan data latih dan data uji partikel optimal didapatkan sebesar 4,37% dan 2,09% sehingga peramalan ini memiliki akurasi yang tinggi karena nilainya <10%. Model PSO-ELM yang dibangun terdiri dari 4 *input* neuron, 7 *hidden* neuron, 60 jumlah populasi, $C_1 = 2$, $C_2 = 1$, bobot inersia maksimum 0,9, bobot inersia minimum 0,4, dan 1000 iterasi maksimum. Hasil peramalan luas area terbakar 12 bulan ke depan di Kalimantan Selatan tertinggi terjadi pada bulan Juli 2024 sebesar 49236,453 ha dan terendah terjadi pada bulan Januari dan Oktober 2024 sebesar 0 ha.

Kata kunci: *Extreme Learning Machine*, Iklim, Kebakaran Hutan dan Lahan, *Particle Swarm Optimization*, Peramalan

I. PENDAHULUAN

Kebakaran hutan dan lahan merupakan bencana nasional karena dampaknya merugikan berbagai sektor. Bencana ini menjadi penyebab berkurangnya kualitas ekosistem alam, gangguan kesehatan masyarakat, serta kerugian aspek ekonomi dan sosial [1]. Bencana kebakaran lahan dan hutan tidak terlepas dari bencana kekeringan (*drought*) yang kejadiannya diperluas oleh faktor manusia sebesar 90%, sementara faktor alam hanya berkontribusi sebesar 10% [2].

Manusia seringkali secara sengaja membakar hutan untuk pembersihan hutan dan lahan dengan demi kepentingan kelompok maupun individu. Tindakan ceroboh manusia tidak terlepas dari kejadian karhutla, seperti membuang puntung rokok sembarangan saat terjadi kekeringan [3]. Faktor alam yang memegang peran dalam kejadian kebakaran hutan dan lahan adalah iklim (curah hujan, temperatur, kecepatan angin, dan kelembaban) [4] [5]. Menurut Fuller (1991), iklim menentukan jumlah bahan bakar alami dan jangka waktu kebakaran. Jika iklim lebih kering, maka jumlah bahan bakar alami akan meningkat dan menyebabkan bahan bakar alami seperti, daun kering, ranting, dan rumput lebih mudah terbakar. Hal ini menyebabkan jangka waktu kebakaran akan meningkat [6].

Berdasarkan morfologis tanah gambut yang tersebar luas di Indonesia mengalami degradasi fungsi dalam menyerap air karena ekologisnya terganggu. Hal ini menyebabkan Indonesia rentan




terjadi bencana kebakaran hutan dan lahan [7]. Pada tahun 2023, luas kebakaran hutan dan lahan meningkat 4 kali lipat dibandingkan 3 tahun sebelumnya dengan Kalimantan Selatan sebagai wilayah dengan luas kebakaran hutan dan lahan tertinggi di Indonesia yang tercatat sebesar 190394,58 hektar. Berdasarkan data KHLK, Kalimantan Selatan mengalami degradasi fungsi tanah gambut hanya tersisa sekitar 10% atau seluas 238465 ha. Topografi Kalimantan Selatan ini menjadi faktor wilayah ini rawan terkena kebakaran hutan dan lahan.



Gambar 1. Kebakaran Tertinggi 2023

Perubahan iklim yang tidak menentu sebagai faktor kebakaran hutan dan lahan memerlukan penelitian lebih lanjut agar bisa digunakan sebagai bahan kebijakan pencegahan oleh lembaga karhutla. Peramalan merupakan cara yang dapat digunakan sebagai acuan masa depan guna memprediksi risiko tinggi kebakaran hutan dan lahan. Data kebakaran hutan dan lahan memiliki fluktuasi yang tinggi sehingga hanya bisa didekati dengan model non-linear. Jaringan Saraf Tiruan adalah metode yang mengadaptasi jaringan saraf biologis pada otak manusia telah banyak diterapkan dalam peramalan data non-linear [8]. ELM merupakan salah satu kategori JST yang prosesnya lebih cepat dibandingkan Metode *Backpropagation* [9].



Gambar 2. Luas Area Terbakar Kalimantan Selatan


Extreme Learning Machine menentukan bobot awal dan *bias* secara acak yang dapat mempengaruhi akurasi. Metode metaheuristik dapat diterapkan untuk mengatasi kelemahan ELM. Penelitian mengenai perbandingan beberapa metode metaheuristik didapatkan PSO menghasilkan akurasi yang lebih baik daripada GA, BA, ABC, dan ACO [10], [11] [12]. Penggabungan metode ELM dan PSO dibuktikan dari penelitian oleh Ariyanti dkk (2023) didapatkan bahwa akurasi Metode ELM sebesar 57,32% sedangkan Metode PSO-ELM sebesar 83,74%. Dengan demikian, Algoritma *Particle Swarm Optimization* mampu meningkatkan akurasi *Extreme Learning Machine* dalam klasifikasi penyakit jantung [13].

Penelitian ini menerapkan algoritma *Particle Swarm Optimization Extreme Learning Machine* (PSO-ELM). Algoritma PSO-ELM digunakan untuk meramalkan luas area kebakaran di Kalimantan Selatan. PSO diterapkan sebagai metode optimasi ELM dalam menentukan bobot awal dan *bias* sehingga akurasi yang dihasilkan meningkat. Hal ini membuat model yang dihasilkan lebih optimal dan *error* prediksi menurun.



II. METODE PENELITIAN

PSO-ELM merupakan hybrid kedua metode PSO maupun ELM. Kedua metode tersebut digabungkan untuk meningkatkan akurasi dan mengatasi kelemahan ELM. Di bawah ini merupakan Langkah PSO-ELM yang akan dilakukan.



Gambar 3. Proses PSO-ELM

2.1. Data Penelitian

Penelitian ini menggunakan data dari NASA untuk faktor iklim dan MapBiomas untuk data luas area kebakaran dari tahun 2014 hingga 2023. Hasil pengumpulan data akan dibagi dengan perbandingan 80% data *training* dan 20% data *testing*. Variabel yang digunakan dalam penelitian ini terdapat pada Tabel 1.

Tabel 1. Variabel Penelitian

Variabel	Nama Variabel	Skala	Satuan
Y	Luas Area Terbakar	Rasio	Hektar (ha)
X_1	Curah Hujan	Interval	Milimeter (mm)
X_2	Kelembaban	Rasio	Persen (%)
X_3	Temperatur	Rasio	Celcius (°C)
X_4	Kecepatan Angin	Rasio	Meter per detik (m/s)

2.2. Peramalan

Peramalan merupakan ilmu yang berfungsi untuk memprediksi masa depan menggunakan *historical* data dan model matematis. Seringkali, peramalan melibatkan penggabungan model matematis dan penilaian manajer [14]. Secara umum, peramalan diklasifikasikan berdasarkan waktunya, yaitu jangka pendek, jangka menengah, dan jangka panjang.

2.3. Extreme Learning Machine (ELM)

Extreme Learning Machine (ELM) adalah metode yang mengadaptasi saraf otak manusia dan dikategorikan dalam jaringan *Single Hidden Layer Feedforward Neural Networks* (SLNFs). Metode



ini ditemukan oleh Huang pada tahun 2004 yang terdiri dari lapisan *input*, satu lapisan *hidden* dan lapisan *output*. Lapisan-lapisan tersebut dihubungkan dengan bobot. ELM diusulkan untuk mengatasi masalah yang ada pada algoritma SLNFs terdahulu, seperti *Slow Gradient Based Learning Algorithm* memiliki kelemahan pada lambatnya kinerja dan mudah terjebak pada minimum lokal. Metode ELM merupakan solusi karena menawarkan kinerja yang lebih cepat dengan algoritma sederhana dan mampu menghasilkan *error* pelatihan yang lebih kecil.

Langkah-langkah metode *Extreme Learning Machine* adalah sebagai berikut:

1. Normalisasi Data

Normalisasi data adalah proses transformasi yang dilakukan agar distribusi data homogen. *Min-max Normalization* adalah salah satu metode normalisasi dengan melakukan transformasi linear data dan persebaran data menjadi seimbang (Henderi et al., 2021). *Min-max Normalization* memiliki interval $[0, 1]$ dengan keunggulan mampu melakukan transformasi dengan cepat (Suryanegara et al., 2021). Menurut Siang (2005), pada metode *Extreme Learning Machine* yang menerapkan fungsi aktivasi sigmoid biner tidak akan mampu menghasilkan transformasi dengan interval $[0, 1]$ karena dikelompokkan sebagai fungsi asimtotik.

$$X' = \frac{0,8(X - \min(x))}{(\max(x) - \min(x))} + 0,1 \quad (1)$$

Keterangan:

X' : data hasil normalisasi
 X : data aktual
 $\min(x)$: nilai minimum
 $\max(x)$: nilai maksimum

2. Proses Training

Proses *training* merupakan proses memasukkan masalah untuk diselesaikan. Langkah-langkah proses *training* dalam metode *Extreme Learning Machine* adalah sebagai berikut:

- 1) Inisialisasi bobot masukan $[-1, 1]$ dan bias $[0, 1]$ dilakukan secara acak.
- 2) Menghitung matriks *output hidden layer* data pelatihan.

$$\mathbf{H}_{init\ train} = (\mathbf{X}_{train} \mathbf{W}^T) + \mathbf{b} \quad (2)$$

Keterangan:

$\mathbf{H}_{init\ train}$: matriks *output hidden layer*
 $\mathbf{X}_{train}$: matriks data latih
 $\mathbf{W}$: matriks bobot *input*
 $\mathbf{W}^T$: matriks transposisi bobot *input*
 $\mathbf{b}$: vektor *bias*

- 3) Menghitung matriks $\mathbf{H}$ menggunakan fungsi aktivasi sigmoid biner.

$$\mathbf{H} = \frac{1}{1 + e^{(-\mathbf{H}_{init\ train})}} \quad (3)$$

Keterangan:

$\mathbf{H}$: matriks *output hidden layer*
 e : eksponensial

- 4) Menghitung matriks *Moore-Penrose PseudoInverse*.

$$\mathbf{H}^+ = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \quad (4)$$



Keterangan:

H^+ : matriks *Moore-Penrose PseudoInverse*

H^T : matriks transposisi H

- 5) Menghitung bobot keluaran.

$$\beta = H^+ Y \quad (5)$$

Keterangan:

β : vektor bobot keluaran

Y : vektor ramalan

- 6) Menghitung hasil ramalan.

$$Y = H\beta \quad (6)$$

Keterangan:

Y : vektor *output* ramalan data pelatihan

- 7) Menghitung nilai RMSE.

Root Mean Square Error (RMSE) adalah selisih antara nilai aktual dan nilai ramalan yang diakar kuadrat. Kriteria dari RMSE adalah semakin kecil nilai RMSE, maka *error*-nya juga semakin kecil [15].

$$RMSE = \sqrt{\frac{1}{N} \sum_{j=1}^N (y_j - \hat{y}_j)^2} \quad (7)$$

Keterangan:

N : jumlah data pelatihan

j : 1, 2, ..., N

y_j : data aktual ke- j

$\hat{y}_j$: data hasil ramalan ke- j

3. Proses *Testing*

Proses *testing* adalah proses untuk mengevaluasi kinerja suatu metode berdasarkan proses *training* [16]. Langkah-langkah proses *testing* dalam metode *Extreme Learning Machine* adalah sebagai berikut:

- 1) Inisialisasi bobot masukan $[-1, 1]$ dan bias $[0, 1]$ dilakukan secara acak.
- 2) Menghitung matriks *output hidden layer* data pengujian.

$$H_{init\ test} = (X_{test} W^T) + b \quad (8)$$

Keterangan:

$H_{init\ test}$: matriks *output hidden layer*

X_{test} : matriks data latih

W : matriks bobot *input*

W^T : matriks transposisi bobot *input*

b : vektor *bias*

- 3) Menghitung matriks H menggunakan fungsi aktivasi sigmoid biner.



$$H = \frac{1}{1+e^{(-H_{init\ test})}} \quad (9)$$

Keterangan:

H : matriks *output hidden layer*

e : eksponensial

- 4) Menghitung keluaran *output layer* menggunakan bobot *output* β yang telah diperoleh dari proses *training* mengacu pada (5).

4. Denormalisasi Data

Denormalisasi data dilakukan untuk mengembalikan data ke distribusi aslinya agar mudah diinterpretasikan [17].

$$\hat{y}_j = \frac{(\hat{y}'_j - 0,10)(\max(x) - \min(x))}{0,8} + \min(x) \quad (10)$$

Keterangan:

$\hat{y}_j$: data denormalisasi ke- j

$\hat{y}'_j$: data peramalan hasil normalisasi ke- j

$\max(x)$: data maksimum sebelum dinormalisasi

$\min(x)$: data minimum sebelum dinormalisasi

2.4. Particle Swarm Optimization (PSO)

Algoritma *Particle Swarm Optimization* (PSO) merupakan algoritma metaheuristic yang terinspirasi dari perilaku sosial dan kecerdasan kumpulan hewan. Kawanan binatang disebut populasi dan setiap populasi terdapat partikel (individu). Algoritma PSO pertama kali diperkenalkan oleh James Kennedy dan Russell Eberhart pada tahun 1995 [18], [19]. PSO mengacu pada pergerakan partikel berdasarkan kecepatan dan posisinya [20]. Partikel akan menentukan posisi terbaik berdasarkan pengalaman historis mereka sendiri (P_{best}). Partikel juga akan mengevaluasi solusi dari partikel lain (G_{best}). Penentuan posisi terbaik dilakukan berulang-ulang (iterasi) dengan mempertimbangkan dua hal tersebut dan menyesuaikan posisi dan kecepatan masing-masing [18], [21].

1. Inisialisasi parameter PSO, seperti populasi, bobot inersia, posisi awal, kecepatan awal dan jumlah iterasi maksimum secara acak serta *learning rates*.
2. Menghitung nilai *fitness* tiap partikel.
3. Inisialisasi P_{best} yang mana nilai P_{best} pertama nilainya sama dengan posisi awal partikel.
4. Inisialisasi G_{best} berdasarkan partikel dengan nilai *fitness* terbaik (terbesar).
5. Menghitung *update* kecepatan partikel.

$$v_{i,j}^{t+1} = w \cdot v_{i,j}^t + c_1 r_1 (P_{best_{i,j}}^t - x_{i,j}^t) + c_2 r_2 (G_{best_{g,j}}^t - x_{i,j}^t) \quad (11)$$

Keterangan:

$v_{i,j}^{t+1}$: vektor *update* kecepatan partikel

w : bobot inersia

$v_{i,j}^t$: vektor nilai kecepatan iterasi ke- t

c_1, c_2 : parameter *learning rates*

r_1, r_2 : bilangan acak $\in [0,1]$



$P_{best\ ij}^t$: posisi optimal iterasi ke- t

$G_{best\ g,j}^t$: global optimal iterasi ke- t

$x_{i,j}^t$: posisi partikel iterasi ke- t

t : iterasi ke- $t = 0$

6. Menghitung *update* posisi partikel.

$$x_{i,j}^{t+1} = x_{i,j}^t + v_{i,j}^{t+1} \quad (12)$$

Keterangan:

$x_{i,j}^{t+1}$: nilai hasil *update* posisi partikel

$x_{i,j}^t$: nilai posisi partikel iterasi ke- t

$v_{i,j}^{t+1}$: vektor *update* kecepatan partikel

7. Melakukan perulangan langkah 2 hingga 6 sampai memenuhi syarat kondisi berhenti (*stopping criteria*), sebagai berikut:

- iterasi telah mencapai jumlah maksimum
- tidak terjadi perubahan yang signifikan pada nilai G_{best} .

Bobot inersia (w) ditambahkan berguna dalam mengurangi kecepatan sehingga tidak terjadi divergensi. Penerapan bobot inersia mampu mengurangi kecepatan partikel saat iterasi besar dan partikel menuju ke satu nilai yang sama (konvergen) [21], [22]. Penerapan batas bobot inersia yang baik adalah 0,9 hingga 0,4 [23].

$$w(i) = w_{max} - \left(\frac{w_{max} - w_{min}}{i_{max}} \right) \times i \quad (13)$$

Keterangan:

$w(i)$: nilai bobot inersia iterasi ke- i

i : iterasi ke- i

i_{max} : iterasi maksimum

w_{max} : nilai maksimum bobot inersia yang ditetapkan

w_{min} : nilai minimum bobot inersia yang ditetapkan

2.5. Ukuran Kesalahan Peramalan

Mean Absolute Percentage Error (MAPE) merupakan pengukuran nilai deviasi hasil peramalan dari data aktual yang berbentuk rata-rata persentase [24]. Menurut Lewis (1982), nilai MAPE kecil mengindikasikan akurasi peramalan yang tinggi.

$$MAPE = \frac{1}{N} \sum_{j=1}^N \frac{|y_j - \hat{y}_j|}{y_j} \times 100\% \quad (13)$$

Keterangan:

N : jumlah data uji

j : 1, 2, ..., N

y_j : data aktual ke- j

$\hat{y}_j$: data hasil peramalan ke- j .



III. HASIL DAN PEMBAHASAN

3.1. Analisis Deskriptif

Tabel 2. Statistika Deskriptif

Variabel	Mean	Standar Deviasi	Maksimum	Minimum
Curah Hujan	7,68	3,56	16,87	0
Kelembaban	87,16	2,65	90,58	75,53
Temperatur	26,26	0,5	27,68	25,27
Kecepatan Angin	0,71	0,14	1,02	0,51
Luas Area Terbakar	6505,71	18389,10	137446	2

Hasil analisis menunjukkan bahwa data tersebar dengan rentang luas dan memiliki fluktuasi yang tinggi. Pada saat kebakaran di Kalimantan Selatan mencapai angka maksimum, variabel iklim tercatat pada angka 26,84°C, 78,4%, 0,87 m/s, dan 1,85 mm. Hal ini bisa mengindikasikan bahwa kebakaran hutan dan lahan cenderung meluas saat temperatur tinggi, kelembaban rendah, kecepatan angin tinggi, dan curah hujan yang rendah.

3.2. Normalisasi Data

Normalisasi data merupakan langkah *pre-processing* yang bertujuan agar data berada pada rentang yang sama. Penelitian ini menerapkan *Min-Max Normalization* agar dapat dimodifikasi sesuai dengan pernyataan Siang (2005) sehingga menghasilkan rentang [0,1, 0,9]. Berikut ini adalah hasil perhitungan normalisasi seluruh data penelitian.

Tabel 3. Normalisasi Data

Curah Hujan	Kelembaban	Temperatur	Kecepatan Angin	Luas Area Kebakaran
0,41	0,81	0,18	0,49	0,10
0,49	0,69	0,28	0,24	0,10
0,56	0,73	0,44	0,15	0,10
:	:	:	:	:
0,58	0,71	0,72	0,15	0,11

3.3. Proses Training

Proses ini diawali dengan menentukan bobot *input* dan *bias*. Sebelum menjalankan program parameter PSO yang perlu ditentukan diawal, yaitu posisi dan kecepatan partikel, populasi (*swarm*) yang berisi kumpulan partikel, bobot inersia, iterasi maksimum, dan *learning rates* c_1 , c_2 . Setelah dilakukan studi pustaka terdahulu dan eksperimen (*trial and error*), parameter yang diterapkan adalah 7 *hidden neuron*, 60 jumlah populasi, 0,4 bobot inersia minimum, 0,9 bobot inersia maksimum, $c_1 = 2$, $c_2 = 1$, dan 1000 iterasi maksimum.

Pemrosesan dilakukan menggunakan data normalisasi yang telah didapatkan kemudian melatih data *training* dengan gabungan antara proses *training* ELM dan algoritma PSO. Proses berhenti saat memenuhi *stopping criteria* dan didapatkan solusi optimal dan didapatkan bobot *input* dan *bias* dari G_{best} .

$$G_{best} \text{ Bobot Input}_{Partikel Optimal} = \begin{bmatrix} 33,14 & -110,81 & -72,18 & -98,99 \\ 32,22 & -49,45 & -78,96 & -32,99 \\ \vdots & \vdots & \vdots & \vdots \\ -5,91 & -92,84 & -28,94 & -80,10 \end{bmatrix}_{7 \times 4}$$

$$G_{best} \text{ bias}_{Partikel Optimal} = [-5,269 \quad -14,481 \quad \dots \quad 91,857]_{1 \times 7}$$



3.4. Proses *Testing*

Proses *testing* dilakukan menggunakan hasil dari solusi optimal G_{best} . Nilai bobot *output* dari G_{best} akan digunakan untuk melakukan peramalan. Model parameter PSO-ELM yang diterapkan sama seperti pada proses *training*. Setelah program dijalankan, hasil ramalan yang didapat adalah sebagai berikut:

$$r = \begin{bmatrix} 0,1004 \\ 0,1004 \\ \vdots \\ 0,387 \end{bmatrix}_{24 \times 1}$$

Hasil nilai ramalan ini perlu didenormalisasi agar dapat dihitung akurasi karena nilai *error* MAPE perlu nilai prediksi aktual.


3.5. Akurasi Peramalan

Perhitungan nilai akurasi peramalan untuk melihat seberapa besar *error*-nya atau seberapa baik hasil peramalan yang didapatkan. Akurasi yang didapat sebesar 4,37% untuk data pelathian dan 2,09% untuk data pengujian sehingga peramalan ini memiliki akurasi yang tinggi karena <10%. Berikut ini merupakan hasil MAPE pengujian parameter optimal PSO-ELM yang ditunjukkan pada Tabel 3.


Tabel 4. Hasil Akurasi

<u>Pelatihan</u>	<u>Pengujian</u>
<u>4,37%</u>	<u>2,09%</u>

3.6. Perbandingan Nilai Prediksi dan Aktual Proses *Training* dan *Testing*



Gambar 4a. Perbandingan data latih



Gambar 5b. Perbandingan data uji

Berdasarkan gambar, terlihat bahwa terdapat beberapa nilai hasil ramalan yang berbeda jauh dari nilai aktual. Hal ini disebabkan karena fluktuasi data luas area terbakar sangat signifikan. Namun, hasil nilai evaluasi *error* MAPE keduanya <10% yang menunjukkan bahwa akurasi peramalan yang dihasilkan sangat baik. Dengan ini, model dapat digunakan untuk meramalkan luas area kebakaran 12 bulan ke depan.

Tabel 5. Peramalan 12 Bulan Berikutnya

<u>Bulan</u>	<u>Peramalan</u>	<u>Bulan</u>	<u>Peramalan</u>
Januari 2024	0	Juli 2024	49236,453
Februari 2024	43308,337	Agustus 2024	67,784
Maret 2024	67,7884	September 2024	67,784
April 2024	47422,082	Oktober 2024	0
Mei 2024	67,784	November 2024	44375,887
Juni 2024	67,784	Desember 2024	67,784



Hasil peramalan luas area terbakar 12 bulan ke depan ditunjukkan pada Tabel 4. Pada periode 12 bulan ini, luas area kebakaran di Kalimantan Selatan tertinggi terjadi pada bulan Juli 2024 sebesar 49236,453 ha. Diikuti dengan bulan April 2024 seluas 47422,082. Sedangkan, luas area terbakar terendah di Kalimantan Selatan terjadi pada bulan Januari dan Oktober 2024 sebesar 0 ha.

IV. KESIMPULAN

Data luas area kebakaran di Kalimantan Selatan mengalami fluktuasi yang signifikan dengan rentang sebesar 2 ha hingga 137446 ha. Nilai MAPE hasil pemrosesan data latih dan data uji partikel optimal didapatkan sebesar 4,37% dan 2,09% sehingga peramalan ini memiliki akurasi yang tinggi karena nilainya $<10\%$. Nilai tersebut didapatkan dari model PSO-ELM yang dibangun terdiri dari 4 *input* neuron, 7 *hidden* neuron, 60 jumlah populasi, $C_1 = 2$, $C_2 = 1$, bobot inersia maksimum 0,9, bobot inersia minimum 0,4, dan 1000 iterasi maksimum. Hasil peramalan luas area terbakar 12 bulan ke depan di Kalimantan Selatan tertinggi terjadi pada bulan Juli 2024 sebesar 49236,453 ha dan terendah terjadi pada bulan Januari dan Oktober 2024 sebesar 0 ha.

REFERENSI

1. B. H. Saharjo and U. Hasanah, "Analisis Faktor Penyebab Terjadinya Kebakaran Hutan dan Lahan di Kabupaten Pulang Pisau, Kalimantan Tengan," *J. Trop. Silv.*, vol. 14, no. 01, pp. 25–29, 2023, doi: 10.29244/j-siltrop.14.01.25-29.
2. Ri. K. Tohir and F. Pramata, "Pemetaan Ancaman Dan Karakteristik Kebakaran Hutan Dan Lahan (Karhutla) Provinsi Lampung," *Wahana For. J. Kehutan.*, vol. 15, no. 2, pp. 12–27, 2020, doi: 10.31849/forestra.v15i2.4705.
3. L. Syaufina and S. Fitriana, "Faktor Penyebab dan Upaya Pengendalian Kebakaran Hutan di KPH Majalengka," *J. Trop. Silv.*, vol. 12, no. 3, pp. 164–171, 2021, doi: 10.29244/j-siltrop.12.3.164-171.
4. E. I. Putra and I. L. Puspawati, "Pengaruh Kelembapan, Suhu Udara dan Curah Hujan terhadap Kejadian Kebakaran Gambut di Kabupaten Tanjung Jabung Timur, Jambi," *J. Trop. Silv.*, vol. 11, no. 3, pp. 189–193, 2020, doi: 10.29244/j-siltrop.11.3.189-193.
5. R. C. Nugroho and P. P. Oktaviana, "Analysis Of Fire Risk For Forest And Land In West Kalimantan Using Logistic Regression Method With Generalized Extreme Value Approach," *J. Mat. Stat. dan Komputasi*, vol. 20, no. 1, pp. 102–115, 2023, doi: 10.20956/j.v20i1.27474.
6. B. H. Saharjo, L. Syaufina, A. D. Nurhayati, E. I. Putra, R. D. Walid, and Wardana, *Pengendalian Kebakaran Hutan Dan Lahan di Wilayah Komunitas Terdampak Asap*, 1st ed., vol. 15, no. 2. Bogor: IPB Press, 2018.
7. H. Jazuli, "Prediksi Luas Area Terbakar Berdasarkan Curah Hujan, Temperatur Dan Kecepatan Angin Di Kabupaten Pulang Pisau Dengan Model Fungsi Transfer," Institut Teknologi Sepuluh Nopember, 2019.
8. J. J. Siang, *Jaringan Syaraf Tiruan Dan Pemrogramannya Dengan Matlab*. Yogyakarta: ANDI, 2005.
9. A. Nur Alfiyatin *et al.*, "Penerapan Extreme Learning Machine (Elm) Untuk Peramalan Laju Inflasi Di Indonesia Implementation Extreme Learning Machine for Inflation Forecasting in Indonesia," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 6, no. 2, pp. 179–186, 2018, doi: 10.25126/jtiik.20186900.
10. S. Yarat, S. Senan, and Z. Orman, *A Comparative Study on PSO with Other Metaheuristic Methods*. CA, USA: Springer International Publishing, 2021.
11. G. Arora, K. Bala, H. Emadifar, and M. Khademi, "A Comparative Study of Particle Swarm Optimization and Artificial Bee Colony Algorithm for Numerical Analysis of Fisher's Equation," *Discret. Dyn. Nat. Soc.*, vol. 2023, pp. 1–10, 2023, doi: 10.1155/2023/9964744.
12. Z. Wu, "A Comparative Study of Solving Traveling Salesman Problem with Genetic Algorithm, Ant Colony Algorithm, and Particle Swarm Optimization," *ACM Int. Conf. Proceeding Ser.*, pp. 95–99, 2020, doi: 10.1145/3450292.3450308.
13. A. P. Ariyanti, M. I. Mazdadi, A.- Farmadi, M. Muliadi, and R. Herteno, "Application of Extreme Learning Machine Method With Particle Swarm Optimization to Classify of Heart Disease," *IJCCS (Indonesian J. Comput. Cybern. Syst.)*, vol. 17, no. 3, p. 281, 2023, doi: 10.22146/ijccs.86291.
14. J. Heizer, B. Render, and C. Munson, *Operations Management: Sustainability and Supply Chain Management*, 12th ed. United States of America: Pearson Education Inc, 2017.
15. F. H. Hamdanah and D. Fitriana, "Analisis Performansi Algoritma Linear Regression dengan Generalized Linear Model untuk Prediksi Penjualan pada Usaha Mikro, Kecil, dan Menengah," *J. Nas. Pendidik. Tek. Inform.*, vol. 10, no. 1, p. 23, 2021, doi: 10.23887/janapati.v10i1.31035.
16. R. Fatwa, I. Cholissodin, and Y. A. Sari, "Penerapan Metode Extreme Learning Machine Untuk Prediksi



- Konsumsi Penerapan Metode Extreme Learning Machine Untuk Prediksi Konsumsi Batubara Sektor Pembangkit Listrik Tenaga Uap,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput. Univ. Brawijaya*, vol. 3, no. 11, pp. 10749–10755, 2019.
17. M. Warohma, E. Budianita, F. Syafria, and I. Afrianty, “Prediksi Jumlah Perceraian Menggunakan Metode Extreme Learning Machine (ELM),” *J. Inf. Syst. Res.*, vol. 4, no. 4, pp. 1448–1454, 2023, doi: 10.47065/josh.v4i4.3581.
 18. I. Robandi, *Artificial Intelligence: Mengupas Rekayasa Kecerdasan Tiruan*, 1st ed. Yogyakarta: ANDI, 2019.
 19. M. Sevkli and A. R. Guner, “Optimization Algorithm for Uncapacitated Facility Location Problem,” in *Ant Colony Optimization and Swarm Intelligence*, 2006, pp. 316–317, doi: https://doi.org/10.1007/11839088_28.
 20. Umi Lailatul Muyassaroh, “Algoritma Particle Swarm Optimization dengan Local Search (PSO-LS) Sebagai Metode Penyelesaian Uncapacitated Facility Location Problem (UFLP),” Universitas Airlangga, 2012.
 21. R. Ilmiyah, D. Rachmatin, and R. Marwati, “Peramalan Inflasi Dengan Metode Particle Swarm Optimization – Extreme Learning Machine,” *Interval J. Ilm. Mat.*, vol. 2, no. 1, pp. 42–51, 2022, doi: 10.33751/interval.v2i1.5181.
 22. Fajar Farisuddin, “Optimasi Parameter Support Vector Machine dengan Particle Swarm Optimization untuk Klasifikasi Tingkat Resiko Stroke,” Universitas Brawijaya, 2020.
 23. Y. Shi and R. Eberhart, “A Modified Particle Swarm Optimizer,” *IEEE Int. Conf. Evol. Comput. Proc.*, pp. 69–73, 1998, doi: 10.1109/ICEC.1998.699146.
 24. Z. Ngabidin, A. Sanwidi, and E. R. Arini, “Implementasi Metode Double Exponential Smoothing Brown Untuk Meramalkan Jumlah Penduduk Miskin,” *Euler J. Ilm. Mat. Sains dan Teknol.*, vol. 11, no. 2, pp. 328–338, 2023, doi: 10.37905/euler.v11i2.23054.