

Prediksi Kebakaran Hutan Berdasarkan Faktor Iklim Untuk Sumatra Menggunakan FLNN-PSO

1st Dian Aries Alfatah
Fakultas Informatika
Universitas Telkom
Bandung, Indonesia

diesalfatah@student.telkomuniversity.ac.id

2nd Irma Palupi
Fakultas Informatika
Universitas Telkom
Bandung, Indonesia

irmapalupi@telkomuniversity.ac.id

Abstrak—Indonesia telah mengalami peningkatan yang mengkhawatirkan dalam kebakaran hutan sejak tahun 1980. Pada tahun 2019, luas kebakaran hutan di Sumatra meningkat secara signifikan, menghasilkan jumlah karbon yang substansial dan berkontribusi secara signifikan terhadap total emisi karbon negara. Faktor cuaca seperti kecepatan angin, suhu, dan curah hujan dapat mempengaruhi kebakaran hutan. Pada penelitian ini dikembangkan model prediksi menggunakan *Functional Link Neural Network* (FLNN), dengan *Particle Swarm Optimization* (PSO) untuk optimisasi pada pencocokan model FLNN. Dataset yang digunakan adalah emisi karbon dari GFED dan faktor iklim dari ERA5 dari tahun 1998 sampai 2022, dimana empat tahun terakhir akan digunakan sebagai data uji. Tiga skenario pengujian dilakukan pada penelitian ini untuk melihat faktor yang dominan dalam model prediksi, disertai dengan analisis *feature importance*. Diperoleh dari tiga skenario pengujian, bahwa keterlibatan indeks waktu dan lokasi tidak berpengaruh untuk memberikan galat kecil pada model prediksi FLNN-PSO. Sehingga faktor cuaca saja yang dominan pengaruhnya terhadap hasil prediksi yang akurat dengan model FLNN-PSO. Nilai MAE terendah untuk total emisi carbon di wilayah Sumatera yang diperoleh adalah 254,28 gC/m²/bulan.

Kata kunci—kebakaran hutan, prediksi, sumatra, emisi karbon, *functional link neural network* (flnn), *particle swarm optimization* (psa)

Abstract—Indonesia has experienced a concerning increase in forest fires since 1980. In 2019, the extent of forest fires in Sumatra significantly increased, resulting in a substantial amount of carbon emissions and contributing significantly to the country's total carbon emissions. Climate factors such as wind speed, temperature, and rainfall can influence forest fires. In this study, a prediction model was developed using the *Functional Link Neural Network* (FLNN), with *Particle Swarm Optimization* (PSO) for model fitting optimization. The dataset used includes carbon emissions from GFED and climate factors from ERA5 from 1998 to 2022, with the last four years used as test data. Three testing scenarios were conducted in this study to identify the dominant factors in the prediction model, accompanied by *feature importance* analysis. From the three testing scenarios, it was found that the involvement of time and

location indices did not significantly contribute to reducing the error in the FLNN-PSO prediction model. Therefore, climate factors alone dominantly influenced accurate predictions with the FLNN-PSO model. The lowest Mean Absolute Error (MAE) for total carbon emissions in the Sumatra region obtained was 254.28 gC/m²/month.

Keywords—forest fire, prediction, sumatra, carbon emission, *functional link neural network* (flnn), *particle swarm optimization* (psa)

I. PENDAHULUAN

Kebakaran hutan sering terjadi di Indonesia terutama pada musim kemarau. Di Indonesia sendiri kebakaran hutan sudah mengalami peningkatan luas dan intensitas sejak tahun 1980, terutama di Sumatra[1]. Berdasarkan Kementerian Lingkungan Hidup dan Perhutanan, pada tahun 2019 Sumatra memiliki angka tertinggi kedua untuk luas kebakaran hutan dan lahan yaitu, 479.250,593 ha[2]. Polusi yang disebabkan oleh kebakaran hutan sangat berbahaya dikarenakan emisi polutan yang dihasilkan sangat besar[3]. Salah satu polutan yang dihasilkan adalah karbon, yang dimana emisi karbon akan dilepaskan ke atmosfer dan menyebabkan kenaikan suhu global[4]. Mengutip kembali pada [2], pada tahun 2019 emisi karbon di pulau Sumatra mencapai 270.629.716 ton, menyumbang 43.3% dari total emisi karbon di Indonesia. Banyak faktor penyebab kebakaran hutan, salah satunya adalah faktor iklim seperti kecepatan angin, curah hujan, temperatur, tingkat kelembapan dan sebagainya[5].

Dengan dibuatnya model prediksi kebakaran hutan memudahkan pencegahan dan membantu meminimalkan resiko dari kebakaran hutan. Sudah banyak yang metode yang digunakan untuk mengimplementasi hal tersebut, salah satunya seperti yang dilakukan oleh Storer et al pada tahun 2016[6], penelitian tersebut menggunakan PSO untuk melatih ANN dalam memprediksi kebakaran hutan. Penelitian tersebut juga membandingkan penggunaan PSO dengan *backpropagation* menunjukkan bahwa penggunaan PSO-ANN lebih unggul dibandingkan *backpropagation* dalam tingkat kesalahan yang

diukur menggunakan MAE masing – masing bernilai 17.98 dan 24.68. Pada penelitian [7], Shabrina et al menggunakan dua model yaitu, *Random Forest* dan ANN untuk meneliti pengaruh dari variabel iklim pada kebakaran hutan di Sumatra dari tahun 1998 sampai 2018. Dimana pada penelitian tersebut, RF menghasilkan model yang lebih akurat dibandingkan ANN pada tahun 2019 sedangkan ANN lebih baik pada tahun 2020-2021. RF dan ANN masing - masing memiliki nilai *mean R²* -3.66 dan -0.35 dengan standard deviasi 15.82 dan 222.

Functional Link Neural Network (FLNN) merupakan jaringan saraf buatan yang berorde tinggi atau *Higher Order Neural Networks* (HONN). FLNN menggunakan neuron functional link atau fungsi ekspansional untuk memodelkan hubungan non-linear antara variabel masukan dan keluaran[8]. Pada penelitian [8], FLNN digunakan untuk dibandingkan hasil prediksinya dengan model HONN hibrida buatan dengan data *exchange rate* mata uang dunia. FLNN menghasilkan nilai evaluasi MAPE yang terbaik yaitu, rata – rata 0.0130222 diantara 7 model lainnya ketika menggunakan PSO sebagai metode *learning*.

Pada penelitian ini dikembangkan model FLNN-PSO yang digunakan untuk melakukan prediksi terhadap emisi karbon kebakaran hutan. PSO digunakan sebagai algoritma pembelajaran untuk mendapatkan nilai optimal bobot pada FLNN. Data yang digunakan adalah rentang data bulanan emisi karbon GFED dan faktor iklim ERA5 tahun 1998 – 2022 pada pulau Sumatra. Selain itu, penelitian ini juga bertujuan untuk menilai secara empiris faktor apa saja yang berpengaruh terhadap model prediksi dengan mengimplementasikan model FLNN-PSO. Model juga dianalisis dan dievaluasi untuk melihat perbandingan hasil dengan ANN pada penelitian sebelumnya.

II. METODOLOGI

A. Global Fire Emission Database (GFED)

Global Fire Emission Database adalah kumpulan data penting yang mencakup informasi tentang emisi kebakaran dan area terbakar di seluruh dunia. GFED berperan penting dalam memahami dampak kebakaran hutan terhadap siklus karbon, komposisi atmosfer, dan perubahan iklim. Dalam penelitian ini, GFED digunakan sebagai sumber data utama untuk memperkirakan emisi karbon bulanan yang dihasilkan dari kebakaran hutan di Sumatra dari tahun 1998 - 2022. Resolusi tinggi pada dataset ini memungkinkan penilaian yang akurat terkait emisi karbon. Emisi karbon merupakan ukuran kuantitatif yang dapat diukur untuk menggambarkan besarnya kebakaran karbon dalam suatu wilayah. Emisi karbon mengindikasikan jumlah karbon yang dilepaskan akibat kebakaran hutan, seperti yang terjadi di Sumatra, Indonesia, dalam penelitian ini. Sebagai representasi variabel terukur, pada penelitian ini emisi karbon merepresentasikan dampak kebakaran

secara kuantitatif terhadap lingkungan dan perubahan iklim.

B. European Reanalysis 5 (ERA5)

European Reanalysis 5 (ERA5) merupakan kumpulan data reanalisis iklim global yang dikeluarkan oleh *European for Medium-Range Weather Forecasts* (ECMWF). Faktor – faktor iklim yang digunakan dari ERA5 adalah:

1. *Wind Speed*: Data kecepatan angin untuk memahami bagaimana kecepatan angin berkontribusi terhadap penyebaran kebakaran hutan
2. *2m Dewpoint Temperature*: Temperatur titik embun pada ketinggian 2 meter di atas permukaan tanah yang digunakan untuk mengevaluasi kondisi kelembapan udara.
3. *2m Temperature* : Data suhu pada ketinggian 2 meter di atas permukaan tanah untuk memanahi hubungan suhu dengan kejadian kebakaran hutan.
4. *Total Precipitation*: Data curah hujan total digunakan untuk mengevaluasi hubungan antara curah hujan dan tingkat kebakaran hutan, serta bagaimana faktor ini dapat mempengaruhi resiko kebakaran.
5. *Temperature Maximum*: Nilai suhu maksimum digunakan untuk memperoleh pemahaman tentang suhu ekstrem yang dapat berdampak pada tingkat kebakaran.
6. *Relative Humidity*: Kelembapan relatif merupakan data yang memberikan tingkat kelembapan di atmosfer.

Data – data tersebut diambil dengan rentang waktu bulanan dari tahun 1998 – 2022.

C. Functional Link Neural Network (FLNN)

FLNN merupakan sebuah jaringan syaraf tiruan dengan aturan pelatihan yang sederhana tanpa memerlukan *hidden layer*. Salah satu fitur penting dari FLNN adalah ekspansi fungsional yang meningkatkan dimensi vektor masukan dan menciptakan ruang yang lebih besar untuk memahami pola masukan dengan lebih baik. Meskipun demikian, FLNN juga memiliki kelemahan potensial, seperti kemungkinan terjebak pada lokal optimum dan minimum [9]. Struktur FLNN terdiri dari dua bagian utama, yaitu bagian ekspansi fungsional dan bagian pelatihan. Fungsi ekspansi fungsional(*Functional Expansion/FE*) yang digunakan dalam FLNN dapat berupa himpunan polinomial, seperti *Power series polynomial*, *Legendre Polynomial*, dan *Chebyshev Polynomials*[10]. Pada penelitian ini, ekspansi fungsional yang digunakan adalah *Legendre Polynomial* dengan persamaan,

$$FE_{m+1} = \frac{1}{m+1} [(2m+1)FE_m - iFE_{m-1}(x)] \quad (1)$$

Dimana FE_i adalah *Legendre Polynomial* dengan m adalah orde dan x adalah data input. Kemudian dihitung jumlah dari nilai ekspansi fungsional dengan persamaan,

$$S_k = \sum_{k=1}^n w_k FE_k(x) \quad (2)$$

Dimana S_k adalah nilai dari penjumlahan dari *Legendre Polynomial* dan w_k adalah nilai bobot dengan n adalah jumlah data. Jumlah dari nilai ekspansi fungsional kemudian diaktifkan dengan fungsi aktivasi *sigmoid* yang kemudian dievaluasi nilai galatnya menggunakan metrik evaluasi yang sudah ditentukan.

D. Particle Swarm Optimization

Particle Swarm Optimization (PSO) adalah sebuah teknik optimisasi berdasarkan populasi. Teknik optimisasi ini dibuat berdasarkan pergerakan kelompok burung dan ikan serta teori kelompok secara umum pada tahun 1995 oleh Kennedy et al [11]. Awalnya PSO menginisiasi partikel secara acak yang kemudian mencari nilai optimal dengan cara memperbarui generasi partikel. PSO memiliki 2 nilai partikel terbaik yang akan muncul pada setiap iterasi, yang mana nilai pertama adalah nilai *fitness* terbaik dari partikel tertentu (P_{best}) dan nilai kedua adalah nilai *fitness* terbaik dari semua partikel (G_{best}). Partikel kemudian memperbarui *velocity* dan *position* setelah kedua nilai terbaik ditemukan dengan persamaan,

$$V_i = Q + R, \quad (3)$$

$$Q = \omega V_i + c1 \cdot r1 \cdot (Pos_{pbest,i} - Pos_{current,i}) \quad (4)$$

$$R = c2 \cdot r2 \cdot (Pos_{gbest,i} - Pos_{current,i}) \quad (5)$$

Keterangan:

Q: komponen kognitif

R: komponen sosial

w: nilai bobot inersia

c1: nilai koefisien kognitif

c2: nilai koefisien sosial

r1 & r2: nilai acak

PSO dalam penelitian ini digunakan untuk memodelkan dataset yang diberikan terhadap model FLNN melalui nilai rata-rata galat, dimana ukuran galat yang digunakan adalah MSE dengan persamaan,

$$mse = \frac{1}{n} \sum_{i=1}^N [y_{aktual}(i) - FLNN(X(i))]^2 \quad (6)$$

Adapun algoritma untuk PSO yang digunakan adalah sebagai berikut,

Algoritma 1: Particle Swarm Optimization

Input: c1, c2, w, populasi, max_iterasi, x_train, y_train

Output: weights for FLNN model


initialize particles:

```
for i in range(populasi)
    particles[i] = np.random.rand(x_train.shape[1] * m)
initialize best positions and velocities of the particles:
    best_positions = particles.copy()
    best_fitnesses = np.inf * np.ones(n_particles)
    global_best_position = particles[0]
    global_best_fitness = np.inf
```

iterate for max_iterasi:

```
for i in range(max_iterasi):
    fitnesses = objective(particles, x_train, y_train, m)
    #update best position and velocity of the particles
    for j in range(populasi)
        if fitnesses[j] < best_fitnesses[j]:
            best_positions[j] = particles[j].copy()
            best_fitnesses[j] = fitnesses[j]
        if best_fitnesses[j] < global_best_fitness:
            global_best_position = particles[j].copy()
            global_best_fitness = best_fitnesses[j]
    #update the position and velocities of the particles
    for j in range(populasi)
        velocity = c1 * random.random() * (best_positions[j] - particles[j]) + c2 * random.random() * (global_best_position - particles[j])
        particles[j] += velocity
        if global_best_fitness == np.min(best_fitnesses)
            break
    #return best weights for flnn
    return particles[np.argmin(best_fitnesses)]
```

III. SISTEM YANG DIBANGUN




GAMBAR 1. FLOWCHART SISTEM YANG DIBANGUN

Gambar 1 menunjukkan sistem yang dibangun dibagi dalam beberapa tahapan proses, yang dimana proses pertama adalah pengambilan data emisi karbon dari GFED dan faktor iklim dari ERA5, kemudian praproses data dimana data ERA5 difilter untuk memisahkan data selain daratan, setelah itu data tersebut diinterpolasi dengan data emisi karbon GFED. Data kemudian dipisah menjadi data *train* dan data *test*. *Batching* data juga dilakukan untuk mengelompokkan data yang digunakan berdasarkan lokasi dengan rentang waktu 12 bulan per-lokasinya. Parameter dituning untuk mendapatkan parameter yang sudah ditentukan dengan hasil yang baik, kemudian dilakukan *training* dengan model FLNN-PSO. Setelah *training* dilakukan, prediksi dilakukan dengan data *test* dan dievaluasi hingga didapatkan hasil yang baik, jika tidak maka proses akan diulang dari *parameter tuning*.

E. Dataset

Dataset yang digunakan pada penelitian ini adalah data emisi karbon dari GFED dan faktor iklim dari ERA5. Faktor iklim yang digunakan adalah *Wind Speed*, *2m Dewpoint*, *2m Temperature*, *Total Precipitation*, *Temperature Maximum*, dan *Relative Humidity*. Rentang waktu kedua dataset yang digunakan adalah data bulanan dari tahun 1998 – 2022 yang berlokasi di pulau Sumatra dengan koordinat North 5.87°, West 94.87°, South -5.87°, East 106.87°.



GAMBAR 2
BOXPLOT FITUR – FITUR YANG DIGUNAKAN

F. Praproses

Dilakukannya praproses pada data dikarenakan data GFED dan ERA5 memiliki grid lokasi yang berbeda, adapun data juga diurutkan berdasarkan lokasinya yang dimana setiap lokasi memiliki data berjumlah 300 data dengan total lokasi berjumlah 535 lokasi.

1. Interpolasi Data

Interpolasi antara data GFED dan ERA5 dilakukan untuk menyeragamkan grid koordinat lokasi kedua data. Interpolasi dilakukan dengan menggunakan *2D Cubic Spline Interpolation* dengan GFED sebagai acuan grid koordinat.

2. Filtering Data

Filtering data dilakukan untuk memilah data yang terdapat di luar pulau Sumatra, yaitu data yang ada di luar daratan dan data yang terdapat pada pulau lain. Filtering dilakukan dengan cara membandingkan data ERA5 yang digunakan dengan data ERA5 yang hanya bertipe *Land Only* dengan titik koordinat yang sama untuk memilah data yang berada di daratan saja. Kemudian memfilter data yang berada di pulau selain Sumatra dengan menghapus grid data yang mewakili koordinat pulau selain Sumatra.

3. Normalisasi Data

Normalisasi data dibutuhkan untuk mengubah rentang nilai data menjadi seragam. Dimana dataset GFED dan ERA5 memiliki nilai data yang jauh berbeda. Ila data emisi memiliki nilai maksimum yang sangat tinggi mencapai 14163, sedangkan data faktor iklim memiliki nilai yang lebih rendah. Normalisasi data dilakukan dengan menggunakan *MinMaxScaler* untuk mentransformasi fitur yang digunakan ke rentang antara 0 dan 1 dengan persamaan,

$$x_{scaled}(i) = \frac{x(i) - x_{min}}{x_{max} - x_{min} + \epsilon}, \text{ dimana } \epsilon \in (0,1) \subset \mathbb{R} \quad (7)$$

4. Split Data

Pemisahan data uji dan data latih dilakukan berdasarkan rentang waktu. Tabel 1 menunjukkan rentang waktu untuk data latih dimulai dari tahun 1998 hingga 2018 sedangkan rentang waktu untuk data uji dimulai dari tahun 2019 hingga 2022.

TABEL 1
SPLITTING DATA

	Data Latih	Data Uji
Rentang waktu	1998-01-01 hingga 2018-12-01	2019-01-01 hingga 2022-12-01

5. Batching Data

Batching dilakukan untuk membagi kumpulan data besar menjadi data kelompok yang lebih kecil disebut *batch*. Setiap set dari batch terdiri dari sejumlah data yang diproses bersamaan. *Batching* yang dilakukan pada penelitian ini, digunakan sebagai inputan pada model FLNN-PSO. *Batching* yang dilakukan adalah membagi data menjadi sebuah kelompok data berdasarkan lokasi dengan rentang waktu 12 bulan.




GAMBAR 3
ILUSTRASI BATCHING DATA

Gambar 3 menunjukkan, zona berwarna biru menyatakan data yang akan digunakan sebagai input dengan target data pada bagian berwarna oranye. Zona berwarna biru pada batch pertama dimulai pada bulan Januari 1998 hingga Desember 1998 dengan target data yang dituju adalah Januari 1999.

G. FLNN-PSO

Struktur dari model FLNN-PSO yang digunakan pada penelitian ini dapat dilihat pada Gambar 4. Dimana inputan diekspansi menggunakan ekspansi fungsional *Legendre Polynomial* menggunakan persamaan (1) dengan orde yang ditentukan melalui *parameter tuning*. Setelah itu, setiap neuron mendapatkan bobotnya masing - masing yang kemudian hasilnya dijumlahkan menggunakan persamaan (2) dan dihitung menggunakan fungsi aktivasi *sigmoid*. Kemudian hasil akan dievaluasi menggunakan metrik evaluasi yang telah ditentukan. PSO berperan sebagai algoritma pembelajaran untuk mengoptimalkan bobot neuron pada FLNN dengan ukuran populasi sebanyak 100. PSO akan melakukan iterasi dengan kondisi maksimal iterasi 10 kali dan nilai partikel yang terbaik akan dijadikan sebagai bobot untuk setiap neuron pada FLNN. Adapun

fungsi objektif yang diminimumkan dengan PSO adalah MSE.



GAMBAR 4
FLNN-PSO

Algoritma sederhana untuk FLNN-PSO.

Algoritma 2: FLNN-PSO

Input : x_{train} , y_{train} , x_{test} , orde, $c1$, $c2$

Output : best error, prediksi

initialize FLNN:

initialize w = random

initialize m = orde

initialize FE = FE function

initialize PSO:

as in **Algoritma 1**

PSO iteration:

as in **Algoritma 1**

optimize FLNN weights:

for each particle

obtain weights from particle

create FLNN model with obtained

weights

train FLNN model and calculate error

result

best particles as the optimal solution

best weights from best optimal solution

create FLNN model

prediction:

utilize optimized FLNN model to predict

based on input data

return:

best error based on input data

predictions

H. Metrik Evaluasi

Metrik evaluasi yang digunakan untuk mengukur performa model prediksi, yaitu *Mean Absolute Error*(MAE) dan *Root Mean Square Error*(RMSE). Motivasi penggunaan ketiga metrik tersebut adalah :

- MAE digunakan untuk melihat rata – rata jarak hasil prediksi dengan data aktual.
- RMSE digunakan untuk melihat korespondensi rata – rata antara prediksi dan aktual

I. Parameter Tuning

Parameter tuning dilakukan dengan menggunakan *Grid Search* untuk mencari nilai parameter terbaik pada PSO dan Orde untuk fungsi

ekspansi FLNN. Digunakan data pada tahun 2007 dan 2015 untuk melakukan *parameter tuning*. Pengaturan nilai untuk parameter tuning yaitu,

1. C1

C1 adalah faktor kognitif yang mengontrol besar pengaruh terhadap perubahan posisi partikel berdasarkan pengalaman partikel itu sendiri. Adapun nilai parameter C1 yang digunakan pada tuning adalah sebagai berikut : [2, 4, 6]

2. C2

C2 adalah faktor sosial yang mengontrol seberapa besar pengaruh terhadap perubahan posisi partikel berdasarkan pengalaman terbaik partikel sekitarnya dalam populasi. Adapun nilai parameter C2 yang digunakan pada tuning adalah sebagai berikut : [2, 4, 6]

3. Orde

Orde adalah tingkat perluasan yang akan dilakukan pada fungsi ekspansi FLNN. Adapun nilai parameter orde yang digunakan pada tuning adalah sebagai berikut : [2, 4]

J. Skenario Pengujian

Terdapat 3 skenario pengujian yang akan dilakukan pada penelitian ini dengan ketiganya terlebih dahulu dilakukan tuning pada hyperparameter. Tabel 2 memperlihatkan fitur yang digunakan pada setiap skenario, disertai dengan nilai parameter terbaik hasil tuning pada proses komputasinya. Skenario 1 hanya melibatkan faktor iklim saja untuk dijadikan fitur, skenario 2 melibatkan informasi waktu, dan pada skenario 3 tidak hanya informasi waktu, namun juga lokasi dijadikan fitur untuk melatih model.

TABEL 2
SKENARIO PENGUJIAN UNTUK FITUR YANG TERLIBAT DALAM MODEL.

Skenario	Fitur yang digunakan	Nilai Parameter
1	Wind Speed, 2m Dew	orde legendre = 4
	Temperature, 2m	w pso = 0.5
	Temperature, Total	c1 pso = 6
	precipitation, Temperature Max, dan Relative Humidity.	c2 pso = 2 population size = 100 max iterasi = 10
2	Wind Speed, 2m Dew	orde legendre = 4
	Temperature, 2m	w pso = 0.5
	Temperature, Total	c1 pso = 6
	precipitation, Temperature Max, Relative Humidity, Month, dan Year	c2 pso = 4 population size = 100 max iterasi = 10
3	Wind Speed, 2m Dew	orde legendre = 4
	Temperature, 2m	w pso = 0.5
	Temperature, Total	c1 pso = 6
	precipitation, Temperature Max, Relative Humidity, Month, Year, Latitude dan	c2 pso = 6 population size = 100 max iterasi = 10

Longitude (Tanpa
Batching)

IV. EVALUASI HASIL

A. Parameter Tuning

Hasil parameter tuning untuk setiap skenario ditunjukkan pada Tabel 3, Tabel 4, dan Tabel 5. Dimana pada ketiga tabel tersebut dapat dikatakan bahwa hasil galat lebih kecil pada parameter orde 4. Adapun pada skenario 1 ketika parameter C2 adalah 2, menghasilkan galat yang lebih kecil dibandingkan 4 dan 6. Untuk skenario 2, tingkat galat untuk setiap parameter pada orde 4 tidak menunjukkan perbedaan yang signifikan, tetapi pada orde 2 tingkat galat lebih kecil ketika C2 adalah 6. Pada skenario 3, tingkat galat yang dihasilkan untuk orde 4 ketika C1 adalah 6 menunjukkan hasil yang lebih kecil. Total waktu yang dihasilkan cenderung lebih lama ketika orde lebih tinggi, hal ini dikarenakan fitur ekspansi pada FLNN yang dimana ketika orde lebih tinggi menyebabkan fitur inputan yang diekspansi semakin banyak.

TABEL 3
HASIL TUNING SKENARIO 1

C1	C2	W	Galat	
			Orde 2	Orde 4
2	2	0.5	0.056104	0.000415
2	4	0.5	0.312972	0.003828
2	6	0.5	0.535022	0.001901
4	2	0.5	0.056104	0.000416
4	4	0.5	0.312972	0.003132
4	6	0.5	0.535022	0.001901
6	2	0.5	0.056104	0.000379
6	4	0.5	0.312972	0.002906
6	6	0.5	0.521882	0.001901
Total Time			59 Menit	3 Jam

TABEL 4
HASIL TUNING SKENARIO 2

C1	C2	W	Galat	
			Orde 2	Orde 4
2	2	0.5	0.616017	0.000368
2	4	0.5	0.628460	0.000368
2	6	0.5	0.402440	0.000368
4	2	0.5	0.665705	0.000368
4	4	0.5	0.577028	0.000368
4	6	0.5	0.402440	0.000368
6	2	0.5	0.623726	0.000368
6	4	0.5	0.625219	0.000368
6	6	0.5	0.402440	0.000368
Total Time			34 Menit	2.3 Jam

TABEL 5
HASIL TUNING SKENARIO 3

C1	C2	W	Galat	
			Orde 2	Orde 4
2	2	0.5	0.085089	0.998244
2	4	0.5	0.096652	0.998244
2	6	0.5	0.104348	0.998244
4	2	0.5	0.082604	0.014922
4	4	0.5	0.082314	0.013116
4	6	0.5	0.082314	0.030907
6	2	0.5	0.082314	0.021408
6	4	0.5	0.144993	0.008995
6	6	0.5	0.082322	0.006093
Total Time			4 Menit	10 Menit

B. Training Model

Model dilatih dengan data latih menggunakan parameter terbaik untuk setiap skenario sekaligus untuk mengoptimisasi bobot pada FLNN dengan hasil seperti yang dapat dilihat pada Tabel 6. Dimana pada skenario 1 dan 2, waktu latih cukup lama dikarenakan terdapatnya proses *batching data*. Berbeda dengan skenario 3 yang cenderung lebih cepat dikarenakan tanpa *batching data*. Error sendiri adalah nilai galat terkecil yang dihasilkan menggunakan bobot FLNN yang dioptimisasi menggunakan PSO.

TABEL 6
HASIL TRAINING MODEL

Skenario	Galat	Total Runtime
1	0.003	5.6 Jam
2	0.009	4.5 Jam
3	0.009	5 Menit

C. Metrik Evaluasi Skenario


Tabel 7 menunjukkan hasil evaluasi dari penelitian yang dilakukan berdasarkan skenario yang dijalankan, dapat dilihat bahwa berdasarkan hasil tersebut didapatkan bahwa skenario 1 mendapatkan hasil evaluasi terbaik dengan nilai MAE sebesar 254.280 gC/m²/bulan dan skenario 2 menjadi skenario dengan hasil terburuk dengan nilai MAE sebesar 7408.724 gC/m²/bulan.

TABEL 7
HASIL METRIK EVALUASI TIAP SKENARIO

Skenario	MAE(gC/m ² /bulan)	RMSE(gC/m ² /bulan)
1	254.280	1299.735
2	7408.724	9834.442
3	5508.878	6116.677


D. Total Emisi Karbon

Gambar 5, 6 dan 7 menunjukkan total emisi karbon aktual mengalami peningkatan yang signifikan pada bulan September 2019. Skenario 1 mendapatkan hasil prediksi yang paling mendekati pada bulan tersebut sedangkan pada skenario 2 dan 3 hasil prediksi sangat tinggi dibandingkan emisi actual.




GAMBAR 5
PERBANDINGAN TOTAL EMISI KARBON SKENARIO 1 & AKTUAL

Gambar 5 menunjukkan skenario 1 mengalami penurunan total emisi karbon yang cukup signifikan dari tahun 2020 hingga 2021. Tetapi mengalami kenaikan yang melonjak tinggi pada bulan 12 tahun 2022.



GAMBAR 6
PERBANDINGAN TOTAL EMISI KARBON SKENARIO 2 & AKTUAL




GAMBAR 7
PERBANDINGAN TOTAL EMISI KARBON SKENARIO 3 & AKTUAL

. Pada gambar 6 dan 7, skenario 2 dan 3 terus menunjukkan total emisi karbon yang cukup tinggi

terutama skenario 3 pada tahun 2021 dan 2022 dengan total emisi karbon yang stagnan.


E. Absolute Error

Pada Gambar 8 menunjukkan bahwa nilai *absolute error* untuk skenario 1 lebih rendah dibandingkan dengan skenario 2 dan skenario 3. Hal ini menunjukkan bahwa akurasi skenario 1 lebih tinggi dibandingkan skenario lainnya.



GAMBAR 8

GRAFIK ABSOLUTE ERROR SKENARIO 1(KUNING), 2(HIJAU) DAN 3(MERAH)



GAMBAR 9

PERBANDINGAN ABSOLUTE ERROR ANN DENGAN FLNN-PSO (SKENARIO 1) TAHUN 2019-2021

Pada Gambar 9 menunjukkan perbandingan antara nilai *absolute error* hasil prediksi untuk model ANN dari penelitian [7] dengan hasil yang didapatkan dari skenario 1 FLNN-PSO pada penelitian ini. ANN memiliki nilai yang lebih rendah dibandingkan dengan FLNN-PSO secara keseluruhan. Tetapi, pada bulan April hingga Oktober 2021 FLNN-PSO memiliki nilai *absolute error* yang lebih rendah dibandingkan dengan ANN.


F. MAE Bulanan

Gambar 10 menunjukkan nilai MAE yang tingkat *error* rata – rata bulanan dari tahun 2019 hingga 2022 untuk setiap skenario pengujian dimana nilai yang rendah berarti lebih baik. Skenario pengujian 1 mengalami penurunan seiring waktu, sedangkan skenario 2 dan 3 tetap relative tinggi. Hal ini menunjukkan bahwa akurasi prediksi skenario 1 terlihat lebih meningkat dari waktu ke waktu.



GAMBAR 10

GRAFIK MAE SKENARIO 1, 2 & 3 BULANAN



GAMBAR 11


PERBANDINGAN MAE ANN DENGAN FLNN-PSO (SKENARIO 1) TAHUN 2019-2021

Gambar 11 menunjukkan perbandingan rata – rata tingkat *error* untuk ANN dengan FLNN untuk bulan Juli hingga Desember 2019 hingga 2021.


G. Plot Map

Gambar 12 dan 13 menunjukkan peta plot titik emisi karbon yang dihasilkan dari model prediksi FLNN-PSO skenario dan data aktual. Tahun 2019, data prediksi menghasilkan titik lokasi yang mendekati data aktual, tetapi pada tahun 2020 dimana data aktual memiliki jumlah emisi karbon yang cukup kecil sehingga tidak menampilkan banyak titik lokasi sedangkan pada data prediksi tetap menampilkan titik lokasi yang cukup tinggi. Untuk tahun 2021, data

prediksi mengalami penurunan terhadap titik lokasi yang mendekati data aktual, tetapi mengalami peningkatan yang tidak signifikan pada tahun 2022.




GAMBAR 12
PLOT PREDIKSI KEBAKARAN HUTAN SKENARIO JULI – OKTOBER(2019 – 2022)




GAMBAR 13
PLOT AKTUAL KEBAKARAN HUTAN JULI – OKTOBER(2019 – 2022)

H. Feature Importance


Feature Importance untuk skenario 1, 2 dan 3 pada Gambar 14, Gambar 15, dan Gambar 16 menunjukkan setiap skenario memiliki fitur tersendiri yang memiliki tingkat kepentingan tertinggi. Dimana untuk skenario 1 dan skenario 2 memiliki *2m Dew Temp* sebagai fitur dengan tingkat kepentingan tertinggi, dan skenario 3 memiliki *Year* dengan tingkat kepentingan fitur tertinggi.



GAMBAR 14
FEATURE IMPORTANCE SKENARIO 1



GAMBAR 15
FEATURE IMPORTANCE SKENARIO 2



GAMBAR 16
FEATURE IMPORTANCE SKENARIO 3

V. KESIMPULAN

Berdasarkan dari hasil pengujian dan evaluasi yang telah dilakukan pada penelitian ini, didapatkan hasil penggunaan model FLNN-PSO pada skenario 1 menjadi model dengan hasil terbaik dengan nilai MAE sebesar 254.280 gC/m²/bulan, lebih rendah dibandingkan dengan skenario lainnya. Pada Gambar 5 juga dapat dilihat bahwa total emisi karbon prediksi untuk skenario 1 sangat dekat dengan total emisi karbon aktual disertai juga pada Gambar 8 dan 10 selisih perbedaan antar total data aktual dengan prediksi. *Feature importance* juga dapat menjelaskan tingkat pengaruh suatu fitur terhadap FLNN-PSO, dimana pada skenario 1 dan skenario 2 *2m dew temperature* menjadi fitur yang paling berpengaruh terhadap prediksi emisi karbon disusul dengan fitur *2m temperature* sedangkan untuk skenario 3 didapatkan bahwa fitur *year* menjadi fitur yang paling

berpengaruh disusul dengan *2m temperature*. Dapat dilihat juga pada perbandingan terhadap ANN, FLNN-PSO memiliki tingkat *error* yang lebih tinggi untuk tahun 2019 dan 2020 tetapi mengalami penurunan tingkat *error* pada tahun 2021. FLNN-PSO juga memiliki waktu eksekusi yang cukup lama pada skenario 1 dan 2 dimana terdapat *batching data*. Waktu eksekusi tersebut juga dipengaruhi oleh besarnya orde yang dimiliki oleh model untuk ekspansi fitur. Sedikit berbeda dengan skenario 3 dimana tidak terdapatnya *batching data* sehingga waktu eksekusi relatif lebih cepat.

Melihat hasil dari 2 skenario lainnya dapat diartikan bahwa FLNN-PSO dapat menghasilkan performa yang lebih baik ketika menggunakan fitur yang lebih sedikit dan tidak ambigu. Adapun pada FLNN-PSO diterapkannya ekspansi fungsional untuk inputan yang memungkinkan kemampuan model untuk berkurang dalam ekstraksi fitur tanpa penggunaan *hidden layer* seperti pada *neural network* umumnya.

Untuk penelitian lebih lanjut, dimungkinkan untuk menggunakan kombinasi metode lainnya terhadap FLNN-PSO serta penggunaan metode praproses data yang berbeda untuk dapat memperluas proses pembelajaran model FLNN-PSO agar mendapatkan hasil yang lebih baik.

REFERENSI

- [1] J. S. Lestari, S. A. Cahyono, S. P. Warsito, W. Andayani, D. Dwidjono, and H. Darwanto, "Faktor-Faktor Yang Mempengaruhi Kebakaran Hutan Di Indonesia Dan Implikasi Kebijakannya (Factors Affecting Forest Fire In Indonesia And Policy Implication)," vol. 3, no. 1, pp. 103–112, 2015.
- [2] Kementrian Lingkungan Hidup dan Kehutanan, "SiPongi Forest and Land Fires Monitoring System," 2022. <https://sipongi.menlhk.go.id/> (accessed Nov. 05, 2022).
- [3] S. Yin, X. Wang, M. Guo, H. Santoso, and H. Guan, "The abnormal change of air quality and air pollutants induced by the forest fire in Sumatra and Borneo in 2015," *Atmos Res*, vol. 243, Oct. 2020, doi: 10.1016/j.atmosres.2020.105027.
- [4] E. Abdul Kadir, S. Listia Rosa, A. Syukur, M. Othman, and H. Daud, "Forest fire spreading and carbon concentration identification in tropical region Indonesia," *Alexandria Engineering Journal*, vol. 61, no. 2, pp. 1551–1561, Feb. 2022, doi: 10.1016/j.aej.2021.06.064.
- [5] X. Pan, M. Chin, C. M. Ichoku, and R. D. Field, "Connecting Indonesian Fires and Drought With the Type of El Niño and Phase of the Indian Ocean Dipole During 1979–2016," *Journal of Geophysical Research: Atmospheres*, vol. 123, no. 15, pp. 7974–7988, Aug. 2018, doi: 10.1029/2018JD028402.
- [6] J. Storer and R. Green, *PSO Trained Neural Networks for Predicting ForestFire Size: A Comparison of Implementation andPerformance*. 2016.
- [7] A. Shabrina et al., "Modelling the climate factors affecting forest fire in Sumatra using Random Forest and Artificial Neural Network," 2022.
- [8] S. C. Nayak, "Development and performance evaluation of adaptive hybrid higher order neural networks for exchange rate prediction," *International Journal of Intelligent Systems and Applications*, vol. 9, no. 8, pp. 71–85, Aug. 2017, doi: 10.5815/ijisa.2017.08.08.
- [9] S. Dehuri, R. Roy, S. B. Cho, and A. Ghosh, "An improved swarm optimized functional link artificial neural network (ISO-FLANN) for classification," *Journal of Systems and Software*, vol. 85, no. 6, pp. 1333–1345, Jun. 2012, doi: 10.1016/j.jss.2012.01.025.
- [10] M. Kumar, S. Singh, and S. K. Rath, "Classification of Microarray Data using Functional Link Neural Network," in *Procedia Computer Science*, Elsevier, 2015, pp. 727–737. doi: 10.1016/j.procs.2015.07.463.
- [11] J. Kennedy and R. Eberhart, "Particle Swarm Optimization," 1995. doi: 10.1109/ICNN.1995.488968.