



Spatial Prediction of Land and Forest Fires in Bangka Belitung Based on CNN-LSTM to Support Food Security and Sustainable Development

Prediksi Spasial Kebakaran Lahan dan Hutan Bangka Belitung Berbasis CNN-LSTM untuk Mendukung Ketahanan Pangan dan Pembangunan Berkelanjutan

Yudistira Bagus Pratama^{1*}, Mega Sukma²

¹Program Studi Ilmu Komputer, Universitas Muhammadiyah Bangka Belitung, Indonesia

²Program Studi Teknik Sipil, Universitas Muhammadiyah Bangka Belitung, Indonesia

E-Mail: ¹yudistira.bagus@unmuhbabel.ac.id, ²mega.sukma@unmuhbabel.ac.id

Received Sep 16th 2025; Revised Apr 26th 2026; Accepted May 08th 2026; Available Online Jun 20th 2026

Corresponding Author: Yudistira Bagus Pratama

Copyright © 2026 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

Forest and land fires in the Bangka Belitung Islands Province have increased significantly, posing serious threats to ecosystems, public health, and food security. This study aims to develop a spatio-temporal prediction model for forest and land fire hotspots using a hybrid deep learning approach based on a Convolutional Neural Network (CNN) and a Long Short-Term Memory (LSTM) network. The novelty of this research lies in integrating multiple environmental variables (NDVI, LST, humidity, precipitation, and wind speed) with satellite-based spatial features to improve prediction accuracy. The model was trained using historical fire data and multi-temporal satellite imagery, and evaluated using Mean Absolute Error (MAE) and Validation loss metrics. The results show that the proposed CNN-LSTM model achieves stable performance with low Validation error ($val_loss = 0.024$) and MAE ranging from 0.12–0.13. Spatial prediction results indicate that high-risk fire zones are concentrated in Bangka Selatan and Bangka Regencies, while temporal forecasting up to 2030 shows relatively stable trends with persistent fire risk in specific areas. These findings demonstrate that the proposed model is effective in capturing complex spatio-temporal fire patterns and can support data-driven early warning systems and regional fire mitigation policies. This study contributes to advancing deep learning applications in environmental risk prediction, particularly in integrating spatial and temporal modeling for sustainable development.

Keyword: Artificial Intelligence, Deep learning, Forecasting, Geospatial, Remote Sensing

Abstrak

Kebakaran hutan dan lahan di Provinsi Kepulauan Bangka Belitung telah meningkat secara signifikan, menimbulkan ancaman serius terhadap ekosistem, kesehatan masyarakat, dan ketahanan pangan. Studi ini bertujuan untuk mengembangkan model prediksi spasial-temporal untuk titik api kebakaran hutan dan lahan menggunakan pendekatan pembelajaran mendalam hibrida berdasarkan Convolutional Neural Network (CNN) dan Long Short-Term Memory (LSTM). Kebaruan penelitian ini terletak pada integrasi variabel lingkungan multi-sumber (NDVI, LST, kelembaban, curah hujan, dan kecepatan angin) dengan fitur spasial berbasis satelit untuk meningkatkan akurasi prediksi. Model dilatih menggunakan data kebakaran historis dan citra satelit multi-temporal, dan dievaluasi menggunakan *Mean Absolute Error* (MAE) dan metrik kerugian validasi. Hasil menunjukkan bahwa model CNN-LSTM yang diusulkan mencapai kinerja yang stabil dengan kesalahan validasi rendah ($val_loss = 0,024$) dan MAE berkisar antara 0,12–0,13. Hasil prediksi spasial menunjukkan bahwa zona kebakaran berisiko tinggi terkonsentrasi di Kabupaten Bangka Selatan dan Bangka, sementara peramalan temporal hingga tahun 2030 menunjukkan tren yang relatif stabil dengan risiko kebakaran yang terus-menerus di area tertentu. Temuan ini menunjukkan bahwa model yang diusulkan efektif dalam menangkap pola kebakaran spasial-temporal yang kompleks dan dapat mendukung sistem peringatan dini berbasis data dan kebijakan mitigasi kebakaran regional. Studi ini berkontribusi pada kemajuan aplikasi pembelajaran mendalam dalam prediksi risiko lingkungan, khususnya dalam mengintegrasikan pemodelan spasial dan temporal untuk pembangunan berkelanjutan.

Kata Kunci: Geospasial, Kecerdasan Buatan, Pembelajaran Mendalam, Penginderaan Jarak Jauh, Prediksi

1. PENDAHULUAN

Kebakaran lahan dan hutan merupakan permasalahan lingkungan yang memiliki dampak luas terhadap ekosistem, kesehatan masyarakat, dan ketahanan pangan [1]. Indonesia, sebagai negara dengan wilayah hutan tropis yang luas, kerap menghadapi ancaman kebakaran akibat faktor alami maupun aktivitas manusia [2]. Salah satu wilayah yang berpotensi mengalami kebakaran adalah Provinsi Kepulauan Bangka Belitung, yang sebagian besar wilayahnya terdiri dari lahan gambut, hutan produksi, serta lahan pertanian yang rentan terhadap kebakaran. Berdasarkan data BNPB, jumlah kejadian kebakaran lahan dan hutan di Bangka Belitung mengalami peningkatan dari tahun 2022 sejumlah 13 kasus dan 2023 sejumlah 89 kasus. Lonjakan ini mengindikasikan perlunya langkah mitigasi yang lebih efektif guna mengantisipasi risiko yang lebih besar di masa mendatang. Selain merusak ekosistem dan mengurangi daya dukung lingkungan, kebakaran lahan dan hutan juga berdampak pada ketahanan pangan [3]. Kebakaran yang terjadi di lahan pertanian dan perkebunan dapat menurunkan produksi pangan, merusak lahan produktif, menghasilkan polusi udara dalam bentuk kabut asap dan aktivitas ekonomi [4].

Dalam beberapa tahun terakhir, perkembangan teknologi kecerdasan buatan telah membuka peluang besar dalam meningkatkan efektivitas mitigasi bencana (5). Pemanfaatan komputer sebagai penghasil produk-produk berbasis teknologi sudah sangat banyak (6). Studi ilmiah tentang algoritma dan model statistik yang digunakan untuk melakukan tugas tertentu seperti prediksi dikenal sebagai *machine learning* (7). Dengan *machine learning*, permasalahan bisa diselesaikan dengan membentuk model yang merupakan representasi yang baik dari kumpulan data yang dipilih [8].

Tersedianya teknologi seperti drone, foto satelit, dan sensor jarak jauh menghasilkan data dalam jumlah besar, kecerdasan buatan dapat membantu proses pengolahan data berdasarkan sumber data tersebut menjadi lebih efektif [9]. Salah satu cara yang efektif untuk memprediksi kejadian kebakaran lahan dan hutan di Kepulauan Bangka Belitung adalah dengan menerapkan teknologi kecerdasan buatan berbasis *deep learning* yang merupakan bagian dari *machine learning* [10]. Pendekatan berbasis *deep learning*, khususnya kombinasi Convolutional Neural Network (CNN) dan Long Short-Term Memory (LSTM), terbukti mampu mengolah data spasial-temporal dengan akurasi tinggi [11]. CNN adalah salah satu bentuk pengembangan *deep learning* yang digunakan untuk menerima data berupa gambar dan belajar mengenali gambar guna mengklasifikasi objek citra menjadi nilai-nilai tertentu [12]. Dengan memanfaatkan data historis kebakaran, curah hujan, suhu udara, kelembapan, dan indeks vegetasi berdasarkan citra satelit model prediktif ini mampu mengidentifikasi area rawan kebakaran lebih dini [13] [14].

Penelitian ini mendukung upaya pembangunan berkelanjutan seperti SDG 13 (*Climate Action*) dengan membantu mitigasi risiko kebakaran lahan dan hutan untuk mengurangi dampak perubahan iklim [15]. SDG 15 (*Life on Land*) dengan melindungi ekosistem darat dan mencegah degradasi lahan akibat kebakaran [16]. SDG 2 (*Zero Hunger*) dengan menjaga ketahanan pangan melalui pencegahan kehilangan lahan pertanian [17]. Penelitian ini bertujuan untuk mengembangkan model prediksi spasial kebakaran lahan dan hutan guna mendukung mitigasi bencana kebakaran dan pembangunan berkelanjutan. Analisis dilakukan menggunakan data historis dari BNPB serta citra satelit Landsat 8, Landsat 9, Sentinel-2, dan MODIS untuk mengidentifikasi pola spasial dan temporal kebakaran lahan.


State of the Art dalam penelitian ini mengacu pada penelitian terdahulu yang menjadi acuan menentukan *research gap* dan *novelty*. Salah satu penelitian menggunakan Naïve Bayes dan Bagging untuk prediksi kebakaran, namun hanya mengandalkan *dataset* Algerian Forest Fire, tanpa mempertimbangkan aspek spasial-temporal secara luas (18). Penelitian selanjutnya mengombinasikan CNN dan Linear Regression, tetapi hanya mempertimbangkan suhu sebagai variabel utama, tanpa mengintegrasikan faktor lingkungan lain (19). Berikutnya penelitian yang menerapkan CNN untuk memprediksi wilayah rawan kebakaran, tetapi hanya berbasis fitur spasial tanpa menangkap pola temporal (20).

Meskipun berbagai penelitian telah dilakukan dalam prediksi kebakaran hutan, sebagian besar masih memiliki keterbatasan, seperti penggunaan model berbasis statistik atau *machine learning* konvensional yang belum mampu menangkap hubungan kompleks antara dimensi spasial dan temporal secara simultan. Selain itu, beberapa penelitian hanya berfokus pada satu jenis variabel lingkungan tanpa mengintegrasikan data multi-source yang lebih representatif terhadap kondisi aktual. Penelitian ini menawarkan kebaruan dengan pendekatan spasial-temporal, di mana CNN digunakan untuk mengekstrak fitur spasial dari citra satelit dan LSTM digunakan untuk menangkap pola waktu, sehingga mampu memberikan prediksi kebakaran yang lebih akurat dan dapat diintegrasikan secara aplikatif ke dalam sistem perencanaan kebijakan daerah, khususnya: penetapan zona rawan kebakaran dalam tata ruang, penyusunan rencana mitigasi kebakaran oleh BPBD dan Dinas Kehutanan, serta penguatan sistem peringatan dini berbasis data spasial. Dengan demikian, penelitian ini memberikan kontribusi signifikan dalam meningkatkan efektivitas prediksi dengan metode yang lebih canggih dan akurat dibandingkan dengan penelitian terdahulu.

2. METODOLOGI PENELITIAN

Metode penelitian yang digunakan dalam penelitian ini adalah dengan memanfaatkan *remote sensing* [21] dan algoritma *deep learning* [22] [23]. Kedua teknologi ini dapat membantu dalam pengembangan

model prediksi spasial kebakaran lahan dan hutan untuk mendukung ketahanan pangan dan pembangunan berkelanjutan di Bangka Belitung. Teknologi *remote sensing* dapat membantu peneliti mengumpulkan informasi tentang objek atau daerah tanpa harus berada di lokasi fisik [24]. Alur Metode Penelitian dapat dilihat pada Gambar 1.



Gambar 1. Metode Penelitian

2.1. Studi Literatur

Pemilihan kombinasi CNN dan LSTM didasarkan pada karakteristik data kebakaran hutan yang bersifat spasial-temporal [25]. CNN efektif dalam mengekstraksi pola spasial dari citra satelit seperti distribusi vegetasi dan tutupan lahan, sedangkan LSTM unggul dalam memodelkan dependensi jangka panjang pada data *time series* seperti suhu, curah hujan, dan kelembaban. Teknologi ini dapat membantu pemantauan lingkungan yang luas dan terus-menerus serta memungkinkan deteksi perubahan lingkungan seperti deforestasi, perubahan penggunaan lahan, erosi tanah, dan perubahan iklim [26]. Sedangkan algoritma *deep learning* LSTM dapat membuat prediksi valid dengan mengidentifikasi pola dan mengingat hubungan temporal dalam data jangka panjang [27]. LSTM mampu mengenali tren historis dari faktor-faktor lingkungan seperti suhu, curah hujan, kelembaban, dan indeks vegetasi, yang berkontribusi terhadap risiko kebakaran lahan dan hutan [28]. Hasil validasi analisis data dengan algoritma *Deep learning* LSTM dapat digunakan sebagai dasar dalam membuat rekomendasi kebijakan berbasis data untuk mitigasi kebakaran lahan dan hutan. Berikut adalah tahapan metode pengembangan algoritma prediksi spasial berbasis *deep learning* yang dapat dilakukan untuk mendukung ketahanan pangan dan pembangunan berkelanjutan.

2.2. Pengumpulan Data

Tahap ini meliputi pemilihan tim peneliti, pengumpulan data dan informasi, serta merumuskan tujuan dan masalah penelitian dengan jelas. Identifikasi kebutuhan dan tujuan: Langkah mengidentifikasi kebutuhan dan tujuan dari prediksi kebakaran lahan dan hutan berbasis *deep learning*. Hal ini dilakukan untuk menentukan fokus dan arah pengembangan model *deep learning* yang akan dibuat. Selain itu melakukan analisis kebutuhan *stakeholder*, seperti peta perubahan lahan, perubahan iklim, dan pemerintah provinsi, untuk memahami masalah dan kebutuhan yang perlu diselesaikan oleh model *deep learning* prediksi spasial kebakaran lahan dan hutan. Mengumpulkan data spasial tentang kebakaran lahan dan hutan antara lain data citra satelit seperti Landsat 8, Landsat 9, Sentinel-2, dan MODIS, data meteorologi dan klimatologi serta data historis kebakaran yang dapat membantu dalam pengembangan model *deep learning* prediksi spasial kebakaran lahan dan hutan.

2.3. Analisis Data

Tahapan selanjutnya melakukan analisis eksploratif terhadap data yang berkaitan dengan kebakaran lahan dan hutan di Bangka Belitung. Data dapat diperoleh dari berbagai sumber, seperti data pemerintah, data industri, dan citra satelit. Mengidentifikasi pola dan korelasi antar variabel data. Selanjutnya mengembangkan model *deep learning* yang sesuai dengan kebutuhan dan tujuan penelitian. Pengembangan model *deep learning* ini meliputi pengumpulan data, pembuatan model, dan validasi model dengan menggunakan

algoritma LSTM. Model yang dikembangkan dapat mengintegrasikan berbagai sumber data, seperti data tutupan lahan, data perubahan iklim, dan *data index land surface temperature*.

2.4. Pengembangan Model Prediksi

Tahapan selanjutnya melakukan prediksi spasial kebakaran lahan dan hutan di Provinsi Kepulauan Bangka Belitung menggunakan model *deep learning* yang telah dilatih untuk mendeteksi pola kebakaran, meningkatkan efektivitas mitigasi bencana, mendukung kebijakan lingkungan, serta memastikan ketahanan pangan dan pembangunan berkelanjutan. Setelah prediksi spasial dilakukan, selanjutnya menganalisis hasil berupa evaluasi keakuratan prediksi apakah sudah mendapatkan hasil yang diharapkan lalu mengidentifikasi area dengan perubahan signifikan dalam kebakaran lahan dan hutan di Bangka Belitung.

3. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan data satelit dan cuaca dari sensor *Moderate Resolution Imaging Spectroradiometer* (MODIS) pada satelit Aqua dan Terra, yang dikumpulkan dari tahun 2010 hingga 2024, yang diambil melalui Google Earth Engine. Data yang digunakan meliputi titik panas historis (FIRMS MODIS), curah hujan (CHIRPS), suhu dan kelembapan (ERA5-Land), tutupan lahan (MODIS), dan kecepatan angin (ERA5). Data ini kemudian diproses menggunakan model pembelajaran mendalam CNN-LSTM hibrida yang mampu mengenali pola spasial (distribusi geografis) dan temporal (perubahan seiring waktu) untuk memprediksi risiko kebakaran.

3.1. Data

Data mentah diambil dari Google Earth Engine dan disaring untuk mendapatkan titik koordinat yang sesuai dengan lokasi Kepulauan Bangka Belitung.



Gambar 2. Data mentah citra satelit

Gambar 2 menampilkan peta Provinsi Kepulauan Bangka Belitung yang ditandai dengan warna merah, mencakup hampir seluruh daratan utama, termasuk Pulau Bangka, Pulau Belitung, dan pulau-pulau kecil di sekitarnya. Garis merah secara keseluruhan menandakan area cakupan analisis atau area fokus penelitian, seperti distribusi titik panas, prediksi kebakaran, atau pemetaan lahan.

Proses awal pengambilan data

```
// 2.1 HOTSPOT (FIRMS)
var hotspotCol = ee.ImageCollection('FIRMS')
  .filterDate(startDate, endDate)
  .filterBounds(geometry);

var hotspots = ee.Algorithms.If({
  condition: hotspotCol.size().gt(0),
  trueCase: hotspotCol.select('T21').max()
    .updateMask(hotspotCol.select('T21').max().gt(300))
    .toFloat()
    .rename('hotspots'),
  falseCase: createEmptyImage('hotspots')
});

// 2.2 CURAH HUJAN (CHIRPS)
var precipCol = ee.ImageCollection('UCSB-CHG/CHIRPS/DAILY')
  .filterDate(startDate, endDate)
  .filterBounds(geometry);

var precipitation = ee.Algorithms.If({
  condition: precipCol.size().gt(0),
```

```
    trueCase: precipCol.sum().rename('precipitation'),
    falseCase: createEmptyImage('precipitation')
  });

// 2.3 SUHU (ERA5-LAND)
var temp = ee.ImageCollection('ECMWF/ERA5_LAND/DAILY_AGGR')
  .filterDate(startDate, endDate)
  .select('temperature_2m_max')
  .mean()
  .subtract(273.15)
  .rename('temperature');
```

Proses ekstraksi data lingkungan untuk analisis kebakaran hutan dilakukan dengan menggunakan tiga variabel kunci melalui Google Earth Engine, yaitu: data titik panas (*hotspot*) dari koleksi FIRMS dengan memilih band 'T21' yang mewakili suhu kecerahan dan hanya mempertahankan nilai di atas 300 Kelvin untuk mengidentifikasi peristiwa kebakaran yang signifikan; data curah hujan dari CHIRPS dengan menjumlahkan total curah hujan selama periode tertentu; dan data suhu udara dari ERA5-Land dengan memilih suhu maksimum harian yang kemudian dikonversi dari Kelvin ke Celsius. Ketiga parameter ini merupakan komponen kritis dalam pemodelan risiko kebakaran yang akan digunakan untuk pengembangan sistem peringatan dini.

Proses pengambilan data citra satelit

```
// 2.4 KELEMBABAN (ERA5-LAND)
var humidity = ee.ImageCollection('ECMWF/ERA5_LAND/DAILY_AGGR')
  .filterDate(startDate, endDate)
  .select('dewpoint_temperature_2m')
  .mean()
  .subtract(273.15)
  .rename('humidity');

// 2.5 NDVI (MODIS)
var ndviCol = ee.ImageCollection('MODIS/006/MOD13Q1')
  .filterDate(startDate, endDate)
  .filterBounds(geometry)
  .select('NDVI');

var ndvi = ee.Algorithms.If({
  condition: ndviCol.size().gt(0),
  trueCase: ndviCol.mean().multiply(0.0001).rename('ndvi'),
  falseCase: createEmptyImage('ndvi')
});

// 2.6 LAND COVER (MODIS)
var lcCol = ee.ImageCollection('MODIS/006/MCD12Q1')
  .filterDate(ee.Date.fromYMD(year, 1, 1), ee.Date.fromYMD(year, 12, 31));

var landCover = ee.Algorithms.If({
  condition: lcCol.size().gt(0),
  trueCase: lcCol.first().select('LC_Type1').rename('land_cover'),
  falseCase: createEmptyImage('land_cover')
});


// 2.7 KECEPATAN ANGIN (ERA5)
var windCol = ee.ImageCollection('ECMWF/ERA5/DAILY')
  .filterDate(startDate, endDate)
  .select(['u_component_of_wind_10m', 'v_component_of_wind_10m']);

var windSpeed = ee.Algorithms.If({
  condition: windCol.size().gt(0),
  trueCase: windCol.mean().expression(
    'sqrt(u*u + v*v)', {
      'u': windCol.mean().select('u_component_of_wind_10m'),
      'v': windCol.mean().select('v_component_of_wind_10m')
    }).rename('wind_speed'),
  falseCase: createEmptyImage('wind_speed')
});
```

Proses ekstraksi data lingkungan dilanjutkan dengan mengambil empat variabel tambahan yang krusial untuk pemodelan kebakaran hutan. Data kelembaban diperoleh dari ERA5-Land dengan menghitung rata-rata titik embun permukaan yang dikonversi dari Kelvin ke Celsius, yang menggambarkan kandungan uap air di atmosfer. Indeks NDVI sebagai indikator kesehatan vegetasi diambil dari MODIS dengan faktor skala 0.0001 untuk mendapatkan nilai yang valid, mencerminkan kepadatan dan kekeringan

vegetasi yang dapat menjadi bahan bakar potensial kebakaran. Data penutup lahan dari MODIS MCD12Q1 menggunakan klasifikasi LC_Type1 untuk mengidentifikasi jenis permukaan lahan dengan tingkat kerentanan yang berbeda terhadap kebakaran. Akhirnya, kecepatan angin dihitung dari komponen u dan v angin ERA5 menggunakan rumus matematis untuk mendapatkan magnitudo angin yang mempengaruhi penyebaran kebakaran. Keempat variabel ini, bersama dengan data sebelumnya, membentuk *dataset* lengkap untuk analisis risiko kebakaran spasial-waktu.

Dua proses utama adalah pengumpulan data tahunan dan persiapan data untuk pelatihan model. Pertama, kode tersebut membuat Koleksi Gambar yang berisi tumpukan data lingkungan untuk setiap tahun dalam periode 2010-2024 dengan memanggil fungsi `getEnvironmentalLayers` untuk setiap tahun, menghasilkan 15 gambar komposit, masing-masing berisi semua variabel lingkungan yang diekstraksi. Kedua, kode secara acak mengambil 1000 piksel dari setiap gambar tahunan pada skala 1000 meter yang mencakup seluruh area studi. Proses pengambilan sampel ini mencakup informasi geometris tentang koordinat setiap piksel sehingga hasilnya dapat digunakan untuk analisis spasial. Hasil pengambilan sampel untuk setiap tahun kemudian diekspor ke Google Drive dalam format CSV, yang akan berisi tabel dengan kolom variabel lingkungan (*hotspots*, curah hujan, suhu, kelembaban, NDVI, tutupan lahan, kecepatan angin) beserta koordinat geografisnya, membentuk *dataset* lengkap yang siap digunakan untuk melatih model pembelajaran mesin atau pembelajaran mendalam dalam prediksi kebakaran hutan.



Gambar 3. Peta wilayah bangka belitung yang sudah diproses

Peta pada Gambar 3 menampilkan lapisan data temporal yang mencakup periode 2010 hingga 2024. Setiap lapisan mewakili variabel lingkungan tertentu yang dipetakan berdasarkan titik tengah tahun yang digunakan sebagai acuan temporal. Area dengan tingkat kebakaran lahan dan hutan yang tinggi dapat dilihat Langkah berikutnya adalah memproses dan membersihkan data temporal dari *Data Frame* menggunakan langkah-langkah sistematis: pertama, kode mengidentifikasi kolom tanggal potensial (seperti 'date', 'Date', atau 'year') dan mengonversinya ke format tanggal dan waktu standar. Jika tidak ditemukan kolom tanggal eksplisit tetapi ditemukan kolom 'year', kode secara otomatis menghasilkan seri tanggal bulanan mulai dari Januari tahun minimum dengan frekuensi bulanan (akhir bulan). Selanjutnya, kode menangani nilai *null* dengan mengisi atau menghapus data yang tidak valid, mengurutkan data berdasarkan tanggal, dan menyaring data hanya untuk rentang waktu Januari 2010 hingga Desember 2024 untuk memastikan konsistensi temporal dalam analisis seri waktu. Hasilnya adalah *Dataframe* yang diindeks secara temporal dan siap untuk diproses lebih lanjut dalam pemodelan seri waktu.

```
Cleaned date range: 2010-01-31 00:00:00 to 2024-12-31 00:00:00
/tmp/lpython-input-3009502321.py:16: FutureWarning: 'M' is deprecated and will be removed in a future version, please use 'ME' instead.
df["Date"] = pd.date_range(start=f'{start_year}-01-31', periods=len(df), freq='M')
system:index hotspots humidity land_cover ndvi precipitation temperature wind_speed year .geo
```

Date	system:index	hotspots	humidity	land_cover	ndvi	precipitation	temperature	wind_speed	year	.geo
2010-01-31	0_0	315.100006	24.127319	8.0	0.649935	3982.806064	28.580749	0.396481	2010.0	["type":"Point","coordinates":[105.41505003587...
2010-02-28	0_34	331.600006	24.291503	8.0	0.642965	3984.836038	28.994625	0.318401	2010.0	["type":"Point","coordinates":[105.58796155520...
2010-03-31	0_66	318.700012	23.970551	8.0	0.548635	3878.228307	28.403841	0.396481	2010.0	["type":"Point","coordinates":[105.39226717542...
2010-04-30	0_194	311.000000	24.344964	8.0	0.667874	3684.889110	28.851981	0.212530	2010.0	["type":"Point","coordinates":[105.69391693085...
2010-05-31	0_192	339.799988	24.154657	2.0	0.734070	4178.228999	28.751222	0.379800	2010.0	["type":"Point","coordinates":[107.66071781121...

Gambar 4. *Dataframe* temporal

Gambar 4 merupakan hasil pemrosesan data seri waktu lingkungan untuk analisis kebakaran hutan yang mencakup periode 15 tahun dari Januari 2010 hingga Desember 2024. *Dataframe* menampilkan data bulanan yang telah dibersihkan dan terstruktur dengan variabel kunci termasuk titik panas (*hotspots*), kelembaban, tutupan lahan (*land_cover*), NDVI (indeks vegetasi), curah hujan, suhu, kecepatan angin,

informasi tahun, dan koordinat geografis dalam format GeoJSON. Nilai titik panas menunjukkan fluktuasi bulanan antara 311-340 Kelvin, menunjukkan variasi aktivitas kebakaran, sementara NDVI berkisar antara 0,55-0,73, mencerminkan perubahan kondisi vegetasi sepanjang tahun. Data ini telah diindeks secara temporal dan siap digunakan dalam pemodelan statistik atau pembelajaran mesin untuk memprediksi risiko kebakaran hutan berdasarkan pola historis parameter lingkungan ini.

3.2. Analisis Data

Analisis ini mencakup analisis deret waktu, analisis spasial, pemodelan prediktif menggunakan CNN-LSTM, dan analisis dampak sosial-ekonomi terkait ketahanan pangan dan Tujuan Pembangunan Berkelanjutan (SDGs). Pendekatan multidisiplin ini akan memberikan wawasan holistik untuk mitigasi kebakaran dan perencanaan pembangunan berkelanjutan di Bangka Belitung.

3.2.1. Analisis Time Series

Pembentukan sequence multi output

```
# Scale
scaler = MinMaxScaler()
data = scaler.fit_transform(series.values.reshape(-1,1)).flatten()

# Create multi-output sequences
def create_multi(data, look_back=24, horizon=12):
    X, Y = [], []
    for i in range(len(data) - look_back - horizon + 1):
        X.append(data[i:i+look_back])
        Y.append(data[i+look_back:i+look_back+horizon])
    return np.array(X), np.array(Y)

look_back = 24
horizon = 12
X, Y = create_multi(data, look_back=look_back, horizon=horizon)
X = X.reshape((X.shape[0], X.shape[1], 1))
print('X shape, Y shape:', X.shape, Y.shape)
X shape, Y shape: (145, 24, 1) (145, 12)
```

Dua proses utama dilakukan, yaitu normalisasi data dan pembentukan *dataset* untuk melatih model prediksi seri waktu *multi-output*. Pertama, data seri waktu univariat ‘hotspots’ dinormalisasi menggunakan *MinMaxScaler*, yang mengubah nilai-nilai tersebut ke dalam rentang [0, 1] agar lebih stabil selama proses pelatihan model. Selanjutnya, fungsi *create_multi* digunakan untuk membentuk urutan data *input* (X) dan *output* (Y), di mana setiap urutan *input* terdiri dari 24 langkah waktu (*look_back*) dan urutan *output* terdiri dari 12 langkah waktu (*horizon*) yang akan diprediksi. Hasilnya adalah array X dengan dimensi (*samples*, *look_back*, 1) dan array Y dengan dimensi (*samples*, *horizon*), yang siap digunakan untuk melatih model jaringan saraf seperti CNN-LSTM yang memerlukan *input* dalam format [*samples*, *timesteps*, *features*].

Pembagian data latih

```
# Train/test split (time-aware)
split = int(len(X) * 0.8)
X_train, X_test = X[:split], X[split:]
Y_train, Y_test = Y[:split], Y[split:]
print('Train samples:', X_train.shape[0], 'Test samples:', X_test.shape[0])
Train samples: 116 Test samples: 29
```


Pembagian *dataset* menjadi data pelatihan dan data uji menggunakan metode pembagian yang sadar waktu untuk pemodelan deret waktu, yang memisahkan 80% data awal sebagai data pelatihan (*X_train* dan *Y_train*) dan 20% data akhir sebagai data uji (*X_test* dan *Y_test*), sehingga menjaga urutan kronologis data dan mencegah kebocoran informasi dari masa depan ke masa lalu. 116 sampel data (80% dari total data) dari periode awal digunakan sebagai data pelatihan untuk melatih model mengenali pola temporal historis, sementara 29 sampel data (20% dari total data) dari periode akhir digunakan sebagai data uji untuk menguji kemampuan prediktif model pada data yang belum pernah dilihat sebelumnya.

Model yang dihasilkan memiliki hiperparameter terbaik dalam bentuk kombinasi filter1: 64, filter2: 256, lstm_units1: 128, dropout1: 0.2, lstm_units2: 96, dropout2: 0.4, dense_units: 32, dropout3: 0.1, dan *learning rate*: 0.01. Dari hasil pelatihan pada Gambar 5 yang berlangsung selama beberapa *epoch*, nilai *loss* dan *val_loss* terus menurun, dengan nilai *val_loss* terbaik tercapai pada 0.02428506314754486. Meskipun muncul peringatan terkait variabel *optimizer* Adam saat memanggil model, proses pelatihan tetap berjalan normal dan menunjukkan metrik *mean absolute error* (MAE) yang relatif stabil dalam rentang 0.12 hingga 0.13, menunjukkan bahwa model mampu belajar dengan baik pada data yang digunakan.

Dua grafik pada Gambar 6 menunjukkan hasil evaluasi model selama proses pelatihan berdasarkan metrik *loss* (MSE) dan MAE. Grafik kiri menampilkan *Training & Validation Loss*, di mana *loss* pelatihan (biru) cenderung menurun secara stabil seiring bertambahnya jumlah *epoch*, sementara *loss* validasi (oranye) berfluktuasi dan tidak stabil, meskipun masih dalam rentang yang relatif rendah. Grafik kanan menunjukkan *Training & Validation MAE*, di mana MAE pelatihan (biru) terus mengalami penurunan yang konsisten hingga sekitar 0,11, sementara MAE validasi (oranye) menunjukkan pola naik-turun dan cenderung lebih tinggi daripada MAE pelatihan. Pola ini menunjukkan bahwa model belajar dengan baik pada data pelatihan. Hasil pelatihan menunjukkan bahwa model mampu mempelajari pola data dengan baik, ditunjukkan oleh penurunan *loss* yang konsisten. Namun, fluktuasi pada *Validation loss* mengindikasikan adanya potensi overfitting ringan, yang kemungkinan disebabkan oleh keterbatasan jumlah data atau kompleksitas model yang tinggi. Hal ini sejalan dengan karakteristik model *deep learning* yang sensitif terhadap distribusi data.

```
Best val_loss So Far: 0.02428506314754486
Total elapsed time: 00h 03m 00s
Best Hyperparameters:
{'filters1': 64, 'filters2': 256, 'lstm_units1': 128, 'dropout1': 0.2, 'lstm_units2': 96, 'dropout2': 0.4, 'dense_units': 32, 'dropout3': 0.1, 'lr': 0.01}
Epoch 1/50
/usr/local/lib/python3.12/dist-packages/keras/src/saving/saving_lib.py:802: UserWarning: Skipping variable loading for optimizer 'adam', because it has 2 variables whereas the saved
saveable.load_own_variables(weights_store.get(inner_path))
3/3 ----- 7s 355ms/step - loss: 0.0271 - mae: 0.1194 - val_loss: 0.0258 - val_mae: 0.1227
Epoch 2/50
3/3 ----- 1s 87ms/step - loss: 0.0292 - mae: 0.1199 - val_loss: 0.0241 - val_mae: 0.1262
Epoch 3/50
3/3 ----- 0s 67ms/step - loss: 0.0259 - mae: 0.1148 - val_loss: 0.0243 - val_mae: 0.1286
Epoch 4/50
3/3 ----- 0s 85ms/step - loss: 0.0262 - mae: 0.1162 - val_loss: 0.0245 - val_mae: 0.1295
Epoch 5/50
3/3 ----- 0s 94ms/step - loss: 0.0249 - mae: 0.1129 - val_loss: 0.0243 - val_mae: 0.1284
Epoch 6/50
3/3 ----- 0s 66ms/step - loss: 0.0239 - mae: 0.1133 - val_loss: 0.0257 - val_mae: 0.1360
Epoch 7/50
3/3 ----- 0s 64ms/step - loss: 0.0252 - mae: 0.1168 - val_loss: 0.0260 - val_mae: 0.1378
Epoch 8/50
3/3 ----- 0s 64ms/step - loss: 0.0249 - mae: 0.1154 - val_loss: 0.0249 - val_mae: 0.1317
Epoch 9/50
3/3 ----- 0s 65ms/step - loss: 0.0233 - mae: 0.1118 - val_loss: 0.0256 - val_mae: 0.1346
Epoch 10/50
3/3 ----- 0s 65ms/step - loss: 0.0251 - mae: 0.1153 - val_loss: 0.0268 - val_mae: 0.1391
Epoch 11/50
3/3 ----- 0s 65ms/step - loss: 0.0238 - mae: 0.1135 - val_loss: 0.0257 - val_mae: 0.1345
Epoch 12/50
3/3 ----- 0s 66ms/step - loss: 0.0229 - mae: 0.1119 - val_loss: 0.0249 - val_mae: 0.1308
```

Gambar 5. Hasil proses pelatihan model *deep learning*



Gambar 6. Visualisasi *training Validation loss & mae*


```
1/1 ----- 0s 426ms/step
1/1 ----- 0s 40ms/step
1/1 ----- 0s 38ms/step
/tmp/ipython-input-89678605.py:16: FutureWarning: 'M' is deprecated and will be removed in a future version, please use 'ME' instead.
months = pd.date_range(start=current_date + pd.offsets.MonthEnd(), periods=horizon, freq='M')
/tmp/ipython-input-89678605.py:16: FutureWarning: 'M' is deprecated and will be removed in a future version, please use 'ME' instead.
months = pd.date_range(start=current_date + pd.offsets.MonthEnd(), periods=horizon, freq='M')
/tmp/ipython-input-89678605.py:16: FutureWarning: 'M' is deprecated and will be removed in a future version, please use 'ME' instead.
months = pd.date_range(start=current_date + pd.offsets.MonthEnd(), periods=horizon, freq='M')
1/1 ----- 0s 43ms/step
1/1 ----- 0s 41ms/step
1/1 ----- 0s 41ms/step
Forecast range: 2025-01-31 00:00:00 to 2030-12-31 00:00:00
/tmp/ipython-input-89678605.py:16: FutureWarning: 'M' is deprecated and will be removed in a future version, please use 'ME' instead.
months = pd.date_range(start=current_date + pd.offsets.MonthEnd(), periods=horizon, freq='M')
/tmp/ipython-input-89678605.py:16: FutureWarning: 'M' is deprecated and will be removed in a future version, please use 'ME' instead.
months = pd.date_range(start=current_date + pd.offsets.MonthEnd(), periods=horizon, freq='M')
/tmp/ipython-input-89678605.py:16: FutureWarning: 'M' is deprecated and will be removed in a future version, please use 'ME' instead.
months = pd.date_range(start=current_date + pd.offsets.MonthEnd(), periods=horizon, freq='M')
hotspots
date
2025-01-31 310.949188
2025-02-28 312.296112
2025-03-31 321.599335
2025-04-30 318.974335
2025-05-31 316.842560
```

Gambar 7. Hasil proses iteratif forecasting

Gambar 7 merupakan hasil prediksi jumlah *hotspot* hingga akhir tahun 2030 menggunakan model deret waktu. Pada awalnya, log prediksi per iterasi terlihat dengan kecepatan eksekusi yang relatif cepat per

langkah (sekitar 38–48 ms/langkah). Dari hasil *output*, rentang prediksi ditampilkan dari Januari 2025 hingga Desember 2030, dengan cuplikan lima bulan pertama data menunjukkan jumlah titik panas yang diperkirakan, misalnya Januari 2025 sebesar 310,95, Februari 312,30, Maret 321,59, April 318,97, dan Mei 316,84. Hasil ini disimpan dalam *Dataframe* dengan indeks berupa tanggal bulanan dan kolom utama bernama *hotspots*.


Visualisasi data historis pada Gambar 8 mengenai jumlah titik panas kebakaran lahan di Kepulauan Bangka Belitung untuk periode 2010–2024 (garis biru) yang diproyeksikan hingga 2030 menggunakan model CNN-LSTM (garis merah). Data historis menunjukkan fluktuasi yang cukup tinggi dengan beberapa puncak signifikan, terutama sekitar tahun 2015 dan 2019, yang menunjukkan periode intensitas kebakaran yang lebih tinggi. Sementara itu, proyeksi hingga tahun 2030 menunjukkan pola yang lebih stabil dengan fluktuasi yang relatif kecil, menunjukkan bahwa model memprediksi kecenderungan jumlah titik panas tetap pada level moderat tanpa lonjakan ekstrem seperti yang terlihat pada data historis.



Gambar 8. Historical forecasting

3.2.2. Analisis Spatial

Setelah model menghasilkan data prediksi, data tersebut diproses di Google Earth Engine untuk visualisasi. Selanjutnya, rentang tahun 2025 hingga 2030 ditentukan sebagai periode prediksi. Kemudian, kode memanggil batas administratif Bangka Belitung dari *dataset* FAO GAUL level 2 dan menampilkan area tersebut sebagai fokus peta. Pada bagian inti, untuk setiap tahun dalam rentang prediksi, data difilter berdasarkan atribut tanggal sesuai tahun, lalu dikonversi menjadi gambar raster (*image*) dengan mengambil nilai atribut prediksi dan menjumlahkan semua bulan dalam tahun tersebut menggunakan `ee.Reducer.sum()`. Nilai prediksi kemudian diolah dengan `unmask(0)` sehingga piksel kosong diisi dengan nol, dan dikalikan dengan seribu (`multiply(1000)`) untuk skala tertentu. Hasil akhir disimpan dalam kamus `yearlyData` yang berisi gambar prediksi per tahun dari 2025 hingga 2030.




Gambar 9. Antaramuka visualiasi kebakaran hutan dan lahan

Secara spasial terlihat pada Gambar 9, konsentrasi *hotspot* yang tinggi di Kabupaten Bangka Selatan dan Bangka dapat dijelaskan oleh karakteristik wilayah tersebut yang didominasi oleh lahan gambut dan aktivitas perkebunan, yang memiliki tingkat kerentanan tinggi terhadap kebakaran. Selain itu, faktor iklim lokal seperti suhu tinggi dan kelembaban rendah turut memperkuat potensi kebakaran di wilayah tersebut. Peta menampilkan distribusi kategori *hotspot* di Provinsi Kepulauan Bangka Belitung untuk tahun 2027 berdasarkan jumlah total *hotspot* per kabupaten/kota. Warna merah menunjukkan kategori tinggi ($\geq 77.823.013$), oranye kategori sedang ($< 77.823.013$), dan kuning kategori rendah ($< 38.911.507$). Dari data tersebut, dapat dilihat bahwa Kabupaten Bangka Selatan memiliki jumlah nilai *hotspot* tertinggi, yaitu 116.734.520, diikuti oleh Kabupaten Bangka dengan 108.563.103 dan Kabupaten Bangka Barat dengan

72.510.096. Kabupaten Bangka Tengah termasuk dalam kategori sedang dengan 57.244.812, sementara Belitung dan Kota Pangkalpinang memiliki nilai yang sama, yaitu 3.816.321, yang termasuk dalam kategori rendah. Sementara itu, Kabupaten Belitung Timur tercatat tidak memiliki titik panas. Peta Gambar 9 menunjukkan bahwa konsentrasi titik panas tertinggi terdapat di bagian selatan dan tengah Pulau Bangka.

Grafik sampel 2030 pada Gambar 10 menunjukkan nilai total *hotspot* yang diprediksi per kabupaten/kota di Provinsi Kepulauan Bangka Belitung untuk tahun 2030. Kabupaten Bangka Selatan diperkirakan memiliki nilai *hotspot* tertinggi, mendekati 120 juta, diikuti oleh Kabupaten Bangka dengan sekitar 110 juta nilai *hotspot*. Kabupaten Bangka Barat berada di posisi ketiga dengan sekitar 75 juta nilai *hotspot*, sementara Kabupaten Bangka Tengah memiliki sekitar 55 juta nilai *hotspot*. Kabupaten Belitung Timur diperkirakan tidak memiliki *hotspot*, sementara Kabupaten Belitung dan Kota Pangkalpinang mencatat angka yang sangat kecil, masing-masing di bawah 5 juta nilai *hotspot*. Pola ini menunjukkan bahwa konsentrasi *hotspot* terbesar terdapat di wilayah Kabupaten Bangka Selatan dan Kabupaten Bangka, sementara Pulau Belitung relatif aman dari potensi *hotspot*.



Gambar 10. Barchart prediksi *hotspot*

4. KESIMPULAN

Penelitian ini berhasil mengembangkan model prediksi spasial-temporal kebakaran hutan dan lahan berbasis *deep learning* hybrid CNN-LSTM dengan memanfaatkan data satelit multi-sumber (MODIS, CHIRPS, ERA5-Land) yang diolah melalui Google Earth Engine. Model yang dihasilkan menunjukkan performa yang baik dengan nilai *Validation loss* rendah dan MAE yang stabil, sehingga mampu mempelajari pola kebakaran secara akurat serta digunakan untuk memprediksi jumlah *hotspot* hingga tahun 2030. Kebaruan utama penelitian ini terletak pada integrasi data *multi-source* berbasis citra satelit dengan pendekatan CNN-LSTM untuk menangkap hubungan spasial dan temporal secara simultan, khususnya pada konteks wilayah Kepulauan Bangka Belitung yang masih terbatas dikaji dengan pendekatan serupa. Hasil analisis menunjukkan bahwa secara spasial, risiko kebakaran tertinggi terpusat di Kabupaten Bangka Selatan dan Bangka dengan kategori tinggi, sementara wilayah Belitung dan Kota Pangkalpinang relatif rendah, bahkan Belitung Timur diprediksi tidak mengalami *hotspot*. Secara temporal, tren *hotspot* cenderung stabil pada tingkat moderat tanpa lonjakan ekstrem, meskipun potensi kebakaran signifikan tetap ada pada wilayah tertentu. Temuan ini menegaskan bahwa risiko kebakaran bersifat spasial terlokalisasi dan musiman, sehingga strategi mitigasi perlu difokuskan pada wilayah berisiko tinggi. Selain itu, integrasi variabel lingkungan seperti cuaca dan vegetasi dalam model terbukti efektif dalam mendukung pengembangan sistem peringatan dini berbasis data historis dan proyeksi jangka panjang. Secara keseluruhan, penelitian ini memberikan kontribusi penting dalam mendukung perencanaan mitigasi kebakaran, pembangunan berkelanjutan, dan penguatan ketahanan pangan sesuai target SDGs. Untuk pengembangan selanjutnya, disarankan penambahan variabel sosial-ekonomi, penggunaan data dengan resolusi lebih tinggi, serta eksplorasi model lanjutan seperti Transformer dan Graph Neural Network guna meningkatkan akurasi dan robustnes prediksi.

REFERENSI

- [1] J. R. Bergado, C. Persello, K. Reinke, and A. Stein, "Predicting wildfire burns from big geodata using *deep learning*," *Saf. Sci.*, vol. 140, no. January 2020, p. 105276, 2021, doi: 10.1016/j.ssci.2021.105276.
- [2] J. Kurniawan, A. Razak, N. Syah, S. Diliarosta, and A. Azhar, "Pemanasan Global: Faktor, Dampak dan Upaya Penanggulangan," *INSOLOGI J. Sains dan Teknol.*, vol. 3, no. 6, pp. 646–655, 2024.
- [3] C. Shi and F. Zhang, "A Forest Fire Susceptibility Modeling Approach Based on Integration *Machine learning* Algorithm," *Forests*, vol. 14, no. 7, 2023, doi: 10.3390/f14071506.
- [4] X. You *et al.*, "A PSO-CNN-Based *Deep learning* Model for Predicting Forest Fire Risk on a

- National Scale,” *Forests*, vol. 15, no. 1, 2024, doi: 10.3390/f15010086.
- [5] C. Y. Ku and C. Y. Liu, “Predictive Modeling of Fire Incidence Using Deep Neural Networks,” *Fire*, vol. 7, no. 4, pp. 1–22, 2024, doi: 10.3390/fire7040136.
 - [6] Y. B. Pratama and N. P. Dalimunthe, “Implementasi Teknik Computer Vision Untuk Deteksi Viridiplantae Pada Lahan Pasca Tambang,” vol. 3, no. 1, pp. 64–72, 2022, doi: 10.47065/bulletincsr.v3i1.193.
 - [7] Y. B. Pratama and A. Setiawan, “Implementasi *Machine learning* Menggunakan Algoritma K-Means Untuk Klasifikasi Sekolah Dasar,” *Resolusi Rekayasa Tek. Inform. dan Inf.*, vol. 4, no. 3, pp. 249–257, 2024.
 - [8] M. Mustaqim, A. Gunawan, Y. B. Pratama, and I. Zaliman, “Pengembangan Chatbot Layanan Publik Menggunakan *Machine learning* Dan Natural Language Processing,” *J. Inf. Technol. Soc.*, vol. 1, no. 1, pp. 1–4, 2023, doi: 10.35438/jits.v1i1.16.
 - [9] Y. B. Pratama, N. P. Dalimunthe, and M. Sukma, “Prediksi Spasial Kerapatan Vegetasi Perkotaan dengan Pendekatan Algoritma *Time series* Untuk Mendukung Pertumbuhan Ekonomi Hijau,” vol. 6, no. 2, pp. 1495–1507, 2025, doi: 10.47065/josh.v6i2.6251.
 - [10] R. Ghali and M. A. Akhloufi, “*Deep learning* Approaches for Wildland Fires Using Satellite *Remote sensing* Data: Detection, Mapping, and Prediction,” *Fire*, vol. 6, no. 5, 2023, doi: 10.3390/fire6050192.
 - [11] N. Alizadeh, M. Mahdianpari, E. Hemmati, and M. Marjani, “FusionFireNet: A CNN-LSTM model for short-term wildfire *hotspot* prediction utilizing spatio-temporal *datasets*,” *Remote Sens. Appl. Soc. Environ.*, vol. 37, p. 101436, 2025.
 - [12] S. Pratama, E. Altirika, and Y. B. Pratama, “Pengembangan Sistem Absensi Mahasiswa Magang PLN Icon Plus Bangka Belitung dengan Pengenalan Wajah menggunakan Computer Vision dan Algoritma *Deep learning*,” vol. 2, no. 2, pp. 52–59, 2024.
 - [13] C. Mambile, S. Kaijage, and J. Leo, “*Deep learning* models for enhanced forest-fire prediction at Mount Kilimanjaro, Tanzania: Integrating satellite images, weather data and human activities data,” *Nat. Hazards Res.*, no. October, pp. 1–13, 2025, doi: 10.1016/j.nhres.2024.12.001.
 - [14] S. Yu and M. Singh, “*Deep learning*-Based *Remote sensing* Image Analysis for Wildfire Risk Evaluation and Monitoring,” *Fire*, vol. 8, no. 1, pp. 1–17, 2025, doi: 10.3390/fire8010019.
 - [15] P. C. Latue, H. Rakuasa, G. Somae, and A. Muin, “Analisis perubahan suhu permukaan daratan di Kabupaten Seram Bagian Barat menggunakan platform berbasis cloud Google Earth Engine,” *Sudo J. Tek. Inform.*, vol. 2, no. 2, pp. 45–51, 2023.
 - [16] S. Najia and A. Triyatno, “Analisis Teori Politik Hijau terhadap Penerapan Tujuan Pembangunan Berkelanjutan (TPB) Kehidupan Daratan di Indonesia: Studi Kasus: Kebakaran Hutan dan Lahan Indonesia 2016-2019,” *J. Sos. Polit. Perad.*, vol. 3, no. 1, pp. 87–104, 2022.
 - [17] R. R. Rachmawati, “Smart Farming 4.0 Untuk Mewujudkan Pertanian Indonesia Maju, Mandiri, Dan Modern Smart Farming 4.0 To Build Advanced, Independent, and Modern Indonesian Agriculture Rika Reviza Rachmawati,” *Forum Penelit. Agro Ekon.*, vol. 38, no. 2, pp. 137–154, 2020, [Online]. Available: <http://dx.doi.org/10.21082/fae.v38n2.2020.137-154>
 - [18] F. Fitriyani, “Implementasi Forward Selection dan Bagging untuk Prediksi Kebakaran Hutan Menggunakan Algoritma Naïve Bayes,” *J. Nas. Teknol. dan Sist. Inf.*, vol. 8, no. 1, pp. 1–8, 2022, doi: 10.25077/teknosi.v8i1.2022.1-8.
 - [19] F. Sodik, A. Sanusi Mashuri, and S. Huda, “Implementasi Algoritma Convolutional Neural Network Dan Linear Regresi Untuk Memprediksi Kebakaran Hutan Implementation of Convolutional Neural Network and Linear Regression Algorithm to Predict Forest Fires,” *Cogito Smart J. |*, vol. 9, no. 1, pp. 28–37, 2023.
 - [20] A. Zuhdi and M. S. Utama, “Prediksi Wilayah Rawan Kebakaran Menggunakan *Deep learning*,” *Ijccs*, vol. x, No.x, no. x, pp. 1–5, 2024.
 - [21] G. Dursun, F. Yilgan, and S. Dogan, “Monitoring of Moisture and Temperature Regime on Agricultural Land Parcels Using Landsat-8 *Remote sensing* Data in the Mardin Province, Türkiye,” *J. Indian Soc. Remote Sens.*, pp. 1–16, 2025.
 - [22] L. Wang, H. Liu, F. Zhang, L. Guo, and Z. Chen, “Intelligent prediction approach of spatial structure response and performance deterioration by integrating spatiotemporal *deep learning* and digital twins,” *Eng. Struct.*, vol. 324, p. 119367, 2025.
 - [23] K. Wang, S. Shan, W. Dou, H. Wei, and K. Zhang, “A cross-modal *deep learning* method for enhancing photovoltaic power forecasting with satellite imagery and *time series* data,” *Energy Convers. Manag.*, vol. 323, p. 119218, 2025.
 - [24] S. Gui, S. Song, R. Qin, and Y. Tang, “*Remote sensing* object detection in the *deep learning* era—a review,” *Remote Sens.*, vol. 16, no. 2, p. 327, 2024.
 - [25] L. Fitriani, “Kerangka Pemodelan Iklim Berbasis Kecerdasan Buatan Menggunakan Fusi Data Satelit dan Pembelajaran Mendalam,” *RIGGS J. Artif. Intell. Digit. Bus.*, vol. 4, no. 4, pp. 8314–8324, 2026.

- [26] B. Haq *et al.*, “Tech-Driven Forest Conservation: Combating Deforestation With Internet of Things, Artificial Intelligence, and Remote Sensing,” *IEEE Internet Things J.*, 2024.
- [27] F. A. Mahbubi, T. I. Hermanto, and C. D. Lestari, “Peramalan Penjualan Saham Nikel Menggunakan Algoritma Long Short Term Memory (LSTM),” *IDEALIS Indones. J. Inf. Syst.*, vol. 8, no. 1, pp. 138–149, 2025.
- [28] Y. Peng, H. Su, M. Sun, and M. Li, “Reconstructing historical forest fire risk in the non-satellite era using the improved forest fire danger index and long short-term memory *deep learning*-a case study in Sichuan Province, southwestern China,” *For. Ecosyst.*, vol. 11, p. 100170, 2024.