

Perbandingan Model Prediksi Frekuensi Titik Panas di Provinsi Riau dengan menggunakan LSTM

Emanuella M. C. Wattimena^{1*}, Meilin I. Tilukay²

¹ Program Studi Ilmu Komputer, Jurusan Matematika, Fakultas MIPA Universitas Pattimura, Ambon, Indonesia

² Program Studi Matematika, Jurusan Matematika, Fakultas MIPA Universitas Pattimura, Ambon, Indonesia

*Email: emanuellowattimena@gmail.com

Manuscript submitted : August 2023

Accepted for publication : September 2023

doi : <https://doi.org/10.30598/tensorvol4iss2pp53-62>

Abstract: The high rate of deforestation in Indonesia due to forest and land fires (karhutla) is still a problem that requires the government's attention because it has become a regional and global disaster. The worst forest fire incident in Indonesia occurred in 2019, the area of the fire was 1,649,258 ha. Riau Province is one of the provinces in Indonesia that often experiences forest fires. Sipongi noted that an average of 52,986 ha of forest and land burned in Riau Province every year from 2016 to 2020. Thus, this study builds a predictive model for the emergence of hotspots as one of the forest fires that aims to reduce the rate of forest fires. Prediction model built using Long Short-Term Memory Recurrent Neural Network (LSTM-RNN). The modeling is carried out using 2 data scenarios, namely multivariate data and univariate data, where multivariate data uses weather variables as predictors of hotspot frequency, and univariate data is hotspot frequency data. The data used is daily data from 2013-2020. Multivariate scenario dataset that produces RMSE of 23,323 and the correlation between actual and predicted data is 0,675554. The RMSE generated by the multivariate dataset is smaller than the RMSE generated by the model with the univariate dataset scenario, which is 25,750. However, datasets with univariate scenarios produce a larger correlation between actual and predicted values when compared to multivariate dataset scenarios. The addition of weather factors as a predictor of hotspot occurrence can improve model performance, where this model is better at predicting values when compared to univariate dataset scenarios even though the running time is longer.

Keywords: forest and land fire, hotspots, Long Short-Term Memory, Recurrent Neural Network, prediction, time series.

1. Pendahuluan

Indonesia memiliki luas wilayah hutan sebesar 94,1 juta Ha, atau sebesar 50,1% dari total luas darat (Kementerian Lingkungan Hidup dan Kehutanan, 2019). Luas ini menjadikan Indonesia sebagai salah satu negara dengan luas wilayah hutan terbesar di dunia. Namun, luas wilayah hutan di Indonesia terus menerus mengalami penurunan dari tahun ke tahun. Tingkat deforestasi tertinggi di Indonesia terjadi pada tahun 2014-2015, yaitu sebesar 1.091.181,5 ha.

Salah satu penyebab tingginya tingkat deforestasi di Indonesia adalah kebakaran hutan dan lahan (karhutla) yang saat ini telah menjadi bencana regional dan global. Di Indonesia, kebakaran hutan terjadi hampir setiap tahun. Salah satu kejadian karhutla terparah terjadi pada tahun 2019, di mana luas kebakaran yang terjadi adalah sebesar 1.649.258 ha [1]. Provinsi Riau merupakan salah satu provinsi di Indonesia yang sering mengalami karhutla dari tahun ke tahun. Data dari Sipongi mencatat bahwa rata-rata 52.986 ha hutan dan lahan terbakar di Provinsi Riau setiap tahunnya sejak tahun 2016-2020.

Menurut [2], ada 2 faktor yang menjadi penyebab terjadinya kebakaran hutan, yaitu faktor manusia dan faktor alam. Manusia memiliki peranan penting dalam terjadinya kebakaran hutan, di mana manusia dapat menjadi penyebab utama kebakaran hutan, baik yang terjadi karena kecelakaan, kelalaian, atau karena tindakan yang disengaja [3]. Sementara itu, terlepas dari peranan manusia sebagai pelaku kebakaran hutan, alam dan lingkungan juga menjadi penyebab terjadinya kebakaran hutan. Faktor alam, seperti suhu udara yang tinggi, musim kemarau berkepanjangan dan angin yang kencang memiliki peranan penting sebagai penyebab terjadinya karhutla [2].

Di Indonesia, indikasi kejadian kebakaran hutan di Indonesia dapat diketahui dari informasi titik panas atau *hotspot*. Pada tahun 2013, Provinsi Riau menjadi penyumbang titik panas (*hotspot*) terbesar dari 32 provinsi yang ada di Indonesia. Jumlah tersebut setara dengan 26.78% dari total sebaran *hotspot* yang terdeteksi oleh satelit NOAA 18 pada tahun 2013 [4]. Identifikasi kemunculan *hotspot* dapat diperoleh dengan menggunakan penginderaan jarak jauh, yaitu pengolahan data citra stelit seperti *Moderate Resolution Imaging Spectroradiometer* (MODIS) dan *Visible Infrared Imaging Radiometer Suite* (VIIRS) [5].

Salah satu upaya yang dapat dilakukan untuk mengatasi masalah karhutla di Provinsi Riau adalah dengan melakukan prediksi terhadap kemunculan titik panas. Evaluasi untuk menganalisis kemunculan titik panas di Provinsi Riau dapat dilakukan dengan meninjau faktor-faktor yang mempengaruhinya. Dalam melakukan prediksi, salah satu pendekatan yang sering digunakan adalah pendekatan *time-series*. Pendekatan *time series* merupakan model yang memperlihatkan kecenderungan dari data masa lalu yang [6].

Penelitian mengenai prediksi kemunculan titik panas pernah dilakukan oleh [7]. Penelitian ini melakukan prediksi kemunculan titik panas dengan menggunakan 1D *Convolutional Neural Network* dengan menggunakan atribut curah hujan, penyinaran matahari, kecepatan angin maksimum, arah angin, dan kecepatan angin rata-rata sebagai prediktor, dan memperoleh nilai MAAPE sebesar 0,9386 terhadap data harian, dan nilai MAAPE sebesar 0,4397 terhadap data bulanan. Penelitian lain terkait prediksi kemunculan titik panas juga pernah dilakukan oleh [8] dengan menggunakan *Autoregressive Integrated Moving Average* (ARIMA) dan memperoleh MAE sebesar 3,76891, di mana tingkat akurasi dari model ini adalah sebesar

96,23%. Arsitektur *Long-short Term Memory* (LSTM) adalah jenis RNN khusus yang diperkenalkan oleh [9] untuk menghindari masalah *long-term dependency* yang ada pada RNN pada umumnya [10]. Selain itu, LSTM-RNN cocok digunakan untuk melakukan prediksi pada data non- linear dan data yang tidak stasioner [11].

Tambahkan penelitian terkait prediksi titik panas di propinsi Riau, aspek apa saja yang digunakan utk memprediksi.

Merujuk dari penelitian-penelitian terdahulu yang menghasilkan model yang baik, penelitian ini bertujuan untuk membuat model prediksi frekuensi kemunculan titik panas di Provinsi Riau dengan menggunakan algoritme LSTM-RNN dengan menggunakan dua skenario *dataset*, yaitu skenario data univariat dan data multivariat. Data univariat merupakan data frekuensi kemunculan titik panas di Provinsi Riau sejak tahun 2013-2020, sementara data multivariat merupakan data gabungan dari frekuensi kemunculan titik panas data berupa data cuaca sebagai prediktor, yang terdiri dari temperatur maksimum, temperatur minimum, temperatur rata-rata, kelembapan rata-rata, curah hujan, lamanya penyinaran matahari, kecepatan angin maksimum, arah angin saat kecepatan maksimum, kecepatan angin rata-rata dan arah angin terbanyak. Hal ini bertujuan untuk melihat sejauh mana faktor-faktor penyebab kemunculan titik panas dapat mempengaruhi model yang prediksi yang dibuat.

2. Metode Penelitian

2.1. Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah data titik panas VIIRS yang diambil dari FIRMS Nasa dengan wilayah Provinsi Riau dari tahun 2013-2020, dan data cuaca dari 3 stasiun BMKG yang terdapat di Provinsi Riau, yaitu Stasiun BMKG Syarif Kasim II, Stasiun BMKG Japura, dan Stasiun BMKG Kampar. Data dari BMKG diperoleh dengan cara didownload dari (<https://dataonline.bmkg.go.id/>).

Atribut-atribut yang diperoleh dari FIRMS NASA pada Tabel 1 merupakan data titik panas yang kemudian akan digunakan sebagai variabel terikat. Sementara itu, data yang diperoleh dari BMKG pada berupa temperatur minimum, temperatur maksimum, temperatur rata-rata, kelembapan rata-rata, curah hujan, lamanya penyinaran matahari, kecepatan angin maksimum, arah angin saat kecepatan maksimum, arah angin terbanyak dan kecepatan rata-rata, seperti yang ditunjukkan oleh Tabel 2 merupakan variabel-variabel cuaca yang akan digunakan sebagai prediktor.

Tabel 1. Atribut data titik panas

Atribut	Keterangan
LATITUDE	Koordinat lintang lokasi titik panas (°)
LONGITUDE	Koordinat bujur lokasi titik panas (°)
BRIGHT_T14	Temperatur kanal 4 (K)
SCAN	Ukuran lebar piksel citra satelit
TRACK	Ukuran panjang piksel citra satelit
ACQ_DATE	Tanggal kejadian titik panas
ACQ_TIME	Waktu kejadian titik panas
SATELLITE	Satelit yang digunakan (Terra atau aqua)
INSTRUMENT	Instrument yang digunakan (VIIRS)
CONFIDENCE	Kualitas titik panas

VERSION	Versi VIIRS yang digunakan (1)
BRIGHT_T15	Temperatur untuk kanal 5 (K)
FRP	Fire radiative power (MegaWatts)
DAYNIGHT	Waktu pengambilan titik panas (D/N)

Tabel 2. Atribut data cuaca

Atribut	Keterangan
Tn	Temperatur minimum ($^{\circ}C$)
Tx	Temperatur maksimum ($^{\circ}C$)
Tavg	Temperatur rata-rata ($^{\circ}C$)
RH_avg	Kelembapan rata-rata (%)
RR	Curah hujan (mm)
ss	Lamanya penyinaran matahari (jam)
ff_x	Kecepatan angin maksimum (m/s)
ddd_x	Arah angin saat kecepatan maksimum ($^{\circ}$)
ff_avg	Kecepatan angin rata-rata (m/s)
ddd_car	Arah angin terbanyak

2.2. Praproses Data

Praproses data dilakukan dengan mengubah struktur data menjadi data yang siap untuk diolah. Tahapan ini bertujuan untuk merubah struktur data sesuai kebutuhan untuk pemodelan. Praproses data yang akan dilakukan antara lain pengecekan *missing value*, pengecekan format setiap atribut, pembuatan atribut baru, pemisahan dataset dan normalisasi min-max.

2.3. Analisis Time-Series

Sebelum dilakukan pemodelan dengan LSTM, data akan diuji terlebih dahulu kestasionerannya dan autokorelasinya. Kedua uji ini merupakan uji asumsi klasik dalam teori statistika yang digunakan untuk mengetahui apakah perubahan data dari waktu ke waktu bersifat stasioner dan apakah ada korelasi antar waktu dari data.

Dalam penelitian ini, uji stasioneritas dilakukan dengan menggunakan uji akar unit Augmented Dickey-Fuller (ADF) terhadap data volume hasil tangkap dan faktor-faktor yang mempengaruhinya. Data dikatakan stasioner jika *p-value* lebih kecil daripada α yang merupakan taraf nyata atau selang kepercayaan yang digunakan untuk mengetahui peluang kesalahan dalam mengambil keputusan menolak atau menerima hipotesis nol (H_0). Nilai taraf nyata yang digunakan dalam penelitian ini adalah 5% atau 0.05 Sementara itu, uji autokorelasi akan dilakukan dengan menggunakan *Partial Autocorrelation Function* (PACF). Pengujian autokorelasi ini bertujuan untuk menentukan nilai *lag* yang akan digunakan di dalam pemodelan.

2.4. Pembagian Dataset

Data yang telah melalui tahap pra proses dibagi menjadi dua, yaitu data latih dan data uji. Dalam penelitian ini, data tahun 2013-2019 akan digunakan sebagai data latih, sementara data tahun 2020 akan dijadikan

sebagai data uji. Data latih digunakan untuk melakukan pemodelan dengan menggunakan LSTM, sementara data uji digunakan untuk melakukan evaluasi model.

2.5. Pemodelan LSTM dengan Dua Skenario

Dalam penelitian ini, pemodelan akan dilakukan dengan menggunakan 2 skenario data, yaitu data multivariat dan data univariat. Skenario dibuat dengan tujuan untuk memperoleh model terbaik, sekaligus untuk melihat sejauh mana faktor-faktor penyebab kemunculan titik panas berpengaruh terhadap model yang dibuat untuk memprediksi frekuensi kemunculan titik panas di Provinsi Riau.

2.6. Evaluasi Model

Setelah model prediksi dihasilkan, model tersebut akan dievaluasi. Model diuji untuk mendapatkan nilai ketepatan prediksi dari model tersebut. Penelitian ini menggunakan *Root Mean Square Error* (RMSE) dan korelasi sebagai kriteria evaluasi model. Selanjutnya, RMSE dari kedua skenario data akan dibandingkan.

Pada kesimpulan ada aspek waktu yang disinggung. Tapi pada evaluasi mengapa tidak ada running time yang ditampilkan.

3. Hasil dan Pembahasan

3.1. Praproses Data

Tahapan praproses data dalam penelitian ini diawali dengan melakukan seleksi fitur dan proses perhitungan frekuensi titik panas per hari. Perhitungan frekuensi titik panas berdasarkan deteksi titik panas di suatu tempat sesuai dengan waktu kejadian. Data titik panas memiliki atribut yang berisi tanggal kejadian terdeteksi titik panas. Tanggal kejadian titik panas tersebut dihitung dengan mengakumulasi jumlah kemunculannya. Kemudian, data frekuensi per hari tersebut diurut berdasarkan waktu kejadian dimulai dari tanggal 1 Januari 2013 sampai dengan 31 Desember 2020. Plot frekuensi kemunculan titik panas dapat dilihat pada Gambar 1.



Gambar 1. Frekuensi titik panas Provinsi Riau tahun 2013-2020

Setelah melakukan penghitungan frekuensi titik panas, tahapan praproses dilanjutkan dengan

melakukan pemeriksaan dan penanganan *missing value*, seleksi atribut untuk menentukan atribut-atribut yang akan digunakan dalam pemodelan, dan normalisasi data. Pada penelitian ini, ditemukan sejumlah *missing value* pada data cuaca dengan persentase jumlah *missing value* seperti yang ditunjukkan oleh Tabel 3. Karena tipe data yang digunakan merupakan data *time series* dan persentase *missing value* pada setiap atribut tidak terlalu besar, maka penanganan *missing value* dilakukan dengan mensubstitusi *missing value* berdasarkan *centrality tendency* (distribusi nilai), yaitu dengan menggunakan mean.

Tabel 3 Persentase jumlah *missing value* pada *dataset*

Atribut	Persentase <i>missing value</i>
Tanggal	0%
Hotspot	0%
Tn	7%
Tx	5%
Tavg	2%
RH_avg	2%
RR	17%
ss	9%
ff_x	2%
ddd_x	2%
ff_avg	1%
ddd_car	1%

Selanjutnya, setelah mengatasi *missing value* pada data, tahapan praproses selanjutnya adalah membentuk 2 skenario dataset, yaitu dataset multivariat dan dataset univariat. Dataset multivariat merupakan dataset gabungan antara atribut hotspot dan atribut-atribut cuaca sebagai prediktornya, sementara dataset univariat merupakan dataset yang hanya terdiri dari atribut hotspot. Kedua skenario dataset ini yang akan digunakan untuk melakukan pemodelan. Namun, sebelum melakukan pemodelan, lebih dulu data akan dinormalisasi dengan menggunakan normalisasi min-max terhadap kedua dataset. Normalisasi data ini bertujuan untuk menghindari perbedaan rentang nilai yang terlalu jauh di dalam dataset.

3.2. Analisis Time-Series

Karena data yang digunakan merupakan data *time series*, maka perlu dilakukan uji stasioneritas dan uji autokorelasi. Uji stasioneritas dilakukan dengan menggunakan uji akar unit Augmented Dickey-Fuller (ADF) terhadap data volume hasil tangkap dan faktor-faktor yang mempengaruhinya. Data dikatakan stasioner jika *p-value* lebih kecil daripada α yang merupakan taraf nyata atau selang kepercayaan yang digunakan untuk mengetahui peluang kesalahan dalam mengambil keputusan menolak atau menerima hipotesis nol (H_0). Nilai taraf nyata yang digunakan dalam penelitian ini adalah

5% atau 0.05. Hasil uji ADF pada data frekuensi kemunculan titik panas dari tahun 2013-2020 adalah sebagai berikut:

Augmented Dickey-Fuller Test


data: target

Dickey-Fuller = -7.9384, Lag order = 14, p-value = 0.01

alternative hypothesis: stationary

P-value yang diperoleh dari augmented dickey fuller dengan kedua skenario data adalah sebesar 0.01 yang berarti nilai p-value lebih kecil daripada taraf nyata α sebesar 0.05 yang menunjukkan bahwa data sudah stasioner.

Selanjutnya, dilakukan plot *Partial Autocorrelation Function* (PACF) yang bertujuan untuk melihat korelasi antar perubahan waktu dari data. Gambar 2 menunjukkan bahwa lag yang berpengaruh secara signifikan terhadap data adalah lag ke-1. Lag ini menunjukkan bahwa data t dipengaruhi secara signifikan oleh data t-1. Selanjutnya, lag ini akan digunakan untuk menentukan jumlah time steps pada pemodelan LSTM.



Gambar 2. Plot PACF frekuensi titik panas

3.3. Pembagian Data Latih dan Data Uji

Setelah menyelesaikan tahapan analisis time series, selanjutnya kedua skenario data akan dibagi menjadi data latih dan data uji untuk melakukan pemodelan. Data yang digunakan sebagai data latih adalah data dari tahun 2013-2019, sementara data tahun 2020 akan digunakan sebagai data uji.

3.4. Pemodelan dengan LSTM

Penentuan hyperparameter LSTM pada penelitian ini dilakukan dengan menggunakan metode hyperparameter tuning dengan menggunakan grid search. Hyperparameter yang akan digunakan di dalam tahap pemodelan ini dapat dilihat pada Tabel 4, di mana penentuan jumlah node pada input layer tergantung pada jumlah atribut yang digunakan.

Tabel 4. Hasil *hyperparameter tuning*

<i>Hyperparameter</i>	<i>Dataset</i>	
	Multivariat	Univariat
<i>Input layer</i>	1	1
<i>Input node</i>	9	1
<i>LSTM layer</i>	1	1
<i>Hidden node</i>	3	255
<i>Output layer</i>	1	1
<i>Output node</i>	1	1
<i>Learning rate</i>	0,01	0,01
Fungsi aktivasi	Sigmoid	Tanh
<i>Optimizer</i>	Adam	Adam
<i>Dropout rate</i>	0.01	0.1

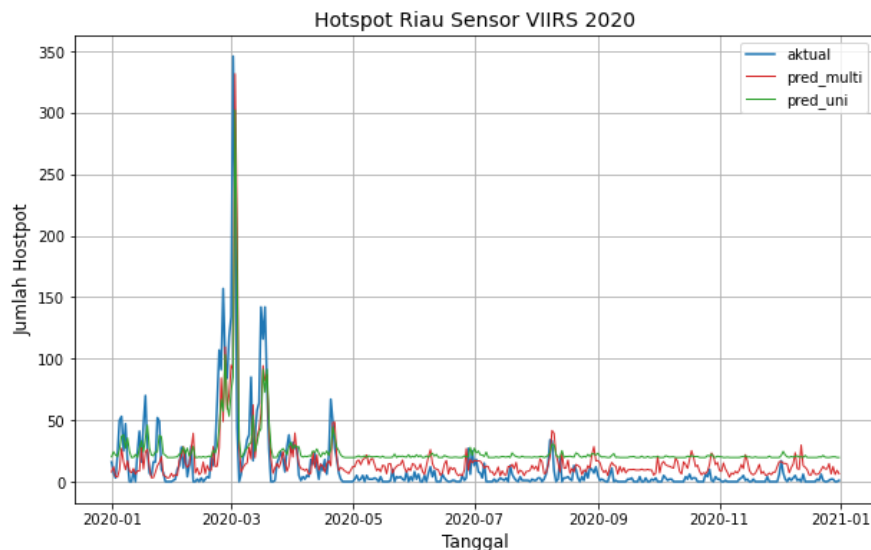
3.5. Evaluasi Model

Setelah model dibuat pada kedua skenario data, model tersebut akan dievaluasi dengan melihat korelasi antara data aktual dan data prediksi pada kedua skenario dataset, dan juga dengan melihat RMSE yang dihasilkan dari kedua model yang dibuat. Nilai RMSE dan korelasi dari kedua skenario dataset dapat dilihat pada Tabel 5. Dataset multivariat menghasilkan nilai RMSE sebesar 23,323 dan korelasi antara data aktual dan data prediksi sebesar 0,675554. Sementara itu, dataset univariat menghasilkan RMSE sebesar 25,750 dan korelasi yang lebih tinggi daripada dataset multivariat, yaitu sebesar 0,684914. Hasil ini menunjukkan bahwa dataset multivariat menghasilkan nilai error yang lebih kecil dibandingkan dataset univariat, namun menghasilkan nilai korelasi yang lebih rendah daripada dataset univariat. Hasil ini berarti penambahan faktor cuaca ternyata mampu menghasilkan model yang lebih baik dibandingkan dengan model prediksi tanpa menggunakan variabel cuaca, walaupun selisih RMSE yang dihasilkan tidak terlalu signifikan.

Tabel 5. Perbandingan Nilai RMSE dan korelasi dari kedua dataset

<i>Dataset</i>	RMSE	Korelasi
Multivariat	23,323	0,675554
Univariat	25,750	0,684914

Selain itu, pemodelan dengan menggunakan data skenario multivariat memiliki performa yang lebih baik daripada data univariat. Perbandingan nilai aktual dan prediksi dari kedua skenario data dapat dilihat pada Gambar 4, di mana plot tersebut menunjukkan bahwa nilai prediksi yang dihasilkan oleh pemodelan dengan menggunakan skenario *dataset* multivariat lebih mampu memprediksi nilai-nilai yang kecil.



Gambar 4 Perbandingan nilai aktual dan prediksi pada skenario data multivariat dan univariat

4. Simpulan dan Saran

4.1. Simpulan

Penelitian ini berhasil meningkatkan performa dari model prediksi kemunculan titik panas di Provinsi Riau dibandingkan dengan penelitian-penelitian terdahulu dengan menggunakan 2 skenario dataset, yaitu dataset multivariat dan dataset univariat. *Dataset* skenario multivariat yang menggunakan variabel cuaca sebagai prediktor menghasilkan RMSE sebesar 23,323 dan korelasi antara data aktual dan data prediksi sebesar 0,675554. RMSE yang dihasilkan oleh *dataset* multivariat lebih kecil jika dibandingkan dengan RMSE yang dihasilkan oleh model dengan skenario *dataset* univariat, yaitu sebesar 25,750. Namun, *dataset* dengan skenario univariat menghasilkan korelasi antara nilai aktual dan nilai prediksi yang lebih besar jika dibandingkan dengan skenario *dataset* multivariat. Melihat perbedaan RMSE dan korelasi dari kedua skenario dataset, dapat disimpulkan bahwa penambahan faktor-faktor cuaca sebagai prediktor kemunculan titik panas dapat meningkatkan performa model, di mana model ini lebih baik dalam memprediksi nilai-nilai yang rendah jika dibandingkan dengan skenario *dataset* univariat walaupun membutuhkan *running time* yang lebih lama.

4.2. Saran

Penelitian ini telah memprediksi frekuensi kemunculan titik panas di Provinsi Riau dengan menganalisis pengaruh faktor cuaca terhadap kemunculannya. Namun, penelitian ini belum melakukan analisis terhadap faktor musiman yang terjadi dalam kurun waktu tertentu, sehingga eksplorasi lebih lanjut diperlukan untuk menganalisis pola dan faktor musiman dari frekuensi kemunculan titik panas.

References

- [1] Sipongi. 2020. Rekapitulasi Luas Kebakaran Hutan dan Lahan (Ha) Per Provinsi Di Indonesia Tahun 2015-2020 [internet]. [diunduh 2020 November 5]. Tersedia pada [http://sipongi.menlhk.go.id/hotspot/luas kebakaran](http://sipongi.menlhk.go.id/hotspot/luas_kebakaran).
- [2] Ganteume A, Camia A, Jappiot M, Miguel-Ayanz JSM, Long-Fournel M, Lampin C. 2013. *A Review of the Main Driving Factors of Forest Fire Ignition Over Europe*. *Environmental Management* (2013) 51. Hal 651-662.
- [3] Henderson M, Kalabokidis K, Marmaras E, Konstantinidis P, Marangudakis M (2005) *Fire and society: a comparative analysis of wildfire in Greece and the United States*. *Hum Ecol Rev* 12(2):169–182.
- [4] [Kemenhut]. 2014. *Statistik Kementerian Kehutanan Tahun 2013*. Jakarta (ID): Kementerian Kehutanan.
- [5] Sepriando A, Hartono, Jatmiko RH. 2019. *Deteksi kebakaran hutan dan lahan menggunakan citra satelit himawari-8 di kalimantan tengah*. *Jurnal Sains dan Teknologi Modifikasi Cuaca*. 20(2):79-89.
- [6] Rizal AA, Soraya S. 2018. *Multi Time Steps Prediction dengan Recurrent Neural Network Long Short-Term Memory*. *Jurnal Matrik*, Vol. 18, No.1, hlm. 115- 124.
- [7] Syarifudin MA, Novitasari DCR, Marpaung F, Wahyudi N, Hapsari DP, Supriyati E, Farida Y, Amin FM, Nugraheni RRD, Ilham, Nariswari R, Setiawan F. 2021. *5th International Conference on Computer Science and Computational Intelligence 2020*. *Procedia Computer Science* 179 (2021). Hl 845-853.
- [8] Slavia AP, Sutoyo E, Witarsyah D. 2019. *Hotspots Forecasting Using Autoregressive Integrated Average (ARIMA) for Detecting Forest Fires*. *IEEE International Conference on Internet of Things and Intelligence System (IoTaIS)*. <https://doi.org/10.1109/IoTaIS47347.2019.8980400>.
- [9] Hochreiter S, Schmidhuber. 1997. *Long Short-Term Memory, Neural Computation*. hlm 1735- 1780.
- [10] Graves A, 2013. *Generating sequences with recurrent neural networks*, arXiv preprint. (2013) arXiv:1308.0850.
- [11] Preeti, Bala R, Singh RP. 2019. *Forecasting Using LSTM Recurrent Neural Network for Short and Long Horizon*. 10th ICCCCNT. Kanpur. India.