

Prediksi Kemunculan Titik Panas Di Lahan Gambut Provinsi Riau Menggunakan *Long Short Term Memory*

Ulfa Khaira ^{1*)}, Muksin Alfalah ², Pikir Claudia Septiani Gulo³, Robi Purnomo⁴
^{1,2,3,4} Program Studi Sistem Informasi, Fakultas Sains dan Teknologi, Universitas Jambi
^{1,2,3,4} Mendalo Darat, Kec. Jambi Luar Kota, Kota Jambi, Jambi 36122
 email: ¹ulfa.ilkom@gmail.com

Abstract – Indonesia is blessed with the largest and most diverse tropical forests in the world. Millions of Indonesians depend on these forests for their lives. But lately forest fires have become an international concern as an environmental and economic issue. One of the causes of the decline in the number of forests is forest fires. Forest fires produce high particle emissions which can endanger human health. For this reason, necessary precautions. One prevention that can be done is to predict the emergence of hotspots, especially in areas where forest fires are frequent. One way to reduce forest fires is to predict the emergence of hot spots on peatlands with the Long Short Term Memory (LSTM) method. This study predicts the emergence of hotspots in Riau Province over the next 6 months, from August 2019 to January 2020. LSTM is able to predict time series with RMSE 363.38.

Abstrak – Indonesia diberkahi dengan hutan tropis terluas dan beraneka ragam hayati di dunia. Jutaan rakyat Indonesia bergantung pada hutan-hutan ini untuk kehidupan mereka. Namun belakangan ini kebakaran hutan menjadi perhatian internasional sebagai isu lingkungan dan ekonomi. Salah satu penyebab menurunnya jumlah hutan adalah kebakaran hutan. Kebakaran hutan menghasilkan emisi partikel tinggi yang dapat membahayakan kesehatan manusia. Untuk itu diperlukan tindakan pencegahan. Salah satu pencegahan yang dapat dilakukan adalah memprediksi kemunculan titik panas, khususnya pada daerah yang sering terjadi kebakaran hutan. Salah satu cara untuk mengurangi kebakaran hutan adalah dengan memprediksi kemunculan titik panas dilahan gambut dengan metode Long Short Term Memory (LSTM). Penelitian ini memprediksi kemunculan titik panas di Provinsi Riau selama 6 bulan ke depan, dari Agustus 2019 hingga Januari 2020. LSTM mampu memprediksi deret waktu dengan RMSE 363.38.

Kata Kunci – Gambut, LSTM, Prediksi, Titik api

I. PENDAHULUAN

Indonesia diberkahi dengan hutan tropis terluas dan beraneka ragam hayati di dunia. Jutaan rakyat Indonesia bergantung pada hutan-hutan ini untuk kehidupan mereka. Manusia membutuhkan hutan sebagai penyedia bahan baku pangan, sandang, dan papan. Hutan juga menyediakan jasa ekosistem seperti pengaturan air, pencegah erosi, dan penyimpan karbon[1]. Namun belakangan ini kebakaran

hutan menjadi perhatian internasional sebagai isu lingkungan dan ekonomi. Salah satu penyebab menurunnya jumlah hutan adalah kebakaran hutan, menurut penelitian [2] dalam periode tahun 2000 hingga tahun 2013 menurunnya jumlah tutupan hutan di lahan gambut Kabupaten Rokan Hilir Riau sebanyak tiga kali lipat dari sebelumnya. Kebakaran hutan menghasilkan emisi partikel tinggi yang dapat membahayakan kesehatan manusia [3].

Provinsi Riau memiliki lahan gambut terluas di Indonesia yaitu 6,5 juta ha. Pada musim kemarau, lahan gambut akan sangat kering sampai kedalaman tertentu dan mudah terbakar[4]. Gambut mengandung bahan bakar (sisa tumbuhan) sampai di bawah permukaan, sehingga api di lahan gambut menjalar secara lambat dan sulit dideteksi serta menimbulkan asap tebal. Api di lahan gambut sulit dipadamkan sehingga bisa berlangsung lama dan hanya bisa mati total setelah adanya hujan yang intensif. Kebakaran hutan dapat menyebabkan pencemaran udara berupa kabut asap, emisi karbon, degradasi, deforestasi yang menyebabkan hilangnya hasil hutan dan kerugian di sektor perekonomian masyarakat pedesaan. Didapatkan kesimpulan bahwa kebakaran hutan dilahan gambut sangat merugikan dan berdampak luas.

Salah satu pencegahan yang dapat dilakukan adalah memprediksi kemunculan titik panas. Titik panas merupakan salah satu indikator dari kebakaran hutan dan lahan[5]. Data titik panas berupa data deret waktu dan mempunyai pola yang berulang setiap periode waktu tertentu. Pantauan NOAA (National Oceanic and Atmospheric Administration) menghasilkan data titik panas dalam bentuk deret waktu. Deep learning sudah menjadi fokus utama dalam data science. Deep learning dapat melakukan ekstraksi pola yang bermakna dari dataset yang besar untuk pengambilan keputusan maupun prediksi.

Salah satu algoritma deep Learning adalah LSTM. LSTM (Long Short Term Memory) adalah metode yang digunakan untuk pemodelan data deret waktu yang merupakan pengembangan neural network. Data yang digunakan sebagai model adalah data titik panas pada lahan gambut di Provinsi Riau pada tahun 2002 sampai dengan tahun 2019 yang di peroleh dari National Aeronautics and Space Administration (NASA). Model prediksi LSTM yang terbaik digunakan untuk melakukan prediksi terhadap kemunculan titik panas dimasa yang akan datang sehingga dapat mencegah terjadinya kebakaran hutan.

*) penulis korespondensi: Ulfa Khaira
 Email: ulfa.ilkom@gmail.com

II. PENELITIAN YANG TERKAIT

Isnar Syaiful Robby dan Imas Sukaesih Sitanggang pada [6] menerapkan metode *Autoregressive Integrated Moving Average* (Arima) untuk memprediksi kemunculan Titik Panas di Provinsi Riau, hasil penelitian menunjukkan model prediksi terbaik Model ARIMA(2,0,0) mempunyai nilai MAPE sebesar 40.974, nilai MAPE tersebut masih cukup besar, hal ini disebabkan oleh data aktual yang sangat tinggi pada bulan Juni, Juli dan Agustus, sehingga menghasilkan selisih error yang tinggi.

Nalar Istiqomah dan Imas Sukaesih Sitanggang pada [7] melakukan penelitian prediksi kemunculan titik panas di Provinsi Riau menggunakan *Seasonal Autoregressive Integrated Moving Average* (Sarima), metode SARIMA digunakan untuk pemodelan data deret waktu musiman. Pemodelan dilakukan pada data kemunculan titik panas perbulan pada periode 2001 sampai 2012 di wilayah Provinsi Riau. Hasil penelitian menunjukkan bahwa model prediksi terbaik adalah ARIMA(1,0,0)(0,1,2)12 dengan nilai mean absolute percentage error (MAPE) terbaik sebesar 0.579 untuk meramal satu bulan ke depan.

Penelitian prediksi temporal untuk kemunculan titik panas di Provinsi Riau menggunakan *Elman Recurrent Neural Network* (ERNN) dilakukan pada tahun 2016, Hasil dari pembelajaran ERNN ini baik dalam memprediksi nilai dengan titik ekstrim data aktual. Hasil pembelajaran menggunakan ERNN dengan arsitektur berdasarkan plot autokorelasi parsial untuk menentukan node lapisan masukan mendapatkan nilai MAPE sebesar 67.54% dan RMSE sebesar 252.98 [8].

III. METODE PENELITIAN

A. Data Penelitian

Data yang digunakan adalah data deret waktu titik panas pada lahan gambut di Provinsi Riau dari Januari 2002 sampai dengan Juli 2019 yang di peroleh dari FIRM MODIS NASA. Untuk mendapatkan lokasi titik panas dilahan gambut, diperlukan sebaran lahan gambut Provinsi Riau yang diperoleh dari Wetland International. Sebaran lahan gambut digambarkan dalam bentuk data spasial. Data spasial adalah data yang memiliki gambaran wilayah yang terdapat di permukaan bumi dipresentasikan dalam bentuk grafik, peta, dan gambar dalam format digital berbentuk shape file. Keseluruhan data spasial menggunakan sistem referensi spatial WGS84. Aspek yang diamati adalah frekuensi titik panas perbulan. Data yang digunakan dalam bentuk data deret waktu yang merupakan suatu rangkaian pengamatan berdasarkan urutan waktu dari satu atau kumpulan kejadian yang diambil dalam periode waktu tertentu.

B. Tahapan Penelitian

Praproses data

Untuk mendapatkan data yang siap untuk digunakan perlu dilakukan praproses data antara lain penentuan AOI, seleksi atribut, perhitungan matriks frekuensi titik panas perbulan dan normalisasi data.

- Penentuan AOI(Area Of Interest)


Penentuan AOI digunakan untuk membatasi wilayah penelitian. Data titik panas lahan Provinsi Riau dalam format SHP dioverlay dengan peta sebaran lahan gambut Provinsi Riau, sehingga di dapatkan data titik panas di lahan gambut Provinsi Riau. Proses Overlay ini dilakukan pada Software Quantum GIS 2.6.0.

- Seleksi atribut

Terdapat 12 atribut titik panas seperti yang disajikan pada Tabel I. Akan dipilih atribut yang dibutuhkan seperti latitude, longitude, acq_date, confidence.

- Perhitungan matriks titik panas

Frekuensi titik panas aktivitas dihitung berdasarkan deteksi titik panas di suatu lokasi sesuai dengan waktu kejadian. Pada proses seleksi dipilih atribut acq_date yaitu tanggal kejadian. Akan dilakukan alur mulai titik panas berdasarkan bulan kejadian. Data frekuensi perbulan diurut berdasarkan waktu kejadian mulai dari bulan Januari 2002 - Juli 2019. Kemudian akan di proses untuk mendapatkan model prediksi kemunculan titik panas beberapa bulan yang akan datang.



Gbr. 1 Tahapan Penelitian

- Normalisasi data

Untuk menghindari nilai yang memiliki rentang nilai besar mendominasi perlu dilakukan normalisasi. Pada Penelitian ini dilakukan proses normalisasi min-max dengan rentang -1 sampai 1. Adapun normalisasi min-max dirumuskan seperti persamaan (1), dimana V' adalah data hasil normalisasi, V nilai yang akan dinormalisasi, Min_A nilai terendah dari data set, Max_A nilai tertinggi dari data set, new_min_A batas nilai minimum normalisasi yang diinginkan, new_max_A nilai maksimum normalisasi yang diinginkan [9].

$$V' = \frac{V - \text{Min}_A}{\text{Max}_A - \text{Min}_A} (\text{new_max}_A - \text{new_min}_A) + \text{new_min}_A \quad (1)$$


Pembagian data

Data titik panas dilahan gambut Provinsi Riau dibagi menjadi dua, yaitu data latih dan data uji. Data tahun 2002 sampai 2014 digunakan sebagai data latih model, sedangkan data 2015 hingga 2019 digunakan sebagai data uji. Data latih digunakan untuk pemodelan algoritma LSTM kemudian model tersebut di uji dengan data testing, akan dilihat akurasi dari model yang dihasilkan.

Pembuatan Model Prediksi Titik Panas Menggunakan LSTM

Long Short Term Memory

Long Short Term Memory networks (LSTM) merupakan sebuah evolusi dari arsitektur RNN, dimana pertama kali diperkenalkan oleh Hochreiter & Schmidhuber. Metode yang digunakan adalah dengan menerapkan Jaringan Syaraf Tiruan atau yang dikenal dengan istilah Neural Network. Jaringan syaraf tiruan memiliki sistem kerja yang menyerupai kerja syaraf di otak manusia. Setiap jaringan memiliki input layer, hidden layer, dan output layer[10]. Model dibangun dengan metode RNN secara bi-directional atau perhitungan bobot pada RNN secara bolak-balik. Jenis variasi RNN yang digunakan adalah LSTM yang memiliki kemampuan untuk mengolah informasi lebih akurat. LSTM memiliki kelebihan daripada sekedar RNN biasa, yaitu adanya arsitektur mengingat dan melupakan output yang akan diproses kembali menjadi input. Selain itu, kemampuan LSTM yang lain adalah dapat mempertahankan *error* yang terjadi ketika melakukan *backpropagation* sehingga tidak memungkinkan kesalahan meningkat.



Arsitektur umum LSTM terdiri dari *forget gate*, *input gate*, *output gate*[12]. *Forget gate* menentukan informasi mana yang akan dihapus dari sel memori. Fungsi aktivasi yang digunakan di *forget gate* adalah fungsi aktivasi sigmoid. Output dari gate ini adalah 0 dan 1. Jika outputnya 1 maka semua data akan disimpan dan jika outputnya 0 maka semua data akan dibuang. Adapun rumus *forget gate* disajikan pada persamaan (2).

$$F_t = \sigma(W_f S_{t-1} + W_f X_t) \quad (2)$$

dengan W_f = bobot dari *forget gate*, S_{t-1} = state sebelumnya atau state pada waktu $t-1$, X_t = input pada waktu t , dan σ = fungsi aktivasi sigmoid.

Pada *input gates* terdapat dua gates yang akan dilaksanakan, pertama akan diputuskan nilai mana yang akan

diperbarui menggunakan fungsi aktivasi sigmoid. Selanjutnya fungsi aktivasi tanh akan membuat vector nilai baru yang akan disimpan pada *memory cell*. Dengan rumus sebagai berikut :

$$I_t = \sigma(W_i S_{t-1} + W_i X_t) \quad (3)$$

$$C_t = \tanh(W_c S_{t-1} + W_c X_t) \quad (4)$$

Dimana W_i bobot dari *input gate* dan W_c adalah bobot pada *cell state*.

Pada *cell gates* akan mengganti nilai pada *memory cell* sebelumnya dengan nilai *memory cell* yang baru. Dimana nilai ini didapatkan dari menggabungkan nilai yang terdapat pada *forget gate* dan *input gate*. Dengan rumus sebagai berikut :

$$c_t = (F_t * c_{t-1} + i_t * C_t) \quad (5)$$

Output gate O_t menghasilkan output (h_t) setelah *memory cell* melewati *forget gate* dan *input gate*. Pada output gates terdapat dua gates yang akan dilaksanakan, pertama akan diputuskan nilai pada bagian *memory cell* mana yang akan dikeluarkan dengan menggunakan fungsi aktivasi sigmoid[13]. Selanjutnya akan ditempatkan nilai pada *memory cell* dengan menggunakan fungsi aktivasi tanh. Terakhir kedua gates tersebut dikalikan sehingga menghasilkan nilai yang akan dikeluarkan.

Dengan rumus sebagai berikut :

$$o_t = \sigma(W_o S_{t-1} + W_o X_t) \quad (6)$$

$$h_t = o_t * \tanh(c_t) \quad (7)$$

Optimizer

Optimizer merupakan salah satu parameter yang dibutuhkan untuk membangun model dalam *package* Keras. *Optimizer* memiliki peranan penting untuk meningkatkan akurasi sebuah model. Beberapa *optimizer* yang terdapat dalam *package* Keras adalah sebagai berikut:

- Adam

Adaptive Moment Estimation (Adam) adalah metode yang menghitung *adaptive learning rate* untuk setiap parameter. Nilai parameter yang direkomendasikan adalah $\beta_1 = 0.9$, $\beta_2 = 0.999$, dan $\epsilon = 10^{-8}$ dengan $\beta_1 = \beta_2$ = tingkat penurunan eksponensial dan ϵ = nilai epsilon untuk *update* parameter[14].

- Adamax

Adamax merupakan jenis Adam yang memiliki norma tak terhingga.

- RMSprop

RMSprop merupakan metode yang mempertahankan moving average dari gradient kuadrat untuk setiap bobot[15].

Pemodelan LSTM

Keluaran dari proses pemodelan ini adalah model yang dapat memprediksi frekuensi kemunculan titik panas. Tahapannya sebagai berikut:

- Inisialisasi parameter

Tahap ini dilakukan inisialisasi parameter yang dibutuhkan, yaitu 1 input layer, 1 hidden layer dengan 4 blok LSTM, 1 output layer dan berbagai jenis optimizer.

- Fungsi aktivasi

Menggunakan fungsi aktivasi sigmoid, jaringan dilatih untuk 100 iterasi dengan batch size = 1.

Evaluasi Model

Evaluasi model dilakukan untuk mendapatkan nilai ketetapan prediksi dari model. Tahapan ini dilakukan dengan cara membandingkan hasil peramalan dengan data aktual, dihitung error menggunakan Root Mean Square Error (RMSE)[16]. Nilai RMSE menunjukkan seberapa besar simpangan nilai prediksi dengan nilai aktualnya. Rumus RMSE dapat dilihat pada persamaan 8.

$$RMSE = \sqrt{\frac{1}{M} \sum_{m=1}^M (X_m - X'_m)^2} \quad (8)$$

Dimana X_m adalah nilai aktual pada waktu ke- m , X'_m adalah nilai prediksi pada waktu ke- m , dan M jumlah data yang diprediksi.

C. Perangkat Penelitian

Perangkat keras yang digunakan dalam penelitian ini adalah komputer personal dengan spesifikasi sebagai berikut:

- Prosesor : Intel® Core™ i3-7100U dual core 2,4 GHz
- RAM : 4 GB
- Memori : 500 GB

Perangkat lunak yang digunakan dalam penelitian ini adalah sebagai berikut:

- Sistem operasi Microsoft Windows 10 (64-bit)
- Jupyter, Bahasa pemrograman Python 3.6, *Package* Keras dan *Backend* Tensorflow untuk membuat model prediksi LSTM.

IV. HASIL DAN PEMBAHASAN

Penentuan AOI (Area Of Interest)

Penentuan AOI digunakan untuk membatasi wilayah penelitian. Data titik panas lahan Provinsi Riau dalam format SHP dioverlay dengan peta sebaran lahan gambut Provinsi Riau, sehingga di dapatkan data titik panas di lahan gambut Provinsi Riau. Proses Overlay ini dilakukan pada Software Quantum GIS 2.6.0.



Gbr.2. Hasil overlay peta lahan gambut dengan titik panas di Provinsi Riau

Seleksi atribut


Komponen utama yang diamati dalam penambangan data ini adalah banyaknya titik panas yang muncul per bulan. Terdapat 12 atribut titik panas seperti yang disajikan pada Tabel I selanjutnya akan dilakukan pemilihan atribut yang dibutuhkan untuk membuat model prediksi. Akan dipilih atribut yang dibutuhkan seperti latitude, longitude, acq_date, confidence. Atribut yang terpilih tersebut akan diproses untuk tahap perhitungan matriks frekuensi titik panas.

TABEL I.
ATRIBUT DATA TITIK PANAS

Atribut	Keterangan
Latitude	Koordinator lintang lokasi titik panas (°)
Longitude	Koordinator bujur lokasi titik panas (°)
Brightness	Temperatur (K)
Scan	Ukuran lebar piksel citra satelit
Track	Ukuran panjang piksel citra satelit
Acq_date	Tanggal kejadian titik panas
Acq_times	Waktu kejadian titik panas
Sattelite	Satelit yang digunakan (Aqua,Terra)
Confidence	Kualitas titik panas (0-100%) 5.0 = MODIS NASA-LANCE
Version	5.1 = MODIS MODAPS-FIRMS
Bright_T31	Temperatur <i>channel-31</i> (K)
FRP	<i>Fire radiative power</i> (Mega Watts)

Perhitungan Matriks titik panas

Hasil perhitungan matriks frekuensi per bulan merupakan banyaknya kemunculan frekuensi kemunculan titik panas setiap bulannya dari bulan Januari 2002 – Juli 2019. Banyaknya kemunculan titik panas per bulan yang diambil adalah yang memiliki confidence $\geq 70\%$.



Gbr.3. Plot data frekuensi titik panas Provinsi Riau per bulan dari bulan Januari 2002 sampai bulan Juli 2019

Normalisasi Data

Setelah membuat matriks frekuensi titik panas per bulan, data dinormalisasi menggunakan normalisasi *min-max*. Contoh hasil normalisasi data titik panas per bulan di Provinsi Riau dapat dilihat pada Tabel II. Data yang telah dinormalisasi memiliki rentang nilai -1 sampai 1.

TABEL II.
CONTOH DATA HASIL NORMALISASI TITIK PANAS PER BULAN DI PROVINSI RIAU

Tahun	Bulan	Data sebelum dinormalisasi	Data sesudah di normalisasi
2002	1	189	-0.96
2002	2	1757	-0.64
2002	3	1249	-0.74
2002	4	50	-0.99
2002	5	72	-0.98
2002	6	100	-0.98

Pemodelan LSTM

Inisialisasi parameter-parameter yang dilakukan dalam pemodelan dapat dilihat pada Tabel III.

TABEL III.
STRUKTUR LSTM

Atribut	Keterangan
Arsitektur	1 input layer
	1 hidden layer dengan 4 blok LSTM
	1 output layer
Fungsi aktivasi	Sigmoid
Optimizer	Adam

Percobaan dilakukan beberapa kali dengan mencoba beberapa optimizer yang ada di dalam package Keras. Optimizer yang digunakan adalah Adam, Adamax, dan RMSprop. Optimizer Adam menggunakan nilai learning rate 0.001. Optimizer Adamax menggunakan nilai learning rate 0.002, sedangkan

optimizer RMSprop menggunakan nilai learning rate 0.001. Data yang diuji adalah data titik panas dari tahun 2015 sampai dengan tahun 2019.


Analisis

Percobaan dilakukan dengan menggunakan epoch = 100, *Optimizer* yang digunakan adalah Adam, Adamax, dan RMSprop. Tabel IV dibawah ini menunjukkan hasil prediksi frekuensi kemunculan titik panas di lahan gambut dengan menggunakan beberapa optimizer. Dalam percobaan yang dilakukan menggunakan *optimizer* Adam didapatkan hasil RMSE sebesar 363.38, *optimizer* Adamax didapatkan RMSE sebesar 471.647 dan *optimizer* RMSprop didapatkan RMSE 751.

TABEL IV.
HASIL PREDIKSI FREKUENSI KEMUNCULAN TITIK PANAS

Nilai Aktual	Prediksi		
	Adam	Adamax	RMSProp
441	1241	1571	1170
663	504	725	572
289	651	903	747
34	410	633	557
56	254	487	430
87	280	539	468
127	301	575	502
536	318	604	539
435	577	873	804
129	488	754	761
174	272	523	592

Berdasarkan Gbr. 5, pemodelan tersebut sudah mendekati nilai aktual, namun belum bisa memprediksi nilai yang sangat tinggi dari pola kejadian. Berdasarkan nilai ketepatan prediksi, yaitu RMSE dapat dilihat bahwa hasil terbaik dihasilkan dari pemodelan dengan parameter *optimizer* Adam dengan *learning rate* 0.001. RMSE dari hasil prediksi menggunakan *optimizer* Adam bernilai lebih kecil dibanding *optimizer* lainnya.




Gbr. 4 Plot hasil prediksi titik panas

Dengan menggunakan model prediksi terbaik yang dihasilkan pada tahapan sebelumnya, akan dilakukan prediksi

kemunculan titik panas di Provinsi Riau untuk 6 bulan ke depan yaitu bulan Agustus 2019 sampai Januari 2020.

dapatkan hasil LSTM dengan *optimizer* Adam lebih baik dengan RMSE 363.38.



Gbr. 5 Plot data aktual, data prediksi uji dan data prediksi 6 bulan ke depan

Gbr. 6 menunjukkan plot data aktual, data prediksi testing dan data hasil prediksi untuk 6 bulan ke depan. Dapat dilihat bahwa pada data aktual ada beberapa nilai ekstrim yaitu pada Februari 2005 sebanyak 7982 titik panas, bulan Juni 2013 sebanyak 8108 titik panas, bulan Februari 2014 sebanyak 8404 titik panas, bulan Maret 2014 sebanyak 9795 titik panas. Sejak Januari 2015 hingga Juli 2019 tidak terdapat nilai yang ekstrim.

Dari Tabel V dapat dilihat nilai prediksi tertinggi pada bulan Oktober 2019 sebanyak 1267 titik panas dan nilai prediksi terendah pada bulan Januari 2020 sebanyak 119 titik panas.

TABEL V.
HASIL PREDIKSI KEMUNCULAN TITIK PANAS DI
PROVINSI RIAU 6 BULAN KE DEPAN

Bulan	Prediksi
Agustus 2019	214
September 2019	721
Oktober 2019	1267
November 2019	132
Desember 2019	161
Januari 2020	119

V. KESIMPULAN

Pemodelan LSTM ini cukup baik dalam memprediksi nilai aktual, akan tetapi belum baik untuk memprediksi jumlah titik panas yang terjadi pada bulan yang memiliki nilai ekstrim. Perbandingan hasil prediksi LSTM dengan menggunakan berbagai *optimizer* Adam, Adamax dan RMSProp di

DAFTAR PUSTAKA

- [1] B. Locatelli, M. Brockhaus, M. Colfer, CJP Murdiyarso and H. Santoso., *Menghadapi masa depan yang tak pasti: bagaimana hutan dan manusia beradaptasi terhadap perubahan iklim*. Bogor: Center for International Forestry Research (CIFOR), 2009.
- [2] U. Khaira, I. S. I. S. Sitanggang, and L. Syaufina, "Detection and Prediction of Peatland Cover Changes Using Support Vector Machine and Markov Chain Model," *TELKOMNIKA (Telecommunication Comput. Electron. Control.*, vol. 14, no. 1, p. 294, 2016.
- [3] W. C. Adinugroho, I. N. N. Suryadiputra, B. H. Saharjo, and L. Siboro, *Pengendalian Kebakaran Hutan*. Bogor: Wetlands International- Indonesia Programme dan Wildlife Habitat Canada, 2005.
- [4] R. Sahputra, S. Sutikno, and A. Sandhyavitri, "Mitigasi Bencana Kebakaran Lahan Gambut Berdasarkan Metode Network Analysis Berbasis GIS (Studi Kasus: Pulau Bengkalis)," *J. Online Mhs. Fak. Tek. Univ. Riau*, vol. 4, no. 2, pp. 1–11, 2017.
- [5] I. S. Sitanggang, S. Kirono, and L. Syaufina, "Temporal Patterns of Hotspot Sequences for Early Detection of Peatland Fire in Riau Province," in *Proceedings - 2018 IEEE Asia-Pacific Conference on Geoscience, Electronics and Remote Sensing Technology: Best Practice for Disaster Mitigation using Geoscience, Electronic, and Remote Sensing, AGERS 2018*, 2018.
- [6] I. S. Robby and I. S. Sitanggang, "Temporal Predictions For Emerging Hotspots in Riau Province Using Autoregressive Integrated Moving Average (ARIMA)". Essay. Natural Sciences, Bogor Agricultural University, 2014.
- [7] N Istiqomah and I. S. Sitanggang "Prediksi Kemunculan Titik Panas Di Provinsi Riau Menggunakan Seasonal Autoregressive Integrated Moving Average (SARIMA)", Skripsi, Institut Pertanian Bogor, 2015.
- [8] A. T. Tsalsa and M. A. Agmalaro. "Prediksi Temporal Untuk Kemunculan Titik Panas Di Provinsi Riau Menggunakan Elman Recurrent Neural Network." Skripsi. Fakultas Matematika dan Ilmu Pengetahuan Alam. Institut Pertanian Bogor: Bogor, 2016.
- [9] J. Y. Kumar and B. S. Kumar, "Min max normalization based data perturbation method for privacy protection," *Int. J. Comput. Commun. Technol.*, vol. 2, no. 8, pp. 45–50, 2011.
- [10] J. Schmidhuber, "Deep learning in neural networks: An overview," *Neural Networks*, vol. 61, pp. 85–117, Jan. 2015.
- [11] C. Olah, "Understanding LSTM Networks." Internet: <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>, 2015.
- [12] XINGJIAN, S. H. I., et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting. In: *Advances in neural information processing systems*. p. 802-810. 2015.
- [13] MA, Xiaolei, et al. Long short-term memory neural network for traffic speed prediction using remote microwave sensor data. *Transportation Research Part C: Emerging Technologies*, 54: 187-197, 2015.
- [14] D. P. Kingma and J. L. Ba, "Adam: A method for stochastic optimization," in *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, 2015.
- [15] Vitaly Bushaev, "Understanding RMSprop - Faster Neural Network Learning." Internet: <https://towardsdatascience.com/understanding-rmsprop-faster-neural-network-learning-62e116fcf29a>, Sept. 12, 2018 [Nov. 29, 2019]
- [16] T. Chai and R. Draxler. "Root mean square error (RMSE) or mean absolute error (MAE)?—Arguments against avoiding RMSE in the literature." *Geoscientific model development.* vol.7, no. 3, pp.1247–1250, 2014.