

HYPERPARAMETER MODEL LSTM-GRU UNTUK PREDIKSI PEMETAAN TINGKAT KEBAKARAN HUTAN

Fahrizal Maulana¹⁾, Kusri²⁾

^{1, 2} Magister PJJ Informatika Program Pascasarja, Universitas Amikom Yogyakarta, Jl. Ring Road Utara, Ngringin,
Condongcatur, Kec. Depok, Kabupaten Sleman, Daerah Istimewa Yogyakarta

Co Responden Email: fahrizalmaulana@students.amikom.ac.id

Abstract

Article history

Received 29 Nov 2024

Revised 14 Dec 2024

Accepted 02 Jan 2025

Available online 31 Jan 2025

Keywords

Hyperparameter,
RNN Combination,
Wild Fire,
Performance Regression,
Data Interpolation

Forest fire disaster is a major problem for the Central Kalimantan provincial government. External and internal steps have been taken through public policies made in the form of prediction results or mapping of forest fires in the future. In this study, a model was developed for trend prediction and mapping of forest fire levels with a focus on the application of hyperparameters to the combination of RNN in two devices and different dataset ratio settings. The dataset used is a combination of MODIS and Merra2 datasets as end-to-end multivariate features and targets. The dataset combination uses the interpolation principle to support the continuity of data gaps. To achieve the research objectives, 12 experimental scenarios were conducted on 6 sets of hyperparameter settings with evaluation using MAE and RMSE regression performance. The research findings show that the LSTM-GRU combination model consistently obtains an average MAE error of 2% and RMSE of 6% on P1 and P2 with the best learning loss performance values in scenarios 7, 10, 11 for the division of the two datasets and scenario 8 in a dataset ratio of 70:30. Testing on different devices also does not affect the reduction in error in the model against the application of hyperparameters except for the length of the model learning runtime. The results of this study provide a comprehensive overview of parameter selection for ideal RNN model combinations based on dataset ratio division and provide an understanding of the application of hyperparameters on different devices.

Abstrak

Riwayat

Received 29 Nov 2024

Revised 14 Des 2024

Accepted 02 Jan 2025

Available online 31 Jan 2025

Kata Kunci

Hyperparameter,
Kombinasi RNN,
Kebakaran Hutan,
Multivariat Data,
Data Interpolasi

Bencana kebakaran hutan merupakan permasalahan besar bagi pemerintah provinsi Kalimantan Tengah. Langkah eksternal maupun internal telah dilakukan melalui kebijakan publik yang dibuat berupa hasil prediksi atau pemetaan kebakaran hutan dimasa akan datang. Dalam penelitian ini dilakukan pengembangan model untuk prediksi tren dan pemetaan tingkat kebakaran hutan dengan fokus penerapan *hyperparameter* terhadap kombinasi RNN di dua perangkat dan pengaturan rasio dataset berbeda. Dataset yang digunakan merupakan penggabungan dataset MODIS dan Merra2 sebagai *end-to-end multivariate* fitur dan target. Penggabungan dataset menggunakan asas interpolasi untuk mendukung kontinuitas kekosongan data. Untuk mencapai tujuan penelitian dilakukan eksperimental sebanyak 12 skenario terhadap 6 set pengaturan *hyperparameter* dengan evaluasi menggunakan performansi regresi MAE dan RMSE. Temuan penelitian menunjukkan model kombinasi LSTM-GRU konsisten memperoleh rata-rata *error* MAE 2% dan RMSE 6% pada P1 dan P2 dengan nilai performa *loss* pembelajaran terbaiknya berada pada skenario 7, 10, 11 untuk pembagian kedua dataset dan skenario 8 di rasio dataset 70:30. Pengujian di perangkat berbeda juga tidak mempengaruhi penurunan *error* pada model terhadap penerapan *hyperparameter* kecuali lama *runtime* pembelajaran model. Hasil penelitian ini memberikan gambaran yang komprehensif terhadap pemilihan parameter terhadap kombinasi model RNN yang ideal berdasarkan pembagian rasio dataset serta memberikan pemahaman tentang penerapan *hyperparameter* pada perangkat berbeda.

PENDAHULUAN

Kebakaran hutan merupakan bencana alam tahunan yang sering terjadi di sejumlah provinsi yang ada di Indonesia (SINDO News, 2023) khususnya pada tahun 2023 berdasarkan data KLHK menyebutkan 7 provinsi yang memiliki status siaga (PPID KLHK, 2023). Provinsi Kalimantan Tengah sepanjang bulan Januari hingga Oktober 2023 terjadi sebanyak 3.436 kejadian kebakaran dengan total lahan terbakar sebesar 9.768 hektar area dan titik sebarannya 45.611 hotspot yang tersebar di beberapa daerah kabupaten Saruyan, Barito Selatan, Kotawaringin, Palangkaraya, Pulang Pisau dan Kapuas (Rini Rahayu, 2023).

Bencana kebakaran ini merupakan permasalahan besar bagi pemerintah provinsi Kalimantan Tengah untuk diatasi dengan cara melakukan hal preventif terhadap daerah-daerah yang rawan terjadinya kebakaran hutan. Langkah eksternal maupun internal yang saling menopang antar keduanya dapat dilakukan seperti kegiatan sosialisasi, memberikan himbuan langsung ke Masyarakat yang bekerjasama dengan pemangku kepentingan dan organisasi terkait terhadap pentingnya pencegahan kebakaran serta melakukan kanalisasi Kawasan hutan (Hema Yurismi et al., 2022) yang landasan dasarnya dapat berupa hasil dari prediksi dan pemetaan kebakaran hutan dimasa akan datang melalui indikator tingkat kebakaran hutan yang ada diseluruh daerah di provinsi Kalimantan Tengah dari waktu ke waktu. Sehingga data prediksi pemetaan tersebut dapat dijadikan acuan membuat kebijakan untuk melakukan pencegahan kebakaran hutan.

Penelitian tentang prediksi kebakaran hutan yang telah dilakukan oleh masing-masing peneliti (Listia Rosa et al., 2022) pada tahun 2022 dan (Kadir et al., 2023) di tahun 2023 memberikan hasil yang beragam terhadap evaluasi LSTM sebagai metode terapan untuk memprediksi data deret waktu. Kedua peneliti tersebut memberikan penjelasannya dalam penelitian di masa depan bahwa dengan memperkecil wilayah serta menerapkan model lain (Dhake et al., 2023) akan berpengaruh terhadap performa kinerja model dan hasil prediksi. Dalam konteks hasil prediksi peneliti lain menggunakan data cuaca sebagai data input untuk membangun model

varian LSTM (Dzulhijjah et al., 2023) yang di adaptasi atau dikorelasikan dengan dataset lainnya (Chen et al., 2023; H. Zhang et al., 2022) sehingga menjadi landasan yang kuat terhadap faktor-faktor dari hasil prediksi kebakaran hutan.

Namun pada penelitian-penelitian yang sudah disebutkan diatas menyarankan harus masih dilakukan penurunan pengurangan persentase *error* saat evaluasi model serta meningkatkan performa kinerja saat pelatihan model (Dzulhijjah et al., 2023; Kadir et al., 2023; Listia Rosa et al., 2022). Mengatasi tantangan tersebut dengan menerapkan penyetelan parameter atau disebut dengan *hyperparameter*. Seperti penggunaan varian dataset kebakaran MODIS sebanyak 154.277 baris data melakukan pengaturan parameter *batch size*, *activation layer*, optimizer, *units neuron* dan penambahan *layer* konvolusi (*hidden layer*) (Dhake et al., 2023), *loss function*, *epoch* berdasarkan pertimbangan data kondisi cuaca di Beijing sebanyak 43.825 kejadian (Mao et al., 2022), *learning rate*, *dropout* dengan jumlah data 1.450 kejadian kebakaran di daerah Pakistan (Jamshed et al., 2022) yang rata-rata memberikan keterangan dalam kesimpulannya mampu meningkatkan variasi penurunan *error* pada metode LSTM. Hal serupa juga dilakukan oleh (Samadi Miandoab et al., 2023) menerapkan *hyperparameter* terhadap model LSTM dan GRU dengan menambahkan parameter yang sangat kompleks diantaranya parameter *unit hidden layers*, *activation function*, *output layer*, *input* dan *output slide windowing* juga mampu melakukan peningkatan yang signifikan terhadap metode pembandingan lainnya.

Oleh karena itu diangkatlah penelitian tentang prediksi tren dan pemetaan tingkat kebakaran hutan di Kalimantan Tengah dengan menerapkan *hyperparameter* terhadap arsitektur *recurrent neural network* (RNN) LSTM dan GRU (LSTM-GRU) yang mana kombinasi layer bermanfaat secara efektif menangkap pola dan hubungan kompleks dalam data (Dzulhijjah et al., 2023) dengan menggunakan dataset yang dikorelasikan dengan data cuaca Merra2 sebagai *end-to-end* multivariate data. Dalam penelitian ini berfokus untuk meningkatkan penurunan *error* dan performa saat evaluasi model dengan

bersandar pada *set* penyetelan *hyperparameter* dan pembagian dataset terhadap setiap pelatihan model guna mencari data yang representatif dari prediksi tren dan pemetaan tingkat kebakaran hutan di Kalimantan Tengah serta validitas *hyperparameter* terhadap *machine* (perangkat komputer) yang berbeda.

METODE PENELITIAN

Metodologi dalam penelitian ini diantaranya melakukan pengumpulan data sebagai dataset yang akan digunakan, melakukan prapemrosesan data agar data bisa dilanjutkan pada tahapan pelatihan dan pengujian sesuai format yang di kehendaki. Selanjutnya melakukan pengolahan data menggunakan metode algoritma yang telah ditentukan sesuai dengan skenario eksperimental. Tahapan akhir dari metodologi penelitian ini adalah mengevaluasi dan menganalisis hasilnya.

A. Pengumpulan Dataset

Data penunjang untuk melakukan penelitian ini menggunakan penggabungan 2 dataset yakni MCD14DL merupakan data kebakaran MODIS koleksi 6.1 dan M2T1NXFLX dari Merra2 sebagai data cuaca. Kurun waktu yang diambil dari kedua dataset antara tahun 2014 - 2020. Variabel-variabel M2T1NXFLX yang dipilih dan dianggap penting dalam keterkaitannya terhadap tingkat kepercayaan kebakaran (*confidence*) yaitu temperatur suhu (TSH), curah hujan (PRECTOTCORR) evaporasi (EVAP), kelembapan (QLML), kecepatan angin (SPEED) yang dijelaskan pada Tabel 1 setiap rincian dari multi variabel fitur dan target. Masing-masing dataset didapatkan dari website (FIRMS Fire Information for Resource Management System, n.d.; GES DISC, n.d.).

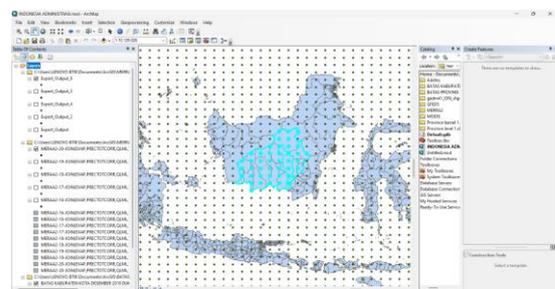
Tabel 1. Pemilihan Variabel

MCD14DL		
Variabel	Definisi	Satuan
<i>confidence</i>	<i>Quality of individual fire pixels. The confidence value ranges from 0% to 100%</i>	<i>Percent</i>
M2T1NXFLX		
TSH	<i>effective surface skin temperature</i>	<i>K</i>
PRECTOTCORR	<i>bias corrected total precipitation</i>	<i>kg m-2 s-1</i>
EVAP	<i>evaporation from turbulence</i>	<i>kg m-2 s-1</i>
QLML	<i>surface specific humidity</i>	<i>1</i>
SPEED	<i>surface wind speed</i>	<i>m s-1</i>

B. Prapemrosesan

Proses penyiapan data yang dilakukan dalam penelitian ini penuh tantangan dan sangat melelahkan. Langkah-langkah pembersihan data yang ditempuh diantaranya membagi data asli dari kedua dataset ke dalam beberapa sub bagian dikarenakan setiap file memiliki jumlah data jutaan terutama dataset M2T1NXFLX yang merupakan data cuaca global. Setelah itu melakukan arsir data spasial dalam hal ini *latitude* dan *longitude* ke wilayah Kalimantan Tengah. Selanjutnya dilakukan penggabungan data tahunan terhadap masing-masing dataset agar dapat dilakukan kembali arsir ke wilayah teritorial setiap kabupaten yang tertuang pada Tabel 2. Setelah melakukan pengerucutan data spasial ke masing-masing arsir wilayah yang fokus pengolahannya menggunakan aplikasi pemetaan Arcgis seperti yang terlihat pada Gambar 1.

Proses selanjutnya melakukan penggabungan kedua dataset berdasarkan data temporal tanggal kejadian setiap teritorial wilayah administrasi kabupaten.



Gambar 1. Arsir Wilayah Menggunakan Arcgis 10.8

Penggabungan dataset dilakukan dengan mempertimbangkan asas interpolasi (W. Zhang et al., 2023) dikarenakan setiap kejadian rekaman antar dataset berbeda terutama data kejadian MODIS lebih banyak

dibandingkan dataset Merra2 sehingga memungkinkan terjadinya data yang kosong maka perlunya hal tersebut dilakukan.

Tabel 2. Arsir Wilayah

Kabupaten	MCD14DL	M2T1NXFLX
Palangkaraya	4019	80
Pulang Pisau	17510	160
Katingan	8748	320
Kotim	11883	480
Kobar	4252	240
Barut	1555	160
Barsel	3571	80
Bartim	1057	80
Kapuas	12030	400
Gumas	1753	240
Lamandau	1949	160
Sukamara	3559	80
Saruyan	9269	320
Murung Raya	1793	588

Penggabungan dataset dilakukan dengan 2 tahapan. Tahapan pertama melakukan *spatial matching* berdasarkan wilayah kabupaten dan konversi data nilai temperature *kelvin* ke satuan *celcius*. Selanjutnya melakukan *temporal matching* yaitu proses interpolasi berbasis tanggal kejadian kebakaran MODIS sebagai acuan penggabungan untuk mengisi data yang kosong pada variabel cuaca Merra2 sehingga kontinuitas data terjaga dimana teori perhitungannya dijelaskan pada Persamaan 1.

$$y = y_1 + \frac{(t+t_2)}{(t_1+t_2)} \times (y_2 - y_1) \quad (1)$$

Keterangan:

y = data kejadian yang hilang

y1 = data kejadian sebelumnya

y2 = data kejadian sesudahnya

t = waktu kejadian

t1 = waktu kejadian sebelumnya

t2 = waktu kejadian sesudahnya

Setelah itu menghapus data kejadian jika *confidence* bernilai 0. Adapun pada tahapan kedua yaitu melakukan penggabungan keseluruhan dataset dari tahapan pertama lalu dilakukan agregasi rata-rata yang dituliskan pada Persamaan 2 berdasarkan pengelompokan tanggal kejadian yang mana jumlah akhir sebanyak 4828 baris data.

$$Mean_t = \frac{\sum_{i=1}^{n_t} x_i}{n_t} \quad (2)$$

Keterangan:

$Mean_t$ = nilai rata-rata *group* tanggal kejadian

x_i = nilai setiap tanggal kejadian

n_t = jumlah kejadian dalam *group* tanggal

Tahapan akhir dari prapemrosesan penyajian data adalah melakukan skala matrik menggunakan *MinMax Scalar* terhadap semua nilai fitur termasuk variabel target yang dijelaskan pada Persamaan 3 untuk perhitungannya serta menyiapkan *sequence input (slide windowing)* dengan panjang *slide* yang ditetapkan untuk setiap inputan model adalah 10.

$$X' = \frac{(X - X_{min})}{(X_{max} - X_{min})} \quad (3)$$

Keterangan:

X' = hasil normalisasi *MinMax Scalar*

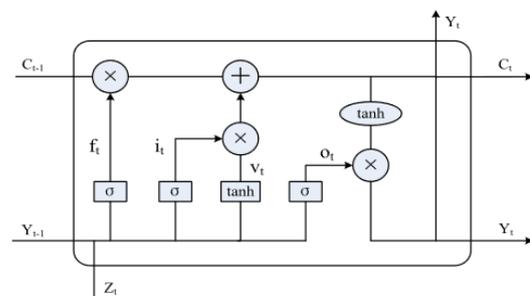
X = nilai asli pada kolom fitur

X_{min} = nilai minimum pada kolom

X_{max} = nilai maksimum pada kolom

C. Pemodelan

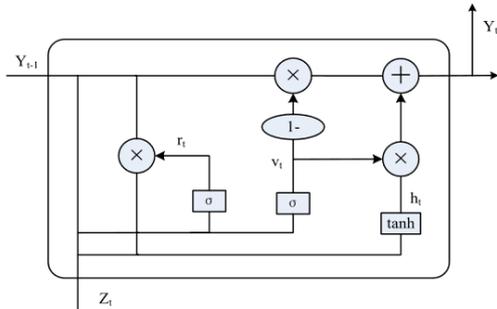
Terkait dengan pemilihan kombinasi model. *Long Short-Term Memory* adalah varian dari RNN. Model LSTM terdiri dari beberapa siklus, di mana informasi masa lalu disimpan dengan memperbarui informasi status neuron (Zeng et al., 2022). Proses ini dilakukan dengan menggunakan gerbang input, gerbang output, dan gerbang pelupaan (*forgetting gates*) untuk mengontrol aliran informasi yang dapat dilihat pada Gambar 2. Dengan struktur ini, LSTM mempertahankan informasi penting dari input sebelumnya untuk jangka waktu yang lebih lama, yang sangat berguna dalam aplikasi yang memerlukan pemahaman konteks dari data sekuensial.



Gambar 2. Arsitektur LSTM (Chen et al., 2023)

Sama halnya dengan LSTM yang dirancang untuk mengatasi masalah seperti ledakan gradien dan hilangnya gradien dalam jaringan saraf berulang. GRU memiliki

struktur yang lebih sederhana dibandingkan dengan LSTM karena menggabungkan gerbang *forget* dan gerbang input menjadi satu gerbang yang disebut *update gate* yang terlihat pada Gambar 3. Dengan mengurangi jumlah gerbang dan melakukan perkalian matriks yang lebih sedikit, GRU dapat menghemat banyak waktu pelatihan, terutama ketika data pelatihan besar.



Gambar 3. Arsitektur GRU (Chen et al., 2023)

Tidak hanya pengaturan parameter dari model, pengembangan model dalam penelitian ini juga menerapkan pengaturan rasio dataset yang berbeda pada masing-masing *hyperparameter* yang ditetapkan yakni pada rasio 80:20 dan 70:30 dimana pada data validasi dan *test* dibagi lagi menjadi 50:50. Perbedaan lingkungan pengujian ditujukan untuk melakukan validasi konsistensi terhadap hasil penerapan *hyperparameter* dalam pengembangan model. Semua skenario eksperimental pada penelitian ini di deskripsikan pada Tabel 3.

Tabel 3. Set *Hyperparameter*

Units	128, 64, 32, 16					
Activation	Relu					
Hidden	4					
Optimizer	Adam					
Loss	MSE					
Epoch	50					
Learning rate	0.001					
Batch size	32	64	128	32	64	128
Dropout	0.01	0.01	0.01	0.02	0.02	0.02
Set	1	2	3	4	5	6

D. Prediksi

Setelah model dilatih berdasarkan skenario eksperimental proses selanjutnya menguji model untuk memprediksi tren dan pemetaan tingkat kebakaran tahun 2020 dengan membandingkan hasil prediksinya terhadap data aktual.

E. Evaluasi

Langkah selanjutnya melakukan evaluasi dari dua sisi yakni evaluasi terhadap pelatihan model menggunakan pengukuran performansi regresi meliputi MAE dan RMSE serta mempertimbangan nilai *loss* dan *runtime* setiap pelatihan model. Evaluasi kedua bersifat deskriptif terhadap hasil prediksi pemetaan tingkat kebakaran dengan membandingkan data aktualnya.

HASIL DAN PEMBAHASAN

Pada bagian ini akan memaparkan hasil keseluruhan pengujian pengembangan model yang dilakukan sebanyak 12 skenario pengujian terhadap 6 set *hyperparameter* di dua perangkat berbeda yakni perangkat pertama (P1) Windows 11 Intel Core i7 Gen 12, 3.4 GHz, 64-bit, 16 GB dan perangkat kedua (P2) dengan spesifikasi komputer Windows 11 Intel Core i5 Gen 11, 2.40 GHz, 64-bit, 8 GB terhadap model LSTM-GRU, GRU-LSTM, LSTM dan GRU untuk menilai hasil performa regresi, *loss* serta *runtime* yang digambarkan berupa grafik pada Gambar 4 dan 5.

A. Hasil Performa Regresi

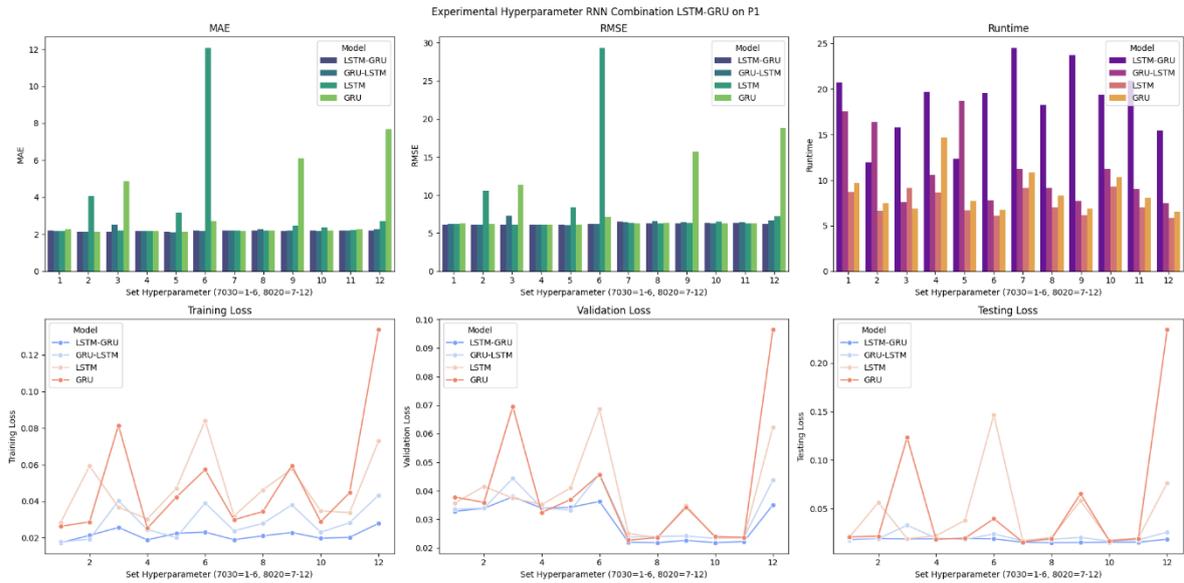
Hasil performa regresi keseluruhan model LSTM-GRU dan GRU-LSTM pada pengujian di P1 memperoleh nilai rata-rata MSE 2% dan RMSE 6%. Sedangkan LSTM dan GRU tidak konsisten dalam memperkecil nilai *error* dari model yang dibangun terlihat pada skenario ke-6 metode LSTM sangat “anjlok” tingkat *error* yang diperoleh dalam membangun model begitu juga metode GRU pada skenario 12. Serupa yang diperoleh pada pengujian di P1. Pada pengujian di P2 metode LSTM dan metode GRU juga tidak menunjukkan performa stabil terlihat pada skenario ke-9 untuk metode GRU dan ke-12 metode LSTM memperoleh tingkat *error* yang sangat tinggi. Sedangkan metode kombinasi masih memperoleh nilai *error* yang rendah dibawah 8%.

B. Hasil Loss

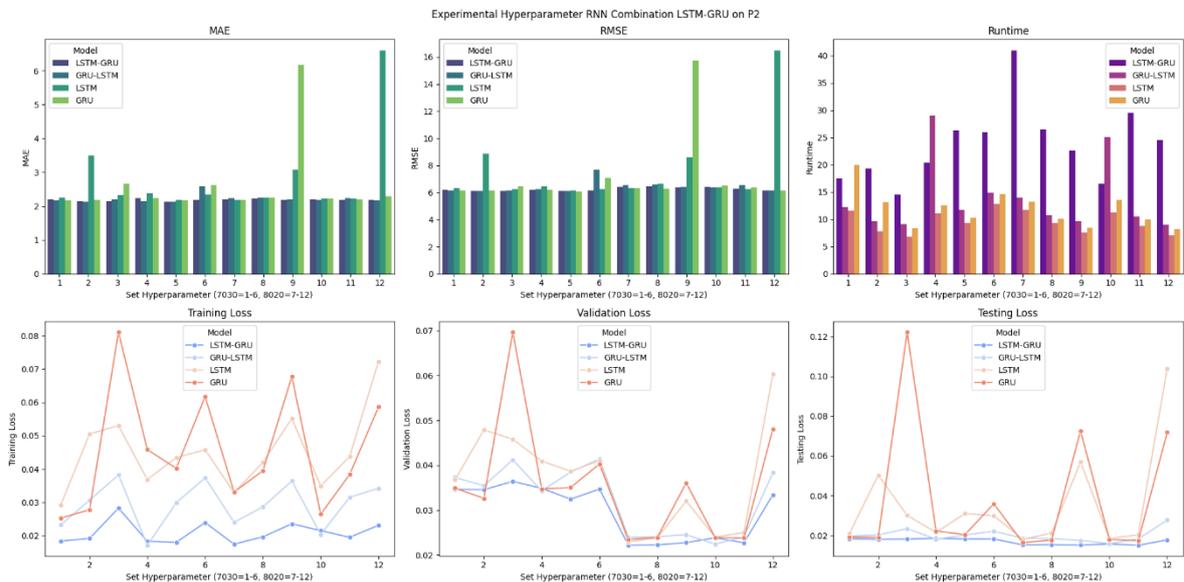
Umumnya metode kombinasi LSTM-GRU dan GRU-LSTM memperoleh *training loss* terendah dibandingkan rata-rata performa model lainnya saat melakukan pembelajaran model baik pada P1 dan P2 di seluruh skenario. Namun pada pembagian dataset 70:30 nilai *validation loss* meningkat drastis dibandingkan rasio 80:20 yang mampu

mengimbal nilai *training loss* khususnya dari skenario 7 sampai 11. Untuk nilai *test loss* memperoleh rata-rata dibawah *training loss* diangka 0.02. Adapun nilai *loss* yang paling

buruk berlaku pada model GRU dimana pada skenario 3 dan 12 pada P1 dan P2 mengalami disparitas sangat tinggi antara ketiga nilai *loss* pembelajaran model.



Gambar 4. Evaluasi Model di P1



Gambar 5. Evaluasi Model di P2

C. Hasil Runtime

Durasi pelatihan model antara metode kombinasi dan metode tunggal sangat jauh berbeda dimana rata-rata yang paling lama melakukan proses pembelajaran model adalah metode kombinasi LSTM-GRU yaitu 40 detik lebih pada P2 dimana dari seluruh proses pembelajaran skenario 2 pada P1 dan skenario 3 pada P2 paling cepat proses pembelajaran modelnya. Sedangkan waktu paling cepat

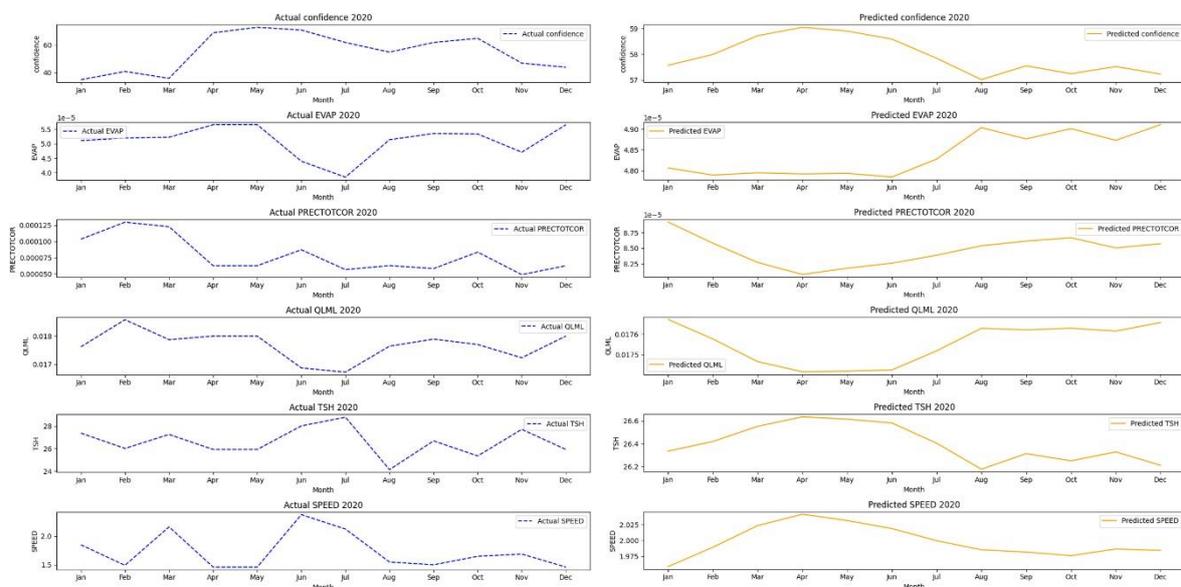
dalam proses pembelajaran model jatuh pada model LSTM yaitu di bawah 6 detik pada skenario 3 di P2 dan 5 detik pada skenario 12 di P1.

D. Hasil Prediksi

Pada sub bagian ini akan mempresentasikan hasil prediksi tren dan pemetaan tingkat kebakaran di Kalimantan

Tengah menggunakan hasil pengembangan model skenario 11 P2 sebagai *sample* model prediksi diantara model terbaik berdasarkan

pertimbangan nilai *loss*. Fluktuasi variabel kebakaran dan data cuaca sepanjang tahun 2020 di gambarkan pada Gambar 6.



Gambar 6. Hasil Prediksi Model Skenario 11 P2

Hasil prediksi menggambarkan tren tingkat kebakaran mampu mengikuti pola data aktual dimana pada bulan April sampai Juni 2020 data prediksi secara konsisten mampu menyamai data aktual. Meskipun pada awal tahun model tidak memberikan kesamaan kenaikan yang terjadi di awal Maret berdasarkan data aktual akan tetapi kenaikan secara eksponensial di bulan Februari. Pada akhir tahun model juga mampu membuat garis menurun dari bulan November ke Desember akan tetapi pada data aktual kejadian terting diakhir tahun terjadi pada bulan Oktober sedangkan model memprediksi pada bulan September.

Untuk pemetaan data cuaca yang mempengaruhi tren kebakaran pada deret waktu tertentu terjadi anomali yang sangat signifikan. Hal ini terjadi pada data evaporasi dari awal tahun sampai bulan Juni. Pada variabel cuaca lainnya seperti kelembapan, suhu, dan kecepatan angin dapat mengimbangi pola dari data aktual dimana puncaknya dari semua data aktual terjadi dibulan Juni. Pada bulan Juni penguapan air menurun pada titik terbawah nilai prediksi variabel evaporasi, curah hujan masih rendah atau tingkat 1 berdasarkan garis Y nilai prediksi, kelembapan air juga di level yang rendah dan prediksi kecepatan angin paling

puncak sepanjang tahun 2020 terjadi di bulan Juni.

E. Diskusi Temuan

Hasil eksperimen penerapan *hyperparameter* terhadap model RNN telah memberikan gambaran yang signifikan pada konsistensi pembelajaran model kombinasi metode LSTM-GRU. Hal ini sejalan dengan penelitian sebelumnya LSTM GRU mampu memberikan nilai *error* yang rendah dan nilai *error* MAE dan RMSE pun lebih rendah daripada penelitian ini (Dzulhijjah et al., 2023) dan mampu menjawab saran penilitian (Kadir et al., 2023) tentang pengurucutan prediksi ke wilayah yang lebih kecil serta penerapan metode lain mampu menghasilkan performa model yang baik.

Dampak dari penerapan *hyperparameter* sangat berpengaruh pada proses pembelajaran model. Semakin kecil *nilai dropout* dan *batch size* maka hasil *training loss* dari pembelajaran model terhadap dataset juga cenderung kecil yang dibuktikan pada skenario 1 sampai 3 dan skenario 4 ke 6 serta skenario 7-9 dan 10-11 pada P1 dan P2. Sebaliknya nilai *validation loss* tidak berbanding lurus terhadap aturan “semakin kecil” tersebut. Aturan ini juga memberikan dampak bagi nilai *testing loss*

lebih stabil mempertahankan nilainya pada rata-rata dibawah nilai *training loss* di semua skenario. Namun aturan ini hanya memberikan disparitas nilai yg rendah antara *training loss*, *validation loss* dan *testing loss* pada metode kombinasi, tetapi tidak pada metode tunggal RNN yang condong fluktuatif nilai *loss* pembelajarannya. Akibatnya metode tunggal LSTM dan GRU memperoleh nilai *error* yang sangat tinggi yang terjadi lebih banyak pada skenario pembagian dataset 80:20.

Hal ini dapat dikatakan bahwa metode kombinasi LSTM-GRU dan GRU-LSTM lebih bisa melakukan generalisasi saat proses pembelajaran dimana turun naiknya antara nilai *training loss* dan *validation* tidak terlalu jauh dan nilai *testing loss* mendekati *validation loss* yang terdapat pada skenario 7, 10, 11 di P1 dan P2 dan skenario 8 pada lingkungan pengujian P2. Sebaliknya metode tunggal sangat kewalahan beradaptasi terhadap set parameter yang telah ditetapkan saat proses pembelajaran.

Adapun pengujian di perangkat berbeda menambah pengaruh terhadap *runtime* pembelajaran selain faktor utamanya adalah pengaturan *batchsize* tetapi tidak dalam hal performa kinerja model khususnya penurunan tingkat *error* dan nilai *loss* dimana pengujian skenario pada P1 waktu terlalu lama dibawah 25 detik sedangkan pada P2 waktu terlalu lama mulai dari 40 detik keatas.

KESIMPULAN

Dalam penelitian ini penerapan *hyperparameter* dengan metode kombinasi RNN LSTM-GRU dan GRU-LSTM lebih baik melakukan generalisasi prediksi terhadap tren dan pemetaan tingkat kebakaran pada rasio dataset 80:20. Penerapan *hyperparameter* khususnya parameter *dropout* berpengaruh langsung terhadap hasil evaluasi model yang dibuktikan pada skenario 1 < 2 < 3, skenario 4 < 5 < 6, skenario 7 < 8 < 9 dan skenario 10 < 11 < 12 tingkat *error* MAE dan RMSE pada P1 dan P2 secara rata-ratanya. Sedangkan parameter *batch size* merupakan hal mendasar yang mempengaruhi lama *runtime* pembelajaran model dimana semakin kecil semakin lama waktu model belajar. Selain pengaturan *hyperparameter* pembagian rasio dataset juga mempengaruhi nilai *loss* dari evaluasi model. Adapun pengujian di perangkat berbeda tidak langsung

mempengaruhi penurunan *error* dari evaluasi model akan tetapi berdampak pada lamanya waktu performa dari pemodelan.

Pada akhirnya penelitian ini berkontribusi pada pemahaman cara memilih set *hyperparameter* yang ideal terhadap penerapan metode kombinasi RNN dan pembagian rasio dataset dalam membangun model prediksi tren dan pemetaan tingkat kebakaran di Kalimantan Tengah. Penerapan *hyperparameter* model prediktif deret waktu ini juga memvalidasi performa yang sama terhadap evaluasi model meskipun dilakukan pada lingkungan perangkat berbeda.

REFERENSI

- Chen, Z., Zhang, C., Li, W., Gao, L., Liu, L., Fang, L., & Zhang, C. (2023). Fire danger forecasting using machine learning-based models and meteorological observation: a case study in Northeastern China. *Multimedia Tools and Applications*, 83(22), 61861–61881. <https://doi.org/10.1007/s11042-023-15881-1>
- Dhake, H., Kashyap, Y., & Kosmopoulos, P. (2023). Algorithms for Hyperparameter Tuning of LSTMs for Time Series Forecasting. *Remote Sensing*, 15(8). <https://doi.org/10.3390/rs15082076>
- Dzulhijjah, D. A., Majid, M. N., Alwanda, A. Y., Kusuma, D. C., Zakaria, F., Kusri, K., & Kusnawi, K. (2023). Comparative Analysis of Hybrid Long Short-Term Memory Models for Fire Danger Index Forecasting with Weather Data. *2023 6th International Conference on Information and Communications Technology (ICOIACT)*, 165–170. <https://doi.org/10.1109/ICOIACT59844.2023.10455879>
- FIRMS Fire Information for Resource Management System. (n.d.). *MODIS Active Fire Data*. <https://Firms.Modaps.Eosdis.Nasa.Gov/Country/>.
- GES DISC. (n.d.). *Merra2 M2TMNXFLX*. https://Goldsmr4.Gesdisc.Eosdis.Nasa.Gov/Data/MERRA2_MONTHLY/M2TMNXFLX.5.12.4/.
- Hema Yurismi, A., Daniah, R., & Wicaksa, A. (2022). Upaya Pemerintah Indonesia

- Dalam Mengatasi Kebakaran Hutan dan Lahan di Pulang Pisau, Kalimantan Tengah. *Interdependence Journal of International Studies*, 3(2), 82–96. <https://doi.org/10.54144/ijis.v3i2.57>
- Jamshed, M. A., Theodorou, C., Kalsoom, T., Anjum, N., Abbasi, Q. H., & Ur-Rehman, M. (2022). Intelligent computing based forecasting of deforestation using fire alerts: A deep learning approach. *Physical Communication*, 55. <https://doi.org/10.1016/j.phycom.2022.101941>
- Kadir, E. A., Kung, H. T., AlMansour, A. A., Irie, H., Rosa, S. L., & Fauzi, S. S. M. (2023). Wildfire Hotspots Forecasting and Mapping for Environmental Monitoring Based on the Long Short-Term Memory Networks Deep Learning Algorithm. *Environments*, 10(7), 124. <https://doi.org/10.3390/environments10070124>
- Listia Rosa, S., Abdul Kadir, E., Syukur, A., Irie, H., Wandri, R., & Fikri Evizal, M. (2022). Fire Hotspots Mapping and Forecasting in Indonesia Using Deep Learning Algorithm. *2022 3rd International Conference on Electrical Engineering and Informatics (ICon EEI)*, 190–194. <https://doi.org/10.1109/IConEEI55709.2022.9972281>
- Mao, Y., Pranolo, A., Wibawa, A. P., Putra Utama, A. B., Dwiyanto, F. A., & Saifullah, S. (2022). Selection of Precise Long Short Term Memory (LSTM) Hyperparameters based on Particle Swarm Optimization. *Proceedings - International Conference on Applied Artificial Intelligence and Computing, ICAAIC* 2022. <https://doi.org/10.1109/ICAAIC53929.2022.9792708>
- PPID KLHK. (2023, December 31). Kinerja Pengendalian Kebakaran Hutan dan Lahan Tahun 2023. <https://Ppid.Menlhk.Go.Id/>
- Rini Rahayu. (2023, October 6). 3.436 Titik Karhutla Periode Januari-Oktober, 9.769 Hektare Lahan Terbakar. <https://www.Detik.Com/Sulsel/Berita/d-6969318/3-436-Titik-Karhutla-Periode-Januari-Oktober-9-769-Hektare-Lahan-Terbakar>.
- Samadi Miandoab, P., Saramad, S., & Setayeshi, S. (2023). Respiratory motion prediction based on deep artificial neural networks in CyberKnife system: A comparative study. *Journal of Applied Clinical Medical Physics*, 24(3). <https://doi.org/10.1002/acm2.13854>
- SINDO News. (2023, October 12). *Kebakaran Hutan dan Lahan Menjadi Bencana Tahunan di Indonesia, Apa Solusianya?* <https://www.Youtube.Com/Watch?V=j7C4z9vASq4&t=164s>.
- Zeng, C., Ma, C., Wang, K., & Cui, Z. (2022). Parking Occupancy Prediction Method Based on Multi Factors and Stacked GRU-LSTM. *IEEE Access*, 10, 47361–47370. <https://doi.org/10.1109/ACCESS.2022.3171330>
- Zhang, H., Zheng, Z., & Wen, G. (2022). Wildfire Monitoring Based on LSTM and Deep Learning. *IGARSS 2022 - 2022 IEEE International Geoscience and Remote Sensing Symposium*, 2682–2685. <https://doi.org/10.1109/IGARSS46834.2022.9883872>
- Zhang, W., Lim, M. K., Yang, M., Li, X., & Ni, D. (2023). Using deep learning to interpolate the missing data in time-series for credit risks along supply chain. *Industrial Management and Data Systems*, 123(5). <https://doi.org/10.1108/IMDS-08-2022-0468>