

PREDIKSI HARIAN VARIASI MEDAN GEOMAGNETIK MENGUNAKAN METODE LONG SHORT-TERM MEMORY (LSTM)

DAILY PREDICTION OF GEOMAGNETIC FIELD VARIATIONS USING THE LONG SHORT-TERM MEMORY (LSTM) METHOD

La Ode Muhammad Musafar, Visca Wellyanita

*E-mail: visca.wellyanita@gmail.com

Pusat Riset Antariksa, Organisasi Riset Penerbangan dan Antariksa, BRIN

Abstrak

Aktivitas geomagnet merupakan parameter penting yang mencerminkan tingkat efisiensi interaksi antara angin matahari dan medan geomagnet, serta dampaknya terhadap sistem antariksa Bumi. Mengingat perannya yang signifikan, kemampuan untuk memprediksi aktivitas geomagnet menjadi kebutuhan yang mendesak, khususnya dalam mendukung mitigasi gangguan pada sistem teknologi berbasis antariksa dan kelistrikan. Secara umum, aktivitas geomagnet diperoleh dari data observasi medan geomagnet yang telah dikoreksi terhadap nilai baseline. Oleh karena itu, ketepatan dalam memprediksi variasi harian medan geomagnet menjadi komponen krusial dalam meningkatkan akurasi prediksi aktivitas geomagnet secara keseluruhan. Penelitian ini berfokus pada pengembangan model prediksi variasi harian medan geomagnet menggunakan pendekatan Long Short-Term Memory (LSTM). Model diterapkan pada data observasi medan geomagnet beresolusi 10 menit dengan rentang waktu lebih dari 10 tahun yang dikumpulkan di wilayah Indonesia. Training dilakukan dengan menggunakan input data 144 titik data dengan output 144 titik data variasi harian dan 1 data baseline tengah malam. Hasil evaluasi menunjukkan bahwa keluaran model memiliki tingkat korelasi yang sangat baik terhadap data observasi, sehingga pendekatan ini berpotensi mendukung peningkatan kemampuan prediksi aktivitas geomagnet.

Kata kunci: variasi harian geomagnet, LSTM, aktivitas geomagnet, pemodelan berbasis data.

Abstract

Geomagnetic activity is an important parameter that reflects the efficiency of the interaction between the solar wind and the Earth's geomagnetic field, as well as its impact on near-Earth space systems. Given its significant role, the ability to predict geomagnetic activity has become increasingly essential, particularly to support the mitigation of disturbances affecting space-based and electrical technological systems. In general, geomagnetic activity is derived from geomagnetic field observations that have been corrected for baseline values. Therefore, accurate prediction of the daily variation of the geomagnetic field constitutes a crucial component in improving the overall accuracy of geomagnetic activity forecasting. This study focuses on developing a predictive model for daily geomagnetic field variation using the Long Short-Term Memory (LSTM) approach. The model was applied to geomagnetic field observation data with a

10-minute temporal resolution spanning more than 10 years, collected in the Indonesian region. The training process utilized 144 input data points to predict 144 output data points of daily variation along with one midnight baseline value. The evaluation results demonstrate that the model outputs exhibit a very strong correlation with the observational data, indicating that this approach has strong potential to enhance geomagnetic activity prediction capability.

Keywords: *geomagnetic daily variation, LSTM, geomagnetic activity, data-driven modelling.*

1. PENDAHULUAN

Medan geomagnet merupakan medan magnet alami yang dihasilkan oleh proses geodinamo di inti luar Bumi, yaitu akibat konveksi fluida logam cair yang bersifat konduktif (utama besi dan nikel) serta dipengaruhi oleh rotasi Bumi. Gerakan fluida ini membangkitkan arus listrik skala besar yang kemudian menghasilkan medan magnet global yang menyelimuti Bumi. Medan ini berperan dalam membentuk magnetosfer, yaitu daerah dominasi medan magnet Bumi yang berinteraksi dengan plasma dari angin Matahari. Secara fisik, magnetosfer berfungsi sebagai sistem penghalang yang memodifikasi distribusi partikel bermuatan berenergi tinggi dari lingkungan antariksa. Dalam kajian geofisika, medan geomagnet menjadi parameter fundamental karena merepresentasikan kopling antara dinamika interior Bumi dan penggerak eksternal dari Matahari.

Medan geomagnet bersifat intrinsik non-stasioner dan menunjukkan variasi temporal pada berbagai skala waktu, mulai dari detik hingga tahunan. Salah satu komponen utama adalah variasi harian atau variasi diurnal yang terutama disebabkan oleh arus listrik ionosfer, khususnya arus dinamo ionosfer, yang terbentuk akibat ionisasi oleh radiasi ultraviolet dan sinar-X Matahari. Interaksi antara medan listrik ionosfer dan medan magnet Bumi menghasilkan variasi teratur pada komponen medan geomagnet terukur di permukaan. Selain itu, terdapat variasi tidak teratur yang bersifat impulsif seperti gangguan geomagnet dan badai geomagnet yang dipicu oleh interaksi antara angin Matahari, termasuk lontaran massa korona (CME), dengan magnetosfer Bumi.

Fenomena tersebut merupakan bagian dari sistem yang dikenal sebagai cuaca antariksa, yaitu kondisi dinamis lingkungan geospace yang dikendalikan oleh fluks energi dan partikel dari Matahari. Dalam sistem ini, magnetosfer, ionosfer, dan termosfer saling berkopling melalui proses elektrodinamika plasma yang kompleks dan multi-skala. Akibatnya, respons medan geomagnet terhadap penggerak eksternal tidak bersifat linier maupun deterministik sederhana, melainkan merupakan hasil interaksi non-linear dari berbagai proses fisis yang berlangsung simultan.

Kompleksitas tersebut menjadikan pemodelan dan prediksi medan geomagnet sebagai masalah inverse yang tidak trivial. Data geomagnet menunjukkan karakteristik non-linear, non-stasioner, serta memiliki struktur dependensi temporal jangka panjang. Selain itu, adanya noise geofisika dan variasi multi-sumber menyebabkan distribusi data sulit direpresentasikan secara akurat menggunakan model parametrik sederhana. Kondisi ini mengindikasikan bahwa pendekatan linier atau berbasis asumsi stasioneritas tidak memadai untuk menangkap dinamika sistem secara menyeluruh.

Metode konvensional yang berbasis statistik klasik, seperti ARIMA atau regresi linier, umumnya mengasumsikan linearitas dan stasioneritas data, sehingga kurang mampu merepresentasikan dinamika non-linear dan perubahan regime pada data geomagnet. Di sisi lain, model fisik berbasis persamaan elektrodinamika plasma membutuhkan parameterisasi yang

kompleks serta input kondisi batas yang tidak selalu tersedia secara langsung dari observasi, sehingga membatasi fleksibilitas dalam aplikasi prediksi jangka pendek seperti harian.

Seiring perkembangan komputasi, pendekatan *data-driven* berbasis *deep learning* semakin banyak digunakan untuk pemodelan sistem kompleks, termasuk deret waktu geofisika. Salah satu arsitektur yang paling relevan adalah Long Short-Term Memory (LSTM), yaitu varian dari Recurrent Neural Network (RNN) yang dirancang untuk mengatasi masalah *vanishing gradient* melalui mekanisme gerbang (*input gate*, *forget gate*, *output gate*) dalam sel memori. Mekanisme ini memungkinkan LSTM mempertahankan informasi historis yang relevan dalam horizon waktu yang panjang, sehingga efektif dalam memodelkan dependensi temporal pada data non-linear dan non-stasioner seperti medan geomagnet.

Berdasarkan karakteristik tersebut, penelitian ini difokuskan pada pengembangan model prediksi variasi medan geomagnet harian menggunakan arsitektur LSTM. Selain itu, penelitian ini bertujuan untuk mengevaluasi performa model dalam merekonstruksi pola temporal data observasi aktual, sehingga dapat dianalisis kemampuan LSTM dalam menangkap dinamika non-linear dan dependensi jangka panjang pada sistem geomagnet. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan pendekatan prediksi berbasis *data-driven* pada sistem geospace yang kompleks.

2. METODOLOGI

Pengamatan jangka panjang yang berkesinambungan sangat diperlukan untuk menerapkan model LSTM dalam memprediksi variasi medan geomagnetik. Namun, ketersediaan data dengan cakupan waktu yang panjang seperti ini masih belum tersedia di wilayah Indonesia. Secara ideal, data dari satu stasiun pengamatan sebenarnya sudah cukup untuk digunakan sebagai masukan model LSTM apabila tersedia pengukuran jangka panjang yang memadai. Untuk mengatasi keterbatasan data tersebut, dalam studi ini digunakan data dari tujuh stasiun magnetometer sebagaimana dijelaskan pada Tabel 1. Masing-masing stasiun merekam tiga komponen medan magnet, yaitu X, Y, dan Z, dengan resolusi waktu satu detik. Mengingat gangguan pada komponen H umumnya paling merepresentasikan variasi geomagnetik di lintang rendah, penelitian ini hanya berfokus pada komponen H (Rastogi, 2005).

Stasiun-stasiun geomagnetik yang digunakan dalam penelitian ini beroperasi pada periode waktu yang berbeda-beda, dengan ketersediaan data yang juga tidak seragam bahkan selama masa operasionalnya. Sebagai contoh, stasiun KTB beroperasi secara tidak kontinu pada periode 2004–2005 dan 2008–2022, namun data yang diperoleh banyak mengandung celah dan periode yang berisik sehingga penggunaannya terbatas. Stasiun PMK menyediakan data pada rentang 2012–2016, sedangkan PRP beroperasi pada 2005–2008, 2010–2012, dan 2014–2016. KPG mencatat data pada periode 2007–2008, 2010–2017, serta 2021. Sementara itu, PTN beroperasi lebih panjang, yaitu 2005–2014 dan 2017–2025. Stasiun TJS mencatat data pada 2004–2005 serta 2007–2021, dan MND pada 2005–2018.

Dalam studi ini, komponen X dan Y digunakan untuk menghitung komponen horizontal medan geomagnetik ($H = \sqrt{X^2 + Y^2}$) yang dinyatakan dalam satuan nanotesla. Fluktuasi geomagnetik dihitung dengan menghilangkan medan utama menggunakan model IGRF-13 untuk tahun 2020, yang diterapkan secara seragam pada seluruh rentang data. Pendekatan ini digunakan untuk memfokuskan analisis pada variasi skala harian, bukan pada tren sekuler jangka panjang. Pengembangan lebih lanjut dengan penggunaan nilai IGRF yang sesuai tiap tahun akan dipertimbangkan pada penelitian mendatang.


Pada tahap pra-pemrosesan, data magnetometer dengan resolusi 1 detik diubah menjadi data rata-rata 1 menit melalui proses resampling. Deret waktu ΔH dari masing-masing stasiun kemudian dilengkapi kembali (gap-filling) menggunakan interpolasi polinomial, dengan orde polinomial yang disesuaikan secara adaptif berdasarkan panjang celah data serta struktur lokalnya. Dalam implementasinya, digunakan polinomial berorde 2–5 untuk celah pendek, dan hingga orde 11 untuk celah yang lebih panjang. Pendekatan ini menjaga keberlanjutan terhadap nilai pengamatan sekaligus mempertahankan pola diurnal, khususnya peningkatan pada sekitar tengah hari yang merupakan karakteristik khas variasi geomagnetik di lintang rendah.

Setelah proses interpolasi, deret waktu ΔH dari tujuh stasiun disejajarkan secara temporal dan kemudian dirata-ratakan pada setiap titik waktu untuk menghasilkan satu dataset representatif wilayah Indonesia. Pendekatan ini didasarkan pada asumsi bahwa stasiun-stasiun yang secara geografis berdekatan dan memiliki karakteristik magnetik serupa akan menunjukkan pola variasi temporal yang sebanding. Analisis data menunjukkan bahwa variasi temporal geomagnetik (ΔH) pada satu lokasi umumnya berada di bawah 5 nT pada kondisi tenang dan dapat meningkat hingga sekitar 12 nT saat kondisi terganggu (Syafitri et al., 2022). Besaran ini setara dengan sekitar 10% dari rentang fluktuasi puncak ΔH yang diamati antarstasiun. Perbedaan spasial yang relatif kecil ini menunjukkan bahwa, terutama pada tahap pelatihan model, pengamatan dari beberapa stasiun secara bersamaan dapat saling melengkapi dan membantu mengatasi data yang hilang pada suatu lokasi tertentu.

Data variasi medan geomagnetik kemudian dibagi menjadi dataset pelatihan serta dataset validasi/pengujian untuk penerapan metode LSTM. Dataset pelatihan mencakup beberapa kejadian badai geomagnetik dan terdiri dari pengamatan dari tujuh stasiun yang direkam pada periode 29 Februari 2004 hingga 31 Desember 2020. Setelah dilakukan penyaringan dengan menghapus hari-hari yang memiliki urutan input tidak lengkap, dataset pelatihan akhir berjumlah 749.088 titik data, yang setara dengan 5.202 hari data dengan resolusi 10 menit (lihat Gambar 1 sebagai contoh). Gambar 1 memperlihatkan cuplikan data pelatihan selama 60 hari, dengan sumbu-x menunjukkan hari kalender dari 0 hingga 59, di mana setiap hari terdiri dari 144 titik data hasil sampling setiap 10 menit. Rentang ini merepresentasikan periode 5 Maret hingga 2 Mei 2004.

Sementara itu, dataset validasi/pengujian disusun dari data stasiun PTN yang memiliki pengamatan kontinu selama periode 1 Januari 2021 hingga 28 Juni 2022. Dataset ini terdiri dari 78.336 titik data, atau setara dengan 544 hari data beresolusi 10 menit. Data tersebut tidak mengandung nilai NaN sehingga layak digunakan untuk evaluasi model secara andal. Selain itu, data geomagnetik dari stasiun PTN pada Mei 2024 yang mencakup kejadian badai Gannon juga dimasukkan untuk menguji kinerja model pada kondisi ekstrem. Stasiun PTN dipilih sebagai data validasi karena ketersediaan datanya yang konsisten pada periode tersebut, sehingga memungkinkan evaluasi yang lebih akurat terhadap reliabilitas model prediksi.

Model LSTM yang dikembangkan dalam penelitian ini menggunakan arsitektur satu lapis (single layer) dengan satu masukan dan satu keluaran. Masing-masing input dan output terdiri dari 144 elemen yang merepresentasikan deret waktu harian dengan interval sampling 10 menit. Data dimasukkan ke dalam model dalam bentuk batch berukuran 32 urutan harian untuk menjaga efisiensi serta stabilitas proses pelatihan. Ukuran batch ini dipilih karena mampu mengoptimalkan pemrosesan paralel pada GPU modern, sekaligus menyeimbangkan antara kecepatan komputasi dan kestabilan pembelajaran.



Gambar 1. Dataset gabungan yang menunjukkan variasi medan geomagnetik hasil observasi dari beberapa stasiun di wilayah Indonesia.

Model ini menggunakan fungsi aktivasi ReLU (Rectified Linear Unit) untuk memperkenalkan non-linearitas pada jaringan, sementara pada lapisan LSTM sendiri digunakan mekanisme internal yang umum, yaitu fungsi sigmoid pada bagian gate. Kombinasi ini meningkatkan kemampuan jaringan dalam memodelkan ketergantungan temporal yang kompleks serta membantu mengurangi masalah vanishing gradient. Seluruh model diimplementasikan menggunakan TensorFlow berbasis Python, yaitu salah satu framework yang banyak digunakan untuk mempermudah pengembangan, pelatihan, dan penyetelan model deep learning. Pendekatan yang digunakan dalam penelitian ini juga mengacu pada sumber-sumber metodologis yang telah mapan (misalnya Mueller dan Guido, 2016; Raschka, 2015; Raschka dan Mirjalili, 2019), sehingga memberikan dasar yang kuat dalam melakukan peramalan variasi harian medan geomagnetik secara akurat.

3. HASIL DAN PEMBAHASAN

Pemrosesan data yang efisien sangat diperlukan untuk mensimulasikan perubahan medan geomagnetik secara akurat, terutama ketika menggunakan teknik pembelajaran mesin. Tahap pra-pemrosesan seperti seleksi fitur, pembentukan urutan data, dan normalisasi sangat penting untuk memastikan keandalan model prediktif. Penentuan struktur input–output yang tepat juga menjadi kunci dalam peramalan deret waktu agar dapat menangkap ketergantungan temporal dalam data. Jaringan LSTM dipilih dalam konteks ini karena kemampuannya dalam mempertahankan dependensi jangka panjang, sehingga meningkatkan akurasi prediksi gangguan geomagnetik.


Dalam penelitian ini, digunakan kerangka pemodelan satu tahap (single-stage) berbasis jaringan Long Short-Term Memory (LSTM) untuk memprediksi variasi ΔH medan geomagnetik. Setiap sampel input terdiri dari 144 langkah waktu yang merepresentasikan data selama 24 jam dengan interval 10 menit, serta mencakup enam fitur, yaitu nilai ΔH asli, urutan ΔH yang dibalik, turunan waktu ($d\Delta H/dt$), representasi sinusoidal dan kosinusoidal dari sudut waktu, serta nilai rata-rata harian ΔH konstan yang dihitung dari interval 16:00 hingga 18:00 UT. Arsitektur model terdiri dari dua lapisan LSTM, yaitu lapisan pertama dengan 64 unit dan lapisan kedua dengan 32 unit. Model menghasilkan dua keluaran, yakni deret prediksi ΔH untuk 144 langkah waktu pada hari berikutnya serta satu nilai skalar yang merepresentasikan rata-rata ΔH pada interval 16:00–18:00 UT. Nilai skalar ini kemudian digunakan sebagai referensi koreksi untuk memperkirakan nilai ΔH pada sekitar tengah malam lokal dari hasil prediksi deret waktu.

Alur data secara keseluruhan yang mencakup pelatihan, penyetelan, serta validasi—termasuk segmentasi sliding window dan pembagian data secara kronologis. Proses pelatihan dilakukan menggunakan optimizer Adam dengan learning rate 0,00001 dan batch size 16. Model dilatih hingga maksimum 2000 epoch, dengan penerapan early stopping (patience = 20 epoch) serta model checkpointing untuk menghentikan pelatihan secara otomatis ketika nilai loss validasi tidak lagi membaik. Sebanyak 10% data digunakan sebagai validation split tanpa proses pengacakan (no shuffling) untuk menjaga struktur temporal data. Pendekatan LSTM satu tahap dengan keluaran ganda ini memungkinkan model untuk menangkap dinamika jangka pendek sekaligus variasi sistematis jangka panjang pada medan geomagnetik, sebagaimana ditunjukkan pada Gambar 2 dan 3 baik dalam kondisi tenang maupun terganggu.

Gambar 2 menunjukkan kinerja model LSTM pertama dalam memprediksi variasi medan geomagnetik pada periode kondisi geomagnetik tenang, yang dievaluasi menggunakan Mean Squared Error (MSE). Gambar ini terdiri dari tiga panel yang disusun secara vertikal. Panel bagian atas memperlihatkan variasi ΔH medan geomagnetik yang teramati (dalam nT), yang menampilkan pola variasi diurnal yang relatif teratur selama beberapa hari. Panel tengah menyajikan hasil prediksi model menggunakan pendekatan sliding window pada dataset pelatihan dalam interval waktu yang sama. Nilai prediksi menunjukkan kesesuaian yang sangat baik terhadap pola observasi, baik dari segi fase maupun amplitudo, yang mengindikasikan kemampuan model dalam menangkap struktur temporal variasi harian medan geomagnetik.

Panel bagian bawah menampilkan nilai MSE yang bersesuaian (dalam nT^2), yang dihitung setiap 10 menit. Nilai MSE rata-rata berada pada kisaran sekitar 0,13 nT^2 , dengan seluruh nilai umumnya tetap berada di bawah 20 nT^2 , kecuali beberapa lonjakan kecil yang kemungkinan berkaitan dengan galat residual model atau fenomena transien yang tidak terakomodasi. Pada konteks ini, sumbu-x merepresentasikan urutan titik data dari subset dataset pelatihan yang dipilih untuk kondisi geomagnetik tenang. Sementara itu, istilah “jangka pendek” merujuk pada setiap urutan input yang terdiri dari 144 titik data (setara 24 jam), sebagaimana digunakan dalam skema sliding window pada LSTM. Perbedaan ini mencerminkan desain model, di mana ketergantungan temporal ditangkap dalam setiap jendela input harian, sedangkan generalisasi diperoleh dari keseluruhan dataset jangka panjang.

Interval data yang ditampilkan menunjukkan kondisi geomagnetik yang tenang, yang juga dikonfirmasi secara independen melalui indeks Kp dan Dst yang rendah. Model LSTM menunjukkan kesalahan prediksi yang lebih rendah secara signifikan pada kondisi tenang dibandingkan dengan periode terganggu, sebagaimana tercermin dari nilai MSE yang konsisten rendah. Hal ini menunjukkan kemampuan model untuk melakukan generalisasi dengan baik pada kondisi tenang, terutama di wilayah lintang rendah yang umumnya memiliki variasi geomagnetik lebih teratur dan kurang dipengaruhi oleh gangguan auroral maupun polar. Sebaliknya, wilayah lintang tinggi cenderung didominasi oleh fenomena yang lebih tidak teratur seperti substorm dan elektrojet, yang meningkatkan variabilitas sinyal dan menjadi tantangan bagi pemodelan berbasis jaringan saraf karena kompleksitas dinamikanya yang lebih tinggi.




Gambar 2. Nilai MSE antara data observasi dan hasil prediksi model pada kondisi aktivitas geomagnetik tenang.

Gambar 3 menunjukkan nilai MSE dari kemampuan model LSTM dalam memprediksi perubahan medan geomagnetik selama periode aktivitas geomagnetik terganggu. Panel pertama memperlihatkan komponen H medan geomagnetik hasil observasi (dalam nT) selama beberapa hari, yang ditandai oleh fluktuasi yang cukup signifikan, termasuk penurunan dan peningkatan tajam yang mencerminkan terjadinya gangguan geomagnetik. Panel kedua menampilkan hasil prediksi model untuk periode yang sama. Meskipun terdapat beberapa deviasi, terutama dalam menangkap perubahan ekstrem yang berkaitan dengan badai geomagnetik, secara umum tren yang dihasilkan masih mengikuti pola observasi. Panel ketiga menunjukkan nilai MSE antara data observasi dan prediksi, yang dinyatakan dalam nT^2 . Pada bagian ini terlihat beberapa lonjakan yang cukup besar, dengan nilai MSE maksimum melebihi 300 nT^2 , jauh lebih tinggi dibandingkan kondisi tenang yang memiliki kesalahan relatif kecil. Rata-rata kesalahan untuk data dengan resolusi 10 menit berada di sekitar $2,1 \text{ nT}^2$. Kecenderungan peningkatan MSE pada saat terjadi badai geomagnetik menunjukkan keterbatasan model dalam merepresentasikan variasi ekstrem pada medan geomagnetik. Hal ini dapat disebabkan oleh kompleksitas intrinsik dan sifat ketidakpastian yang tinggi pada peristiwa geomagnetik yang kuat, serta ketidakseimbangan jumlah kejadian badai dalam dataset pelatihan, yang pada akhirnya dapat mempengaruhi kemampuan generalisasi model pada berbagai tingkat aktivitas geomagnetik.

Kemudian diterapkan kerangka LSTM yang sama pada dataset yang berbeda untuk mengevaluasi kinerja peramalan secara real-time, dengan mengacu pada model yang telah dilatih dan divalidasi pada bagian sebelumnya. Subbagian 3.2 memperluas penelitian ini dengan memanfaatkan model untuk melakukan prediksi satu hari ke depan (one-day-ahead forecasting) selama kejadian badai geomagnetik signifikan pada Mei 2024. Untuk menjaga konsistensi metodologis sekaligus menilai ketahanan operasional model dalam menghadapi peristiwa cuaca antariksa ekstrem, digunakan struktur input yang sama, yaitu urutan data 24 jam dengan enam fitur yang disampling setiap 10 menit.

Dengan menggunakan data input dari 24 jam sebelumnya, model yang telah dikembangkan kemudian digunakan untuk memprediksi perubahan medan geomagnetik, khususnya untuk horizon prediksi satu hari ke depan. Gambar 6 menyajikan hasil prediksi

tersebut, dengan garis putus-putus yang menunjukkan batas antara data input dan data output. Kurva merah dan biru masing-masing merepresentasikan nilai prediksi dan observasi, sedangkan kurva hitam menunjukkan data input. Secara visual, terlihat bahwa nilai prediksi dan observasi memiliki kesesuaian yang sangat tinggi dan hampir saling tumpang tindih, yang mengindikasikan bahwa model LSTM mampu menghasilkan prediksi yang akurat.




Gambar 3. Nilai MSE antara data observasi dan hasil prediksi model pada kondisi gangguan besar medan geomagnetik.

Pada Gambar 6, sumbu-x menunjukkan tanggal dalam UTC yang mencakup periode 31 Desember 2020 hingga 1 Januari 2021. Sumbu-y merepresentasikan perubahan komponen horizontal medan magnet Bumi (ΔH) dalam satuan nT. Kurva hitam menggambarkan data input dari hari sebelumnya, sedangkan kurva biru dan merah masing-masing menunjukkan data observasi dan hasil prediksi untuk periode peramalan. Kedekatan yang sangat kuat antara kurva observasi (biru) dan prediksi (merah), yang hampir saling berhimpitan sepanjang interval, menunjukkan bahwa model LSTM mampu meramalkan perubahan medan geomagnetik satu hari sebelumnya dengan baik.

Model ini secara akurat menangkap pola dan dinamika fluktuasi medan magnet, yang merupakan aspek penting dalam peramalan cuaca antariksa yang presisi. Selain itu, Gambar 4 juga menunjukkan konsistensi kinerja model sepanjang hari, dengan hanya terdapat deviasi kecil antara nilai prediksi dan observasi. Perbedaan ini bersifat minor dan tidak mempengaruhi reliabilitas keseluruhan model. Tingkat akurasi yang tinggi ini menegaskan kemampuan LSTM dalam menangani data deret waktu yang kompleks seperti variasi geomagnetik, serta mendukung potensinya untuk aplikasi prediksi dan pemantauan cuaca antariksa.

Dengan menggunakan dataset besar yang mencakup lebih dari 16 tahun pengamatan gabungan dari tujuh stasiun magnetometer di Indonesia, metode LSTM berhasil diterapkan untuk memprediksi variasi harian medan geomagnetik. Model ini dilatih menggunakan dataset tersebut dan divalidasi dengan data dari stasiun PTN yang direkam antara Januari hingga Desember 2021. Hasil menunjukkan bahwa model bekerja dengan baik pada kondisi geomagnetik tenang, namun akurasinya menurun selama peristiwa gangguan geomagnetik besar, yang tercermin dari meningkatnya nilai MSE harian antara data observasi dan prediksi pada periode gangguan medan magnet.

Pada peristiwa badai geomagnetik besar, model masih mampu menangkap waktu puncak terjadinya gangguan dengan cukup baik, namun amplitudo yang diprediksi cenderung tereduksi secara signifikan, dengan nilai MSE sekitar 150 nT^2 . Untuk badai yang lebih kecil, puncak gangguan yang diprediksi dapat mengalami keterlambatan dibandingkan data observasi, dengan MSE sekitar 20 nT^2 . Perilaku ini konsisten dengan variasi tingkat gangguan geomagnetik, yang menunjukkan bahwa meskipun kejadian dengan onset sedang atau tiba-tiba kurang akurat diprediksi, kondisi tenang dan badai besar masih dapat direpresentasikan secara cukup baik oleh model.



Gambar 4. Contoh validasi prediksi medan magnet untuk hari berikutnya. Hasil menunjukkan prediksi untuk 1 Januari 2021 berdasarkan data input pada 31 Desember 2020.

Keterbatasan ini sejalan dengan temuan sebelumnya yang menunjukkan bahwa model LSTM memiliki kinerja yang kuat pada kondisi stabil, tetapi mengalami penurunan kemampuan dalam menangkap dinamika kompleks selama periode gangguan geomagnetik yang intens. Hasil validasi juga menegaskan hal ini, di mana perbedaan antara data prediksi dan observasi pada skala jam menjadi semakin jelas selama periode badai. Perbedaan antara nilai observasi dan prediksi menunjukkan selisih puncak hingga sekitar 12 nT , dengan deviasi yang lebih besar umumnya terjadi pada saat gangguan geomagnetik, meskipun besaran serupa juga dapat muncul pada kondisi tenang akibat keterbatasan inheren model.

Meskipun demikian, model ini tetap merupakan alat yang berguna untuk analisis aktivitas cuaca antariksa. Seperti yang telah dijelaskan sebelumnya, model LSTM memberikan dasar yang baik untuk peramalan cuaca antariksa, khususnya di wilayah lintang rendah seperti Indonesia, di mana variasi geomagnetik cenderung lebih halus dan teratur dibandingkan wilayah lintang tinggi. Di wilayah lintang tinggi, adanya arus aurora dan substorm menyebabkan fluktuasi yang lebih intens dan berfrekuensi tinggi, sehingga lebih sulit untuk dimodelkan dengan arsitektur LSTM saat ini.

Perilaku tersebut sejalan dengan hasil penelitian sebelumnya yang menunjukkan bahwa model berbasis LSTM mengalami kesulitan dalam menangkap fluktuasi geomagnetik mendadak yang terkait dengan kondisi gangguan, khususnya pada prediksi perubahan medan magnet permukaan. Sebaliknya, karakteristik variasi geomagnetik di wilayah ekuator yang lebih dapat diprediksi menjadikannya lebih sesuai untuk pengembangan dan validasi awal model.

Tingginya kesalahan prediksi selama periode badai menunjukkan perlunya peningkatan model lebih lanjut. Keterbatasan ini juga mencerminkan bahwa, dalam rangka mengevaluasi kinerja dasar LSTM terhadap perubahan medan magnet di permukaan bumi, penelitian ini secara

sengaja hanya berfokus pada variasi ΔH . Namun demikian, penelitian sebelumnya menunjukkan bahwa penambahan parameter cuaca antariksa lain—seperti kecepatan angin matahari, medan magnet antarplanet (IMF), dan konduktivitas ionosfer—dapat meningkatkan kinerja prediksi secara signifikan selama periode gangguan geomagnetik. Temuan ini menunjukkan bahwa integrasi data tersebut pada pengembangan model di masa depan berpotensi meningkatkan kemampuan model dalam menangkap variasi saat badai, sekaligus memperbaiki keandalan prediksi cuaca antariksa untuk mendukung mitigasi dampaknya terhadap sistem teknologi.

4. KESIMPULAN

Dengan menggunakan dataset pengamatan lebih dari 16 tahun dari tujuh stasiun magnetometer di Indonesia, model LSTM berhasil diterapkan untuk memprediksi variasi harian medan geomagnetik dan divalidasi menggunakan data stasiun PTN tahun 2021. Hasil menunjukkan bahwa model memiliki kinerja yang baik pada kondisi geomagnetik tenang, namun mengalami penurunan akurasi pada saat terjadi gangguan geomagnetik, yang ditandai oleh peningkatan nilai MSE. Meskipun demikian, model masih mampu menangkap waktu terjadinya puncak gangguan, meskipun amplitudo sering tereduksi atau terjadi keterlambatan pada beberapa kasus, terutama pada gangguan kecil hingga menengah. Secara umum, deviasi prediksi terhadap observasi meningkat selama periode gangguan, tetapi tetap dalam batas yang masih informatif untuk analisis tren. Temuan ini menegaskan bahwa LSTM lebih efektif untuk kondisi geomagnetik yang stabil, khususnya di wilayah lintang rendah seperti Indonesia, sementara performanya menurun pada kondisi gangguan kompleks yang ditandai fluktuasi cepat dan tidak teratur. Oleh karena itu, peningkatan model dengan integrasi parameter cuaca antariksa tambahan diperlukan untuk meningkatkan akurasi pada kondisi geomagnetik terganggu.

5. DAFTAR RUJUKAN

- Ahmad, N., Herdiwijaya, D., Djamaluddin, T., Usui, H., Miyake, Y., 2018. Diagnosing low earth orbit satellite anomalies using NOAA-15 electron data associated with geomagnetic perturbations. *Earth, Planets and Space* 70(91). <https://doi.org/10.1186/s40623-018-0852-2>
- Ahmad, N., Kilowasid, LOMM., Fakhrrurroja, H., Neflia., Rachman, A., Husin, A., Fathoni, H., 2025. How geomagnetic storms affect the loss of Starlink satellites in February 2022? *Earth, Planets and Space* 77(2). <https://doi.org/10.1186/s40623-024-02124-2>
- Bartels, J., 1957. The Technique of Scaling Indices K and Q of Geomagnetic Activity. In: *IGY Instruction Manual, Part I. Geomagnetism* (1), pp. 215-220, Pergamon Press, Oxford.
- Biggin, A., Strik, G. and Langereis, C. 2008, Evidence for a very-long-term trend in geomagnetic secular variation. *Nature Geosci* 1, 395–398. <https://doi.org/10.1038/ngeo181>
- Chakraborty, S., Morley, S.K., 2020. Probabilistic prediction of geomagnetic storms and the Kp index, *J. Space Weather Space Climate* 10(16). <https://doi.org/10.1051/swsc/2020037>
- Constable, C., 2016. Earth's Electromagnetic Environment. *Survey in Geophysics* 37, 27–45. <https://doi.org/10.1007/s10712-015-9351-1>
- Lethy, A., El-Eraki, M.A., Samy, A., Deebes, H.A., 2018. Prediction of the Dst Index and Analysis of Its Dependence on Solar Wind Parameters Using Neural Network, *Space Weather*, 16(9), 1277-1290. <https://doi.org/10.1029/2018SW001863>
- Mandea, M., Korte, M., Yau, A., Petrovský, E., 2019. Temporal Field Variations: Spatial and Temporal Variations of the Geomagnetic Field. In: *Geomagnetism, Aeronomy and Space Weather: A Journey from the Earth's Core to the Sun. Series: Special Publications of the International Union of Geodesy and Geophysics*, Cambridge University Press.

- Mueller, A.C., Guido, S. 2016. Introduction to Machine Learning with Python: A Guide for Data Scientists. O'Reilly Media.
- Myagkova, I., Shiroky, V., Dolenko, S., 2017. Prediction of geomagnetic indexes with the help of artificial neural networks. In: E3S Web Conference Volume 20, 2017 VIII International Conference "Solar-Terrestrial Relations and Physics of Earthquake Precursors". <https://doi.org/10.1051/e3sconf/20172002011>
- Myllys, M., Partamies, N., Juusola, L., 2015. Latitude dependence of long-term geomagnetic activity and its solar wind drivers, *Annales Geophysicae* 33(5), 573-581. <https://doi.org/10.5194/angeo-33-573-2015>
- Raschka S., 2015. Python Machine Learning, Packt Publishing
- Raschka, S., Mirjalili, V., 2019. Python Machine Learning: Machine Learning and Deep Learning with Python, scikit-learn, and TensorFlow 2. Packt Publishing
- Rastogi R.G., 1993. Geomagnetic field variations at low latitudes and ionospheric electric fields, *Journal of Atmospheric and Terrestrial Physics* 55(10), 1375-1381. [https://doi.org/10.1016/0021-9169\(93\)90105-8](https://doi.org/10.1016/0021-9169(93)90105-8)
- Rastogi, R.G., 2005. Magnetic storm effects in H and D components of the geomagnetic field at low and middle latitudes, *Journal of Atmospheric and Solar-Terrestrial Physics*, 67(7), 665-675. <https://doi.org/10.1016/j.jastp.2004.11.002>
- Richmond, A. D. (1995). The ionospheric wind dynamo: Effects of its coupling with different atmospheric regions. In R. M. Johnson & T. L. Killeen (Eds.), *The upper mesosphere and lower thermosphere: A review of experiment and theory* (Vol. 87, pp. 49-65). American Geophysical Union. <https://doi.org/10.1029/GM087p0049>
- Richmond, A. D., 2011. Electrodynamics of Ionosphere-Thermosphere Coupling. In: Bhattacharyya, A., Pancheva, D., Abdu, M.A. (eds) *Aeronomy of the Earth's Atmosphere and Ionosphere*, Springer Netherlands, pp. 191-201
- Sierra-Porta, D. Petro-Ramos, J.D., Ruiz-Morales, D.J., Herrera-Acevedo, D.D., García-Teheran, A.F., Tarazona Alavarado, M., 2024. Machine learning models for predicting geomagnetic storms across five solar cycles using Dst index and heliospheric variables, *Advances in Space Research* 74(8), 3483-349. <https://doi.org/10.1016/j.asr.2024.08.031>
- Suparta, W., Gusrizal., Ali, MAM. and Ahmad, N., 2013. Distribution of energetic particle fluxes in the vicinity of SAA according to kriging interpolation. In: 2013 IEEE International Conference on Space Science and Communication (IconSpace), 1-3 July 2013 (pp. 17-22). <https://doi.org/10.1109/IconSpace.2013.6599425>
- Syafitri, N., Putra, A.Y., Erlansyah, Muzirwan, Rasidi, H., Purnama, S.A., Suryaputra, H., Kilowasid, L.O.M.M., Wisnu, K., Bakri, I., Nurdiansah, L., Nuraeni, F., Purnomo, C. and Rasimeng, S., 2022. Analysis of H-Component of Geomagnetic Variation in Indonesian Region. In: IC3INA '22: Proceedings of the 2022 International Conference on Computer, Control, Informatics and Its Applications (pp. 341-344). <https://doi.org/10.1145/3575882.3575948>
- Takeda, M., Iyemori, T. and Saito, A., 2003. Relationship between electric field and currents in the ionosphere and the geomagnetic Sq field, *Journal of Geophysical Research*, 108(A5), 1183. <https://doi.org/10.1029/2002JA009659>
- Tan, Y., Hu, Q., Wang, Z. and Zhong, Q., 2018. Geomagnetic index Kp forecasting with LSTM, *Space Weather* 16(4), 406-416. <https://doi.org/10.1002/2017SW001764>

- Thébault, E., and Vervelidou, F. 2015. A statistical spatial power spectrum of the Earth's lithospheric magnetic field. *Geophysical Journal International*, 201(2), 605–620. <https://doi.org/10.1093/gji/ggu463>
- Tsyganenko N. A., Sitnov, M.I., 2007. Magnetospheric configurations from a high-resolution data-based magnetic field model, *Journal of Geophysical Research* 112(A6), A06225. <https://doi.org/10.1029/2007JA012260>
- Uwamahoro, J., Habarulema, J.B. (2014). Empirical modeling of the storm time geomagnetic indices: A comparison between the local K and global Kp indices, *Earth Planets and Space* 66(95). <https://doi.org/10.1186/1880-5981-66-95>
- Vorobev, A.V., Vorobeva, R.G., 2023. Machine Learning for Diagnostics of Space Weather Effects for the Arctic Region, *Moscow Univ. Phys.* 78 (Suppl 1), S226–S235. <https://doi.org/10.3103/S0027134923070317>
- Wang J, Luo B, Liu S., Shi L., 2023. A machine learning-based model for the next 3-day geomagnetic index (Kp) forecast, *Front. Astron. Space Sci.* 10, 1082737. <https://doi.org/10.3389/fspas.2023.1082737>
- Yamazaki, Y., Maute, A., 2017. Sq and EEJ—A Review on the Daily Variation of the Geomagnetic Field Caused by Ionospheric Dynamo Currents, *Space Science Reviews* 206, 299–405. <https://doi.org/10.1007/s11214-016-0282-z>
- Yumoto K. and the MAGDAS Group, 2006. MAGDAS project and its application for space weather, In: Gopalswamy N. and Bhattacharyya A. (eds) *Solar Influence on the Heliosphere and Earth's Environment: Recent Progress and Prospects*, pp. 309–405.