

Implementasi Algoritma *Extreme Learning Machine* pada Prediksi Aktivitas Badai Geomagnetik

Extreme Learning Machine Algorithm Implementation on Predicting Geomagnetic Storm Activity

Irsyad Riandri Dana Prawira ^{#1}, Rani Megasari ^{#2}, Eki Nugraha ^{#3}, Anton Winarko ^{*4}

[#]Departemen Pendidikan Ilmu Komputer, Universitas Pendidikan Indonesia

Bandung, Indonesia

¹ irsyad.riandri.d@student.upi.edu

^{2,3} {megasari, ekinugraha}@upi.edu

^{*}Divisi Surya dan Ruang Angkasa Pusat Sains Antariksa, LAPAN

Bandung, Indonesia

⁴anton.winarko@lapan.go.id

Abstrak—Badai geomagnetik merupakan gangguan yang terjadi di magnetosfer bumi, akibat adanya aktivitas matahari yang dapat berdampak pada infrastruktur listrik di bumi. Sebagai peringatan dini, Lembaga Penerbangan dan Antariksa Nasional (LAPAN) di Indonesia memiliki kegiatan rutin untuk memprediksi kemungkinan terjadinya badai tersebut dalam rentang waktu 24 jam ke depan. Namun pada tahun 2015, hasil prediksi badai geomagnetik yang dilakukan secara manual oleh LAPAN hanya mendapatkan akurasi sebesar 57.14%. Oleh karena itu, penelitian ini mengusulkan pemanfaatan metode *Extreme Learning Machine (ELM)* dengan inisiasi bobot dan bias input secara acak sehingga memiliki waktu eksekusi cepat dalam melakukan prediksi badai geomagnetik, yang bertujuan untuk mendapatkan nilai prediksi secara otomatis dengan nilai akurasi yang dapat dijadikan sebagai pendukung keputusan. Data penelitian yang digunakan meliputi data *coronal hole*, *coronal mass ejection*, *solar wind* dan indeks *Dst* pada tahun 2011 hingga 2016. Hasil penelitian ini menunjukkan algoritma ELM memiliki tingkat akurasi yang lebih besar dalam memprediksi badai geomagnetik tahun 2015, dengan nilai 57.80822%. Meskipun memiliki selisih akurasi yang kecil, namun pemanfaatan ELM ini dapat membantu prediksi badai geomagnetik secara otomatis. Secara umum, algoritma ELM yang dibangun dalam penelitian ini memiliki nilai rata-rata akurasi prediksi tertinggi sebesar 69.9055%.

Kata Kunci: Prediksi; *Machine Learning*; Klasifikasi; *Extreme Learning Machine*; Badai Geomagnetik; Indeks *Dst*.

Abstract – Geomagnetic storms are interference that happens on Earth’s magnetosphere, due to the presence of the sun’s activity that could affect Earth’s electricity infrastructure. As an early warning, Indonesia’s National Institute of Aeronautics and Space (LAPAN) has a routine on predicting the possibility of said storm occurring within the span of the

next 24 hours. But as of 2015, the accuracy rate of LAPAN’s prediction of the geomagnetic storm is only at 57.14%. Thus, this research suggests the utilization of *Extreme Learning Machine (ELM)* method with weight initiation and random input bias such that the execution time of the geomagnetic storm prediction will be fast, which aims to automatically acquire prediction value with an accuracy value that can be used as the decision’s support. Research data used consists of coronal hole data, coronal mass ejection data, solar wind data and *Dst* index from 2011 to 2016. The result of this research shows that ELM algorithm has a higher accuracy rate on predicting geomagnetic storms in 2015, with the value of 57.80822%. Despite the small difference in the accuracy rate, the utilization of ELM helps in automatically predicting geomagnetic storms. Generally, the ELM algorithm built in this research has an average of highest prediction accuracy value of 69.9055%.

Keywords: Prediction; *Machine Learning*; Classification; *Extreme Learning Machine*; Geomagnetik storms; *Dst* index.

I. PENDAHULUAN

Badai geomagnetik merupakan gangguan utama pada magnetosfer bumi yang terjadi ketika terdapat perubahan energi secara signifikan dari angin matahari terhadap lingkungan di ruang angkasa yang melingkupi bumi [1]. Badai geomagnetik muncul ketika intensitas medan geomagnetik global menurun pada urutan puluhan hingga ratusan nanotesla (nT) yang terjadi pada skala terbesar dalam gabungan sistem tata surya angin-magnetosfer-ionosfer [2]. Badai geomagnetik ini dapat diklasifikasikan berdasarkan tingkat kekuatannya, meliputi *quite*, *active*, *minor storm*, *moderate storm*, *major storm* dan *severe storm* [3]. Kemunculan badai geomagnetik ini dapat berpotensi meningkatkan konsentrasi ozon yang menyebabkan bertambahnya temperatur di permukaan

bumi [4]. Peningkatan temperatur di muka bumi ini merupakan penyebab terjadinya pemanasan global [5]. Selain itu, kemunculan badai geomagnetik pun dapat menyebabkan peningkatan kuat arus pada trafo listrik sehingga terjadi ketidakseimbangan saluran transmisi dan berdampak pada padamnya jaringan listrik [6].

Munculnya fenomena badai geomagnetik ini telah menginisiasi para peneliti khususnya di bidang matahari untuk melakukan prediksi terhadap aktivitas badai tersebut. Di Indonesia, penelitian dalam melakukan prediksi aktivitas badai geomagnetik dilakukan oleh Lembaga Penerbangan dan Antariksa Nasional (LAPAN). Pada tahun 2015, Pusat Sains Antariksa LAPAN membangun aplikasi *website Space Weather Information and Forecast Services (SWIFtS)* yang salah satu fiturnya menunjukkan hasil prediksi manual aktivitas badai geomagnetik oleh LAPAN, sebagai peringatan dini apabila badai tersebut terjadi. Pada tahun 2015, tim *forecaster* yang merupakan sebutan bagi para peneliti matahari di LAPAN dan pakar SWIFtS melakukan kegiatan peramalan, secara manual hanya dapat memprediksi dengan tepat aktivitas badai geomagnetik dengan akurasi sebesar 57.14% [7].

Dalam rangka membantu proses peramalan aktivitas badai geomagnetik secara otomatis, dalam penelitian ini dilakukan prediksi dengan memanfaatkan metode *machine learning* menggunakan algoritma *Extreme Learning Machine (ELM)*. Algoritma ELM ini telah terbukti memiliki performa generalisasi yang baik dan menunjukkan pencapaian tingkat galat yang kecil meskipun dalam waktu pembelajaran yang sangat cepat [8]. Sebagai pijakan awal, akurasi yang didapatkan LAPAN pada tahun 2015 dijadikan tolak ukur untuk terbentuknya akurasi prediksi yang lebih baik dengan diimplementasikannya metode ELM ini. Penelitian ini pun merupakan penelitian pertama yang memanfaatkan metode *machine learning* dalam membantu prediksi aktivitas badai geomagnetik di LAPAN. Pemanfaatan metode ELM ini diharapkan dapat menambah variasi baru dalam melakukan model prediksi aktivitas badai geomagnetik serta dapat dijadikan alat bantu pendukung keputusan para peneliti dalam melakukan prediksi aktivitas geomagnet pada tahun-tahun berikutnya.

II. PENELITIAN TERKAIT

Penelitian dengan memanfaatkan metode *machine learning* dalam melakukan prediksi terhadap aktivitas badai geomagnetik telah dilakukan sebelumnya oleh beberapa peneliti di seluruh dunia. Sebagai contoh, pemanfaatan algoritma *Multivariate Relevance Vector Machine (MVRVM)* pernah digunakan dalam memprediksi indeks Dst, *Amplitude Lower (AL)* dan *Polar Cap (PC)* [9]. Penelitian tersebut menggunakan data *solar wind* dan indeks geomagnetik dari satelit *Advanced Composition Explorer (ACE)* dan *WIND* pada rentang tahun 1975 hingga 2007. Proses pembelajaran model MVRVM tersebut menggunakan 5 buah parameter meliputi *interplanetary magnetic field (IMF)* B_y dan B_z , kecepatan angin matahari, densitas ion plasma matahari,

serta turunan dari kecepatan dan densitas. Hasil dari penelitian tersebut menunjukkan nilai *prediction efficiency (PE)* untuk masing-masing indeks yaitu 82.42%, 84.40%, dan 76.00%.

Lalu dalam penelitian lain dilakukan pula prediksi badai geomagnetik berdasarkan indeks *Auroral Electrojet (AE)* menggunakan empat model *Neuro-Fuzzy* yaitu *Brain Emotional Learning Based Fuzzy Inference System (BELFIS)*, *Brain Emotional Learning Recurrent Fuzzy System (BELRFS)*, *Adaptive Neuro-Fuzzy Inference System (ANFIS)* dan *Locally Linear Model Tree (LoLiMoT)* [10]. Data indeks AE yang digunakan pada penelitian tersebut didapatkan dari *World Data Center for Geomagnetism and Space Magnetism* di Universitas Kyoto. Hasil prediksi dari penelitian tersebut menunjukkan nilai *normalised mean square error (NMSE)* untuk masing-masing model sebesar 0.0125, 0.0224, 0.0215, dan 0.0273, serta rata-rata error sebesar 10.2 %, 10.5 % 10.66 % dan 22.9 %.

Pada penelitian lainnya, digunakan algoritma *time-delay neural network* yang dioptimasi menggunakan *particle swarm optimization*, untuk memprediksi indeks Dst dari *auroral electrojet (AE)* [11]. Penelitian tersebut menggunakan *dataset* indeks Dst dan *auroral electrojet* pada tahun 2000 hingga 2004 pada proses pembelajaran dan data tahun 2005 untuk proses pengujian atau prediksi. Hasil dari penelitian tersebut menunjukkan tingkat akurasi prediksi menggunakan 2 perhitungan yang berbeda dengan nilai masing-masing 0.9661 dan 0.9653.

Selain itu terdapat pula berbagai macam metode *machine learning* lainnya yang digunakan dalam melakukan prediksi aktivitas badai geomagnetik, seperti *singular spectrum analysis* dan *fuzzy descriptor models* untuk memprediksi aktivitas harian matahari dan geomagnetik [12], *dynamic neural networks* [13], *bayesian regularization*, *levenberg marquardt*, *non-autoregressive neural network multilayer perceptron*, *linear regression enter* dan *linear regression stepwise* untuk memprediksi fluktuasi indeks Dst [14], *particle swarm optimization*, *gaussian processes autoregressive* untuk memprediksi indeks Dst [15], serta *support vector machine* untuk memprediksi kondisi CME yang geoeftif [16].

III. DATA

Data yang digunakan dalam penelitian ini meliputi data *coronal hole (CH)*, *solar wind*, *coronal mass ejection (CME)* dengan target klasifikasi kelas aktivitas badai geomagnetik yang ditunjukkan oleh indeks Dst. Data yang digunakan merupakan data pada tanggal 1 Januari 2011 hingga 31 Desember 2016. Semua data parameter yang digunakan diambil dari empat buah halaman website yang digunakan oleh LAPAN dalam melakukan peramalan aktivitas geomagnetik harian. Adapun keempat halaman website tersebut meliputi *CACTUS CME List* dari *Solar Influences Data Analysis Center* yang berisi data *coronal mass ejection (CME)* melalui link url <http://sidc.oma.be/cactus/catalog.php>, *iSolSearch* dari *Atmospheric Imaging Assembly* yang berisi data *coronal*

hole (CH) melalui link url <http://suntoday.lmsal.com/suntoday/>, Solar and Heliospheric Observatory (SOHO) dari NASA yang berisi data solar wind melalui link url <ftp://sohoftp.nascom.nasa.gov/sdb/goes/ace/daily/>, serta Geomagnetic Equatorial Dst index dari World Data Center for Geomagnetism, Kyoto yang berisi data indeks disturbance storm-time (Dst) melalui link url <http://wdc.kugi.kyoto-u.ac.jp/dstdir/index.html> yang digunakan sebagai nilai rujukan untuk menentukan kelas aktivitas badai geomagnetik.

Adapun dataset yang digunakan merupakan data pada tahun 2011 hingga 2016, namun tanpa data tahun 2015. Data tahun 2015 akan dijadikan sebagai data banding hasil prediksi manual aktivitas badai geomagnetik oleh LAPAN dengan prediksi menggunakan ELM. Jumlah dataset yang terkumpul berjumlah 1827 baris data, sedangkan data banding sebanyak 365 baris data. Atribut parameter yang akan dipakai dalam penelitian ini dapat dilihat pada Tabel I.

TABEL I
ATRIBUT PARAMETER YANG DIGUNAKAN DALAM PENELITIAN

No.	Nama Atribut	Type Data
1	Solar wind speed - flux before	Numerik
2	Solar wind speed - flux after	Numerik
3	Solar wind min density	Numerik
4	Solar wind max density	Numerik
5	Solar wind min IMF Bz	Numerik
6	Solar wind max IMF Bz	Numerik
7	CME excistances	Karakter
8	Amount of geoeffective CME	Numerik
9	Min speed CME	Numerik
10	Max speed CME	Numerik
11	Total CH event	Numerik
12	Total CH area	Numerik
13	Total CH event day-1	Numerik
14	Total CH area day-1	Numerik
15	Total CH event day-2	Numerik
16	Total CH area day-2	Numerik
17	Total CH event day-3	Numerik
18	Total CH area day-3	Numerik
19	Total CH event day-4	Numerik
20	Total CH area day-4	Numerik
21	Judgement (target klasifikasi)	Karakter

Berdasarkan TABEL I, atribut parameter yang digunakan pada proses pembelajaran dan pengujian berjumlah 20 buah dengan rincian 19 tipe data numerik dan 1 tipe data karakter. Lalu ditambah dengan 1 buah target kelas klasifikasi bertipe data karakter, yang menunjukkan tingkat kekuatan aktivitas badai geomagnetik. Target klasifikasi pada dataset berisi 1277 kelas quiet, 352 kelas active, 154 kelas minor storm, 42 kelas moderate storm, dan 2 kelas major storm.

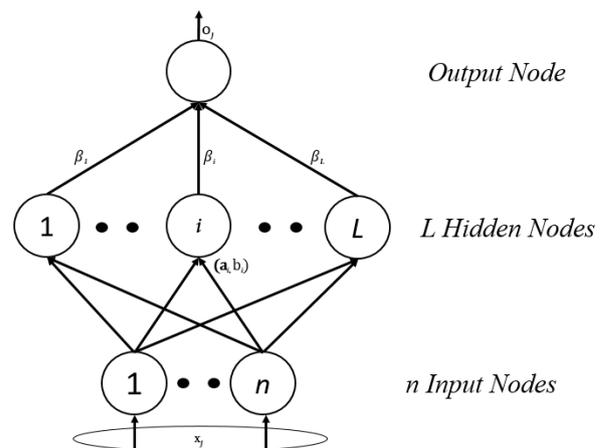
Sedangkan target klasifikasi pada data banding berisi 211 kelas quiet, 90 kelas active, 45 kelas minor storm, 14 kelas moderate storm, dan 5 kelas major storm. Kelas severe storm tidak dapat diprediksi karena tidak terdapat satupun sampel data yang mewakili kelas tersebut, sehingga dalam penelitian ini berfokus pada prediksi aktivitas badai geomagnetik dengan kelas quiet, active, minor storm, moderate storm, dan major storm.

IV. Prediksi Badai Geomagnetik Menggunakan ELM

Dalam penelitian ini dibangun model ELM yang akan digunakan dalam melakukan prediksi aktivitas badai geomagnetik. Penjelasan mengenai pemodelan tersebut akan dijabarkan sebagai berikut.

A. Extreme Learning Machine

Extreme Learning Machine (ELM) adalah algoritma pembelajaran sederhana untuk Single Layer Feedforward Neural Network (SLFN) dengan waktu pembelajaran hingga ribuan kali lebih cepat jika dibandingkan dengan feedforward neural network tradisional seperti backpropagation [17]. Teori dalam algoritma ELM ini menunjukkan bahwa hidden neuron dalam model jaringan syaraf tiruan sangatlah penting, namun nilainya dapat ditentukan secara acak dan bersifat independen dari aplikasi yang dibuat. Meskipun bobot lapisan tersembunyi bersifat acak, telah terbukti bahwa ELM masih mampu melakukan pendekatan universal terhadap fungsi non-konstan piecewise yang bersifat kontinu kontinu [18, 19]. Disamping itu, model ini pun memiliki kemampuan klasifikasi dan aproksimasi yang umum, bahkan dapat membangun hubungan secara langsung antara berbagai teori (regresi, optimasi, stabilitas sistem linier, performa generalisasi jaringan syaraf tiruan dan matriks) [20]. Aritektur jaringan ELM dapat dilihat pada Gambar 1. Adapun tahapan yang diterapkan dalam algoritma ELM ini dapat dijabarkan sebagai berikut.



Gambar. 1 Arsitektur Jaringan ELM.

Jika terdapat sebuah kumpulan sampel N yang berbeda (x_i, y_i) dengan $x_i \in \mathbb{R}^d$ dan $y_i \in \mathbb{R}$, kemudian

keluaran dari sebuah SLFN dengan neuron sebanyak M dapat didefinisikan sebagai:

$$\hat{y}_j = \sum_{i=1}^M \beta_i f(w_i x_j + b_i), j \in [1, N] \quad (1)$$

Keluaran \hat{y}_j merupakan aproksimasi dari y_j , f merupakan fungsi aktivasi, w_i merupakan vektor bobot masukan, b_i merupakan bias lapisan tersembunyi dan β_i merupakan bobot keluaran yang bersesuaian dengan neuron ke- i pada lapisan tersembunyi.

Dalam kasus SLFN yang secara sempurna mengaproksimasi data (yaitu kesalahan antara keluaran \hat{y}_j dan nilai sebenarnya y_j adalah nol), relasinya akan berubah menjadi:

$$\sum_{i=1}^M \beta_i f(w_i x_j + b_i) = y_j, j \in [1, N]$$

yang dapat ditulis secara singkat menjadi:

$$H\beta = Y$$

dimana H adalah matriks keluaran lapisan tersembunyi yang didefinisikan sebagai:

$$H = \begin{pmatrix} f(w_1 x_1 + b_1) & \dots & f(w_M x_1 + b_M) \\ \vdots & \ddots & \vdots \\ f(w_1 x_N + b_1) & \dots & f(w_M x_N + b_M) \end{pmatrix}$$

dan untuk nilai bobot menuju *output layer*:

$$\beta_i = (\beta_1 \dots \beta_M)^T$$

serta nilai *output*:

$$Y = (y_1 \dots y_N)^T$$

Secara lebih ringkas, algoritma ELM dapat dimodelkan dengan tiga langkah pembelajaran, yang dapat dijabarkan pada penjelasan berikut ini.

Jika diketahui:

- training set $X = \{ (x_i, t_i) \mid x_i \in \mathbb{R}^n; t_i \in \mathbb{R}^m; i=1, \dots, N \}$,
- fungsi aktivasi G , dan
- jumlah hidden nodes L ,

maka langkah yang dapat dilakukan untuk melakukan pemodelan algoritma ELM ini adalah sebagai berikut.

- Langkah 1: Tetapkan bobot setiap input (a_i) dengan nilai random dan bobot bias pada hidden node (b_i), dimana i adalah iterasi sejumlah nilai L , $i=1,2,\dots,L$.
- Langkah 2: Hitung matriks H , yang merupakan *output* atau nilai pada *node* di *hidden layer*.

- Langkah 3: Hitung Nilai β , yang merupakan bobot menuju *output node*. Nilai bobot ini dihitung dengan rumus:

$$\alpha + \beta = \chi \quad (1) \quad (7)$$

$$\beta = H^+ T$$

dimana H^+ adalah *Moore-Penrose generalized invers* dari matriks H .

B. Persiapan dan Praproses Data

Agar data yang telah terkumpul siap untuk digunakan pada proses pembelajaran dan pengujian dengan ELM, akan dilakukan persiapan dan praproses terlebih dahulu melalui tahapan transformasi data, normalisasi data, serta pembagian data latih dan data uji. Pada tahapan transformasi data, semua data bertipe karakter (*CME existence dan judgement*) akan ditransformasi menjadi tipe data numerik untuk memudahkan proses kalkulasi. Selanjutnya pada tahapan normalisasi data, akan diterapkan normalisasi berdasarkan nilai minimum dan maksimum yang ada pada masing-masing atribut, sehingga akan menghasilkan rentang nilai antara 0 hingga 1.

Pada tahapan pembagian data latih dan uji, akan digunakan teknik *k-fold cross validation*, dimana data set akan direplikasi sebanyak k buah, dan untuk setiap *fold* akan dibagi ke dalam k sub-bagian. Setiap 1 bagian akan dijadikan sebagai data uji dan $k-1$ bagian lainnya sebagai data latih. Proses pembagian sub-bagian di tiap *fold* dilakukan dengan menentukan indeks data secara acak.

C. Implementasi ELM dan Eksperimen

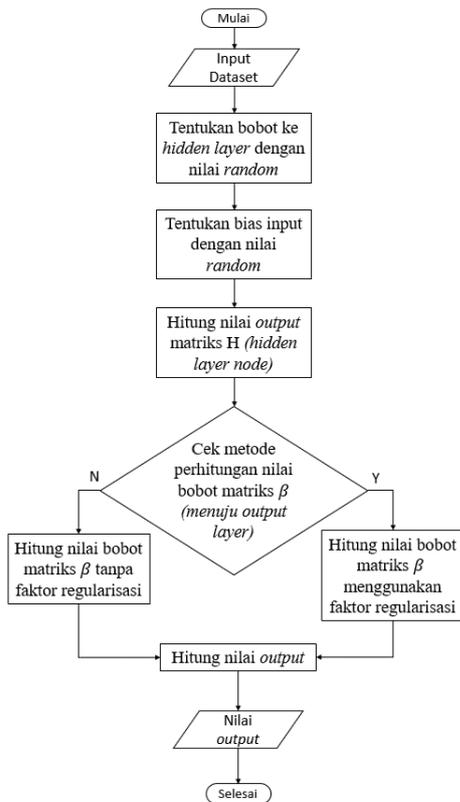
Gambaran umum proses pada algoritma ELM yang dilakukan dalam penelitian ini dapat dilihat pada Gambar 2.

Berdasarkan Gambar 2, alur algoritma ELM yang dilakukan dalam penelitian ini terdiri dari beberapa tahapan meliputi:

- penentuan matriks bobot *hidden layer* secara acak,
- penentuan matriks bias *input* secara acak,
- kalkulasi nilai *output matriks hidden layer*,
- kalkulasi nilai bobot matriks menuju *output layer*,
- perhitungan nilai *output* klasifikasi.

Dalam penelitian ini, eksperimen yang dilakukan terbagi ke dalam 2 bagian besar, yaitu proses perhitungan nilai bobot matriks β menggunakan faktor regularisasi dan tanpa menggunakan faktor regularisasi, seperti yang digambarkan pada Gambar 2. Dalam masing-masing eksperimen akan dibagi lagi ke dalam beberapa bagian sub eksperimen berdasarkan nilai parameter yang digunakan, meliputi jumlah *fold* proses *k-fold cross validation*, jumlah *node* pada *hidden layer*, dan fungsi aktivasi yang akan diterapkan untuk mencari matriks H . Sedangkan pada eksperimen dengan menggunakan faktor regularisasi, akan ditambahkan pula parameter koefisien regularisasi. Dalam penelitian ini, nilai dari masing-

masing parameter yang akan digunakan pada eksperimen akan ditunjukkan pada Tabel 2.



Gambar 2. Flowchart Proses Algoritma ELM.

TABEL II
NILAI PARAMETER EKSPERIMEN

No.	Parameter	Nilai Parameter yang Digunakan
1	Jumlah <i>fold</i>	5, 10
2	Jumlah <i>hidden node</i>	5, 10, 20, 50, 100
3	Fungsi aktivasi	1, 2, 3, 4
4	Penggunaan Regularisasi	0, 1
5	Nilai koefisien regularisasi (C)	0.01, 0.1, 1, 10, 100

Pada TABEL II, nilai parameter fungsi aktivasi ditunjukkan oleh angka yang masing-masing merepresentasikan metode yang dipakainya. Nilai 1 merepresentasikan sigmoid unipolar, 2 merepresentasikan sigmoid bipolar, 3 merepresentasikan tangen *hyperbolic*, dan 4 merepresentasikan radial basis. Sedangkan pada penggunaan regularisasi, nilai 1 merepresentasikan eksperimen dengan menggunakan faktor regularisasi dan nilai 0 merepresentasikan eksperimen tanpa faktor regularisasi.

Eksperimen dengan menggunakan faktor regularisasi dilakukan sebanyak 200 kali. Jumlah eksperimen ini merupakan kombinasi dari penggunaan parameter jumlah

fold, jumlah *hidden node*, fungsi aktivasi, dan nilai C. Sedangkan eksperimen tanpa menggunakan faktor regularisasi dilakukan sebanyak 40 kali. Jumlah eksperimen tersebut merupakan kombinasi dari penggunaan parameter jumlah *fold*, jumlah *hidden node*, dan fungsi aktivasi.

Setelah proses eksperimen, akan dilakukan penyeleksian penggunaan parameter. Nilai parameter pada masing-masing eksperimen yang memiliki nilai rata-rata akurasi *testing* tertinggi, akan digunakan sebagai parameter pembelajaran dataset. Bobot yang didapatkan pada proses pembelajaran tersebut selanjutnya akan digunakan untuk memprediksi aktivitas badai geomagnetik tahun 2015.

V. HASIL DAN PEMBAHASAN

Berdasarkan eksperimen yang dilakukan dalam penelitian ini, didapatkan perbedaan nilai rata-rata akurasi yang akan ditunjukkan pada Tabel 3.

TABEL III
RANGKUMAN HASIL EKSPERIMEN

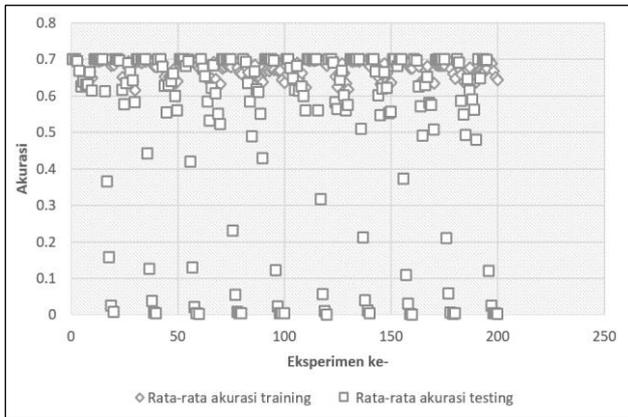
Eksperimen	Nilai Rata-rata Akurasi Tertinggi Training	Nilai Rata-rata Akurasi Tertinggi Testing	Nilai Rata-rata Waktu Eksekusi Training	Nilai Rata-rata Waktu Eksekusi Testing
Menggunakan faktor regularisasi	0.699099	0.699055	0.01244	0.0023
Tanpa faktor regularisasi	0.697986	0.698977	0.024415	0.002463

Berdasarkan eksperimen yang dilakukan, nilai rata-rata akurasi *training* dan *testing* pada eksperimen menggunakan faktor regularisasi menunjukkan nilai yang lebih besar, dengan selisih angka 0.000078 dan 0.001113. Sedangkan eksekusi *training* dan *testing* pada eksperimen menggunakan faktor regularisasi juga menunjukkan waktu yang lebih cepat dengan selisih 0.011975 detik dan 0.000163 detik. Grafik sebaran akurasi *training* dan *testing* pada masing-masing eksperimen dapat dilihat pada Gambar 3 dan Gambar 4.

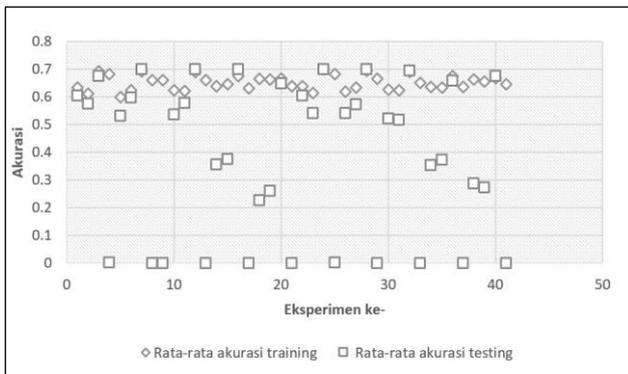
Pada Gambar 3 dan Gambar 4, memiliki pola sebaran nilai rata-rata akurasi yang hampir sama. Nilai rata-rata *training* cenderung stabil pada rentang akurasi 0.6 hingga 0.7. Sedangkan nilai rata-rata akurasi *testing* lebih berfluktuatif dan cenderung stabil pada rentang 0.5 hingga 0.7.

Berdasarkan hasil eksperimen, maka untuk melakukan perbandingan prediksi menggunakan algoritma ELM pada data tahun 2015, akan digunakan parameter dengan hasil akurasi *testing* tertinggi pada masing-masing

eksperimen. Pada eksperimen menggunakan faktor regularisasi, didapatkan akurasi *testing* tertinggi sebesar 0.699099 dengan menggunakan parameter jumlah *fold* 10, jumlah *hidden node* 50, fungsi aktivasi sigmoid unipolar dan nilai koefisien regularisasi 0.01. Sedangkan pada eksperimen tanpa faktor regularisasi, didapatkan akurasi *testing* tertinggi sebesar 0.697986 dengan menggunakan parameter jumlah *fold* 5, jumlah *hidden node* 50, dan fungsi aktivasi tangen *hyperbolic*.



Gambar 3. Grafik Sebaran Akurasi pada Eksperimen Menggunakan Faktor Regularisasi.



Gambar 4. Grafik Sebaran Akurasi pada Eksperimen Tanpa Faktor Regularisasi.

Berdasarkan hasil eksperimen, maka untuk melakukan perbandingan prediksi menggunakan algoritma ELM pada data tahun 2015, akan digunakan parameter dengan hasil akurasi *testing* tertinggi pada masing-masing eksperimen. Pada eksperimen menggunakan faktor regularisasi, didapatkan akurasi *testing* tertinggi sebesar 0.699099 dengan menggunakan parameter jumlah *fold* 10, jumlah *hidden node* 50, fungsi aktivasi sigmoid unipolar dan nilai koefisien regularisasi 0.01. Sedangkan pada eksperimen tanpa faktor regularisasi, didapatkan akurasi *testing* tertinggi sebesar 0.697986 dengan menggunakan parameter jumlah *fold* 5, jumlah *hidden node* 50, dan fungsi aktivasi tangen *hyperbolic*.

Berdasarkan parameter eksperimen yang digunakan untuk melakukan prediksi aktivitas badai geomagnetik tahun 2015 menggunakan ELM baik dengan faktor regularisasi maupun tanpa regularisasi, didapatkan hasil prediksi yang identik sama dengan hasil akurasi prediksi sebesar 57.80822%. Dibandingkan dengan akurasi hasil prediksi yang dilakukan oleh LAPAN secara manual, nilai tersebut menunjukkan hasil yang sedikit lebih besar dengan selisih akurasi 0.0066822.

VI. KESIMPULAN

Berdasarkan hasil dan pembahasan pada eksperimen yang telah dilakukan, eksperimen ELM menggunakan faktor regularisasi menunjukkan hasil yang lebih baik sebesar 0.001113 pada perolehan nilai rata-rata akurasi *testing* tertinggi. Selain itu, proses prediksi aktivitas badai geomagnetik tahun 2015 yang dilakukan menggunakan ELM menunjukkan hasil yang lebih baik dibandingkan dengan prediksi manual oleh LAPAN, dengan perolehan selisih akurasi sebesar 0.0066822. Meskipun hanya memiliki selisih akurasi yang kecil, namun pemanfaatan ELM ini dapat dijadikan alat bantu penentu keputusan bagi LAPAN dalam melakukan prediksi secara otomatis.

Untuk penelitian berikutnya, guna mendapatkan nilai akurasi prediksi yang lebih baik, dapat digunakan versi algoritma ELM lainnya, khususnya untuk mengatasi kasus klasifikasi *multiclass*. Selain itu, dapat juga dilakukan *tuning* parameter yang lebih beragam untuk mendapatkan model yang lebih akurat dalam memprediksi aktivitas badai geomagnetik menggunakan ELM.

REFERENSI

- [1] NOAA, "Geomagnetic Storms," 27 12 2014. [Online]. Available: <http://www.swpc.noaa.gov/phenomena/geomagnetic-storms>.
- [2] N. Tsutomu, "Geomagnetic Storms," *Journal of The Communications Research Laboratory*, pp. 139-154, 2002.
- [3] A. Santoso, D. Nurmallo, M. Juangsih, I. Rusnadi, S. Ekawati, A. Winarko and S. Filawati, "ANALISIS PENGARUH BADAI GEOMAGNET TERHADAP RESPON foF2 IONOSFER DI BPAA SUMEDANG," in *Seminar Nasioanl Sains Antariksa*, Bandung, 2016.
- [4] D. R. Martiningrum, A. Purwono, F. Nuraeni and J. Muhamad, *Fenomena Cuaca Antariksa*, Bandung: Pusat Sains Antariksa Lapan, 2012.
- [1] NOAA, "Geomagnetic Storms," 27 12 2014. [Online]. Available: <http://www.swpc.noaa.gov/phenomena/geomagnetic-storms>.
- [2] N. Tsutomu, "Geomagnetic Storms," *Journal of The Communications Research Laboratory*, pp. 139-154, 2002.
- [3] A. Santoso, D. Nurmallo, M. Juangsih, I. Rusnadi, S. Ekawati, A. Winarko and S. Filawati, "ANALISIS PENGARUH BADAI GEOMAGNET TERHADAP RESPON foF2 IONOSFER DI BPAA SUMEDANG," in *Seminar Nasioanl Sains Antariksa*, Bandung, 2016.
- [4] D. R. Martiningrum, A. Purwono, F. Nuraeni and J. Muhamad, *Fenomena Cuaca Antariksa*, Bandung: Pusat Sains Antariksa Lapan, 2012.
- [5] Riebeek, "Global Warming," NASA Earth Observatory, 3 6 2010. [Online]. Available: <https://earthobservatory.nasa.gov/Features/GlobalWarming/>. [Accessed 15 11 2017].

- [6] H. Quebec, "In March 1989, Quebec experienced a blackout caused by a solar storm," 9 3 2012. [Online]. Available: <http://www.hydroquebec.com/learning/notions-de-base/tempe-mars-1989.html>.
- [7] A. Winarko, "Sekilas Review Akurasi Prediksi Aktivitas Geomagnet pada SWIFtS 2015," Buletin Cuaca Antariksa, pp. 22-23, April-Juni 2016.
- [8] G. Huang, "Extreme learning machine theory and applications," Science Direct, 2006.
- [9] T. Andriyas and S. Andriyas, "Use of Multivariate Relevance Vector Machines in Forecasting Multiple Geomagnetic Indices," Journal of Atmosphere and Slar-Terrestrial Physics, pp. 21-32, 2017.
- [10] M. Parsapoor, U. Bilstrup and B. Svensson, "Neuro-fuzzy Models for Geomagnetic Storms Prediction: Using the Auroral Electrojet Index," in 10th International Conference on Natural Computation (ICNC), Piscataway, 2014.
- [11] J. Lazzus, C. Lopez-Caraballo, P. Rojas, I. Salfate, M. Rivera and L. Palma-Chilla, "Forecasting of DST index from auroral electrojet indices using time-delay neural network + particle swarm optimization," Journal of Physic, pp. 1-7, 2016.
- [12] M. Mirmomeni, E. Kamaliha, M. Shafiee and C. Lucas , "Long-term prediction of solar and geomagnetic activity daily time series using singular spectrum analysis and fuzzy descriptor models," Earth Planet Space, pp. 1089-1101, 2009.
- [13] J.-G. Wu and H. Lundstedt, "Geomacnetic storm predictions from solar wind data with the use of dynamic neural networks," Journal of geophysical research, pp. 255-268, 1997.
- [14] J. Casswell, "A Nonlinear Autoregressive Approach to Statistical Prediction of Disturbance Storm Time Geomagnetic Fluctuations Using Solar Daa," Journal of Signal and Information Processing, pp. 42-53, 2014.
- [15] M. Chandorkar, E. Camporeale and S. Wing, "Gaussian Processes Autoregressive Models for Forcasiting the Disturbance Storm Index," Journal of Space Weather and Space Climate, 1997.
- [16] S. Choi, Y. Moon, N. Vien and Y. Park, "Application of support vector machine to prediction of geo-effective halo CMES," Journal of the Korean Astronomical Society, pp. 31-38, 2012.
- [17] Huang, "Extreme learning machine Theory and applications," Science Direct, p. 490, 2006.
- [18] G.-B. Huang, L. Chen and C.-K. Siew, "Universal approximation using incremental constructive feedforward networks with random hidden nodes," IEEE Transactions on Neural Networks, 17(4), pp. 879-892, 2006.
- [19] G. Huang and L. Chen, "Convex incremental extreme learning machine," Neurocomputing, pp. 3056-3062, 2007.
- [20] E. Cambria, "Extreme Learning Machines," IEEE Intelligent Systems, pp. 30-59, 11-12 2013.