

PRAKIRAAN *FLARE* SINAR-X MATAHARI BERDASARKAN EVOLUSI DAERAH AKTIF (PREDICTION OF SOLAR X-RAY FLARES BASED ON ACTIVE REGIONS EVOLUTION)

Santi Sulistiani* dan Tiar Dani

Pusat Sains Antariksa, Lembaga Penerbangan dan Antariksa Nasional (LAPAN), Indonesia

*e-mail: santi.sulistiani@lapan.go.id

Diterima 27 Desember 2018; Direvisi 27 Februari 2019; Disetujui 28 Februari 2019

ABSTRACT

Solar flares are known to originate from active regions and can release energy up to 10^{23} ergs. Radiation from a solar flare can ionize the Earth's upper atmosphere and cause radio communication disruption. Therefore, solar flare prediction is very important for space weather early warning. This study aims to improve the prediction of x-ray flare produced by an active region for the next 24 hours based on active region's three-days evolution including heliographic latitude and longitude, area, individual spot count and McIntosh and Hale classifications. Flare prediction model was developed by using random forest algorithm. The most optimum configurations used in this algorithm yield a prediction model with accuracy of around 75% for predicting non-flaring conditions, around 40-45% for predicting C and M class flares and around 80% for predicting X class flares. A configuration of 500 trees and 90 leaves yields a prediction of \geq C class X-ray flare with training accuracy and testing F-score of 71.9% and 70.0%, respectively. While that of 500 trees and 150 leaves yields a prediction with training accuracy and testing F-score of 71.0% and 70.4%, respectively. Physical properties with the highest importances in predicting the solar flare are the area, Hale class, McIntosh class, spot count, and heliographic longitude 24 and 48 hours prior to flare occurrence. This flare prediction model can be used to support SWIFtS activity that has been operating in LAPAN since 2015.

Keywords: *solar flare, prediction, active region, McIntosh classification, Hale classification, random forest*

ABSTRAK

Flare Matahari diketahui berasal dari daerah aktif dan dapat melontarkan energi hingga 10^{23} erg. Radiasi *flare* Matahari dapat mengionisasi atmosfer-atas Bumi sehingga mengakibatkan terganggunya komunikasi radio. Oleh karena itu, prakiraan *flare* Matahari sangat penting untuk peringatan dini cuaca antariksa. Makalah ini bertujuan untuk mengembangkan sistem prakiraan *flare* sinar-X yang dihasilkan suatu daerah aktif untuk 24 jam ke depan menggunakan masukan perubahan parameter dari daerah aktif selama tiga hari sebelum terjadinya *flare*, meliputi posisi lintang dan bujur heliografis, luas, jumlah bintik, dan kelas McIntosh dan Hale. Model prakiraan *flare* dikembangkan menggunakan salah satu metode *machine learning*, yaitu algoritma *random forest*. Konfigurasi paling optimal yang digunakan dalam algoritma ini menghasilkan model prakiraan dengan akurasi sekitar 75% untuk prakiraan kondisi tanpa-*flare*, sekitar 40-45% untuk prakiraan *flare* kelas C dan M, dan sekitar 80% untuk prakiraan *flare* kelas X. Konfigurasi 500 pohon dan 90 daun menghasilkan prakiraan *flare* sinar-X kelas \geq C dengan akurasi data latih sebesar 71,9% dan F-score data uji sebesar 70,0%. Sementara itu, konfigurasi 500 pohon dan 150 daun menghasilkan prakiraan dengan akurasi data latih sebesar 71,0% dan F-score data uji sebesar 70,4%. Parameter fisis daerah aktif yang paling berkontribusi terhadap prakiraan *flare* adalah luas, kelas Hale, kelas McIntosh, jumlah bintik, dan posisi bujur dalam 24 dan 48 jam menjelang *flare*. Model prakiraan *flare* ini dapat digunakan untuk mendukung kegiatan SWIFtS yang telah beroperasi di LAPAN sejak tahun 2015.

Kata kunci: *flare Matahari, prakiraan, daerah aktif, klasifikasi McIntosh, klasifikasi Hale, random forest*

1 PENDAHULUAN

Flare Matahari adalah peristiwa peningkatan intensitas radiasi pada berbagai panjang gelombang yang berlangsung sangat kuat dan cepat di atmosfer Matahari (Gold dan Hoyle, 1960; Parker, 1963; Hudson, 2011). Berdasarkan fluks puncak pada panjang gelombang sinar-X 1-8 Å, *flare* dibagi menjadi kelas B, C, M, dan X dengan fluks minimum pada saat puncak *flare* masing-masing sebesar 10^{-7} , 10^{-6} , 10^{-5} , dan 10^{-4}Wm^{-2} . Salah satu dampak *flare* terhadap atmosfer Bumi adalah radiasi yang dapat mengakibatkan atmosfer atas Bumi terionisasi dan mengembang sehingga mengganggu komunikasi radio yang memanfaatkan lapisan ionosfer Bumi. Oleh karena itu, prakiraan *flare* Matahari sangat penting untuk peringatan dini cuaca antariksa.

Energi hingga 10^{23} erg (Emslie *et al.* 2012) dilontarkan pada peristiwa *flare*, berupa energi magnet yang disimpan di dalam medan magnet daerah aktif. Dengan kata lain, grup bintik Matahari adalah sumber utama peristiwa *flare* Matahari.

Daerah aktif yang sering diamati sebagai grup bintik Matahari telah lama dipelajari terkait potensinya dalam menghasilkan *flare* Matahari. Berdasarkan kompleksitas magnetnya, bintik Matahari dibagi menjadi delapan kelas, yaitu α , β , γ , $\beta\gamma$, δ , $\beta\delta$, $\beta\gamma\delta$, dan $\gamma\delta$ (Hale *et al.*, 1919; Künzel, 1960). Klasifikasi ini dikenal sebagai klasifikasi Hale atau klasifikasi Mount Wilson. Daerah aktif dengan kompleksitas magnet lebih tinggi dan luas bintik lebih besar menghasilkan *flare* yang lebih kuat (Sammis *et al.*, 2000). Berdasarkan bentangan grup bintik, jenis penumbra bintik utama, dan distribusi bintik, McIntosh (1990) mengklasifikasikan grup bintik Matahari menjadi 60 kelas. Daerah aktif dengan kelas McIntosh lebih tinggi (bentangan lebih lebar dengan penumbra lebih besar dan asimetris, dan memiliki lebih banyak bintik) menghasilkan lebih banyak *flare*

(McIntosh, 1990; Bornmann dan Shaw, 1994; Norquist, 2011).

LAPAN telah membangun sebuah perangkat lunak menggunakan algoritma jaringan saraf tiruan propagasi mundur yang diberi nama SOLARe (*Solar Flare Prediction*) yang mampu memprakirakan kejadian *flare* sinar-X untuk 24 jam ke depan berdasarkan parameter fisis bintik Matahari pada saat itu dengan akurasi maksimum sekitar 75% (Dani *et al.*, 2010). SOLARe pada awalnya dirancang untuk memprakirakan kejadian *flare* berdasarkan parameter fisis yang diperoleh dari pengamatan yang dilakukan di Pusat Sains Antariksa, Balai Pengamat Antariksa dan Atmosfer Sumedang, dan Balai Pengamatan Antariksa dan Atmosfer Pasuruan. LAPAN juga telah mengembangkan layanan prakiraan cuaca antariksa harian di bawah kegiatan bernama SWIFtS (*Space Weather Information and Prediction Services*) yang beroperasi sejak Maret 2015 (Dani, 2016). SOLARe belum dapat memenuhi kebutuhan para *forecaster* SWIFtS dalam memprakirakan *flare* karena hasil evaluasi selama Januari 2017-Maret 2018 menunjukkan bahwa ketepatan prakiraan *flare* menggunakan SOLARe hanya sebesar 68% (Sulistiani *et al.*, 2018). Selain itu, SOLARe belum mempertimbangkan klasifikasi Hale daerah aktif. Sementara itu, studi menunjukkan bahwa kejadian *flare* tidak hanya bergantung pada karakteristik morfologi dan medan magnet fotosfer saat itu, tetapi juga dipengaruhi oleh karakteristik daerah aktif sebelumnya (Yu *et al.* 2009; Li dan Zhu, 2013).

Tujuan dari penelitian ini adalah untuk mengembangkan sistem prakiraan *flare* sinar-X yang dihasilkan suatu daerah aktif untuk 24 jam ke depan berdasarkan klasifikasi McIntosh dan Hale, dan parameter fisik lain dari grup bintik Matahari selama rentang waktu tertentu menggunakan algoritma *random forest* (RF) (Breiman, 2001; Cutler *et al.*, 2012; Cutler, 2014).

Penelitian ini dilakukan untuk mendukung kegiatan SWIFtS dengan menyempurnakan SOLARe.

2 METODOLOGI

2.1 Data

Penelitian ini menggunakan data *flare* sinar-X dan data daerah aktif selama Januari 1998-Juni 2018 yang dirangkum oleh SWPC-NOAA (*Space Weather Prediction Center-National Oceanic and Atmospheric Administration*) pada tautan <ftp://ftp.swpc.noaa.gov/pub/warehouse/>.

Data *flare* sinar-X merupakan hasil pengamatan satelit GOES (*Geostationary Operational Environmental Satellite*) (Allegrino *et al.*, 2011). Data ini mencantumkan informasi mengenai tiap *flare* yang diamati, meliputi waktu awal, maksimum, dan akhir *flare*, posisinya dalam koordinat heliografis, kelas sinar-X, dan nomor NOAA daerah aktif penghasil *flare* tersebut. Penelitian ini hanya mempertimbangkan *flare* kelas C, M, dan X untuk menyesuaikan dengan pembagian kondisi Matahari pada layanan evaluasi dan prediksi SWIFtS (Tabel 2-1). *Flare* kelas B dianggap sebagai kondisi tanpa *flare*.

Tabel 2-1: PEMBAGIAN KONDISI MATAHARI PADA LAYANAN SWIFtS.

No.	Kondisi	Penjelasan
1.	Tenang	Tidak ada <i>flare</i> kelas $\geq C$
2.	Eruptif	<i>Flare</i> kelas C
3.	Aktif	<i>Flare</i> kelas M
4.	<i>Flare</i> kuat	<i>Flare</i> kelas X

Data daerah aktif merupakan hasil analisis dan kompilasi harian dari laporan enam observatorium yang tergabung dalam jaringan pengamatan optik Matahari (SOON/*Solar Optical Observing Network*) USAF (*United States Air Force*). Data ini berisi informasi harian tiap daerah aktif meliputi tanggal pengamatan, posisi dalam koordinat heliografis, luas grup bintik, jumlah

bintik, klasifikasi McIntosh, dan klasifikasi Hale.

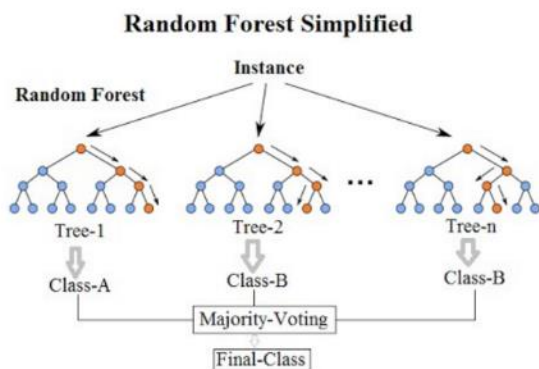
2.2 Metode Penelitian

Data *flare* sinar-X dicocokkan dengan data daerah aktif dan dipilih *flare* terkuat yang dihasilkan tiap daerah aktif tiap harinya. Rekapitulasi data ini digunakan untuk menghitung persentase kelas *flare* terkuat yang dihasilkan oleh tiap kelas Hale daerah aktif. Rekapitulasi ini juga digunakan untuk menghitung usia rata-rata daerah aktif ketika pertama kali menghasilkan *flare* sinar-X kelas $\geq C$. Usia rata-rata ini dijadikan dasar dalam penentuan interval waktu evolusi daerah aktif untuk prakiraan peristiwa *flare* sinar-X.

Data sebanyak 43.733 baris ini kemudian digunakan untuk membuat prakiraan *flare* sinar-X menggunakan salah satu metode *machine learning*, yaitu *random forest* (RF) (Breiman, 2001; Cutler *et al.*, 2012; Cutler, 2014). Pemilihan algoritma RF didasarkan pada hasil penelitian Florios *et al.* (2018) dan Liu *et al.* (2017) yang menyimpulkan bahwa RF adalah algoritma yang paling bisa diandalkan dalam melakukan prakiraan *flare* jika dibandingkan dengan metode *machine learning* lainnya. Dalam penelitiannya, Florios *et al.* (2018) menggunakan data SHARP (*Space Weather HMI Active Region Patches*) (Bobra *et al.*, 2014) dalam rentang waktu 1 Oktober 2012-13 Januari 2016. Sementara itu, Liu *et al.* (2017) menggunakan data yang sama dalam rentang waktu Mei 2010-Desember 2016 dengan sistem prediksi biner (*flare* kelas B/C dan kelas M/X).

Breiman (2001) juga telah mengungkapkan keunggulan algoritma RF dibandingkan dengan metode *machine learning* lainnya. Algoritma RF membangun sekelompok model dari pelatihan sebagian data yang ada. Sebagian data ini diambil acak dari satu set data pelatihan yang lengkap. Elemen keacakan lain yang digunakan adalah set data pelatihan untuk pohon-pohon

individu dalam sekelompok hutan acak (*random forest*) yang tidak menggabungkan semua atribut/prediktor, melainkan mengambil bagian acak juga dari atribut tersebut. Intinya, RF merupakan sekumpulan keputusan pohon biner yang dari masing-masing pohon tersebut akan dipilih dan menghasilkan prediksi akhir.



Gambar 2-1: Ilustrasi algoritma *random forest* (Koehrsen, 2017). Pohon individu dinyatakan sebagai Tree-1 hingga Tree-n dengan simpul-simpul yang disebut daun.

Tabel 2-2: TABEL KONVERSI KLASIFIKASI HALE DAERAH AKTIF

Kelas Hale	Angka konversi
α	1
β	2
γ	3
$\beta\gamma$	4
δ	5
$\beta\delta$	6
$\beta\gamma\delta$	7
$\gamma\delta$	8

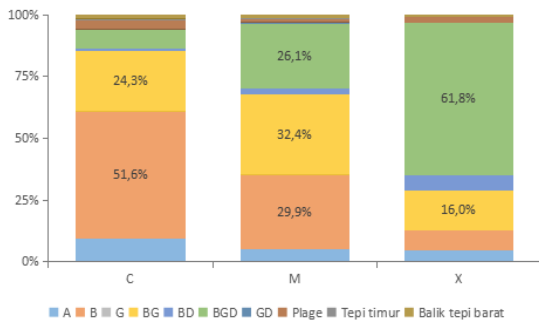
Koehrsen (2017) mengilustrasikan algoritma RF seperti pada Gambar 2-1. Pohon individu ditunjukkan sebagai *Tree-1* hingga *Tree-n* dengan simpul-simpul yang disebut daun pada tiap pohon. Pohon di sini adalah pohon keputusan yang dipilih secara acak, sedangkan daun adalah kriteria yang harus dipenuhi dalam menghasilkan

sebuah prediksi. Hasil akhir dari prediksi adalah keputusan kolektif (*wisdom of the crowd*) dari daun-daun terakhir di tiap pohon.

Data daerah aktif yang digunakan sebagai masukan adalah posisi lintang (NS) dan bujur (EW) heliografis, luas grup bintik Matahari, jumlah bintik (f) dalam grup yang bersangkutan, dan klasifikasi McIntosh (McIn) dan Hale daerah aktif dalam beberapa hari menjelang peristiwa *flare* sinar-X kelas $\geq C$. Klasifikasi McIntosh dikonversikan menjadi angka 1-60 berdasarkan nilai kelas yang dapat diakses melalui http://www.cv-helios.net/zmci_tab.html. Klasifikasi Hale dikonversikan menjadi angka 1-8 seperti yang ditunjukkan pada Tabel 2.2. Makin besar angkanya, makin kompleks pula konfigurasi medan magnetnya. Data yang mencakup siklus Matahari ke-23 dan 24 ini dibagi menjadi data latih sebanyak 70% dan data uji sebanyak 30%.

3 HASIL PEMBAHASAN

Daerah aktif yang tercatat selama Januari 1998–Juni 2018 hanya terbagi menjadi tujuh kelas Hale, yaitu α , β , γ , $\beta\gamma$, $\beta\delta$, $\beta\gamma\delta$, dan $\gamma\delta$. Beberapa peristiwa *flare* juga terjadi di daerah aktif tanpa bintik (*plage*), ketika daerah aktif masih berada di tepi timur, dan ketika daerah aktif telah berada di balik tepi barat piringan Matahari (Gambar 3-1). Dari Gambar 3-1 dapat dilihat bahwa *flare* kelas C (kondisi eruptif) paling berpeluang (51,6%) muncul di daerah aktif kelas β , *flare* kelas M (kondisi aktif) paling berpeluang (32,4%) muncul di daerah aktif kelas $\beta\gamma$, sedangkan *flare* kelas X (kondisi *flare* kuat) paling berpeluang (61,8%) muncul di daerah aktif kelas $\beta\gamma\delta$. Sementara itu, dari penelitian sebelumnya, Dani *et al.* (2007) menyimpulkan bahwa lima kelas McIntosh daerah aktif dengan produktif tertinggi dalam menghasilkan *flare* kelas M dan X adalah kelas Fkc, Dac, Dkc, Cki, dan Fko.

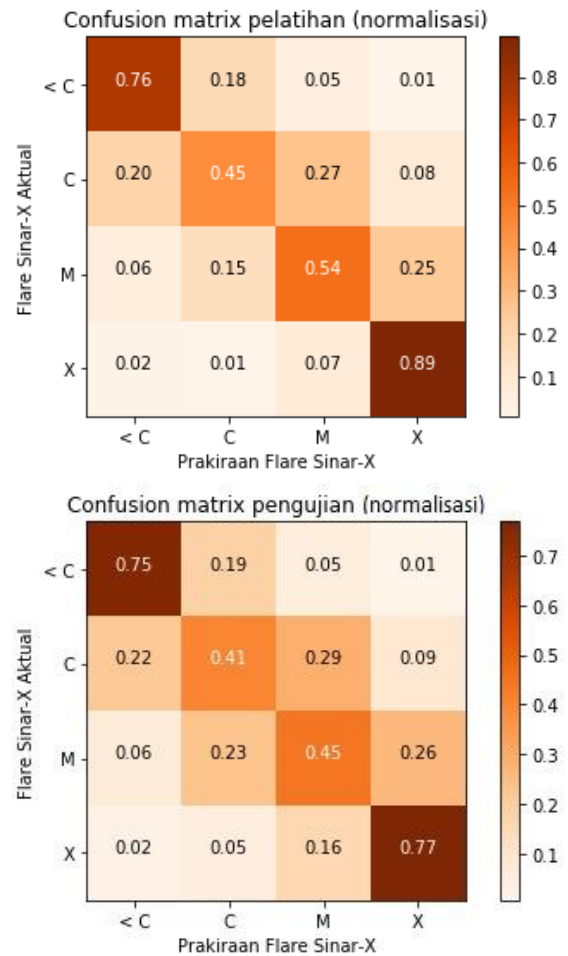


Gambar 3-1: Persentase kejadian flare sinar-X kelas C, M, dan X sebagai flare terkuat di tiap kelas Hale daerah aktif, di daerah aktif tanpa bintik (*plage*), di tepi timur, dan di balik tepi barat piringan Matahari. Persentase di bawah 10% tidak dicantumkan.

Berdasarkan data yang sama, diperoleh bahwa daerah aktif pertama kali menghasilkan flare kelas $\geq C$ rata-rata pada hari ke-3 atau ke-4 kemunculannya di piringan Matahari. Dengan demikian, prakiraan flare dilakukan berdasarkan evolusi daerah aktif dalam tiga hari karena data yang digunakan adalah data harian. Penggunaan data evolusi daerah aktif selama tiga hari ini juga telah dilakukan oleh Li dan Zhu (2013) yang membuat prakiraan flare menggunakan dua metode jaringan saraf, yaitu *multilayer perceptron* (MLP) dan *learning vector quantization* (LVQ). Li dan Zhu (2013) menggunakan data selama rentang waktu Januari 1996-Desember 2008 yang meliputi luas, klasifikasi Mt. Wilson, dan klasifikasi McIntosh bintang Matahari yang dilengkapi dengan fluks $f_{10,7}$.

Untuk mendapatkan model prakiraan flare yang optimal, telah dicoba berbagai konfigurasi pohon dan daun dalam RF. Konfigurasi yang diambil adalah dua konfigurasi terbaik dengan akurasi $\geq 70\%$. Konfigurasi pertama adalah 50 pohon dengan 90 daun di masing-masing pohon. Konfigurasi ini memberikan akurasi data latih sebesar 71,9% dan F-score data uji sebesar 70,0% dengan *confusion matrix*

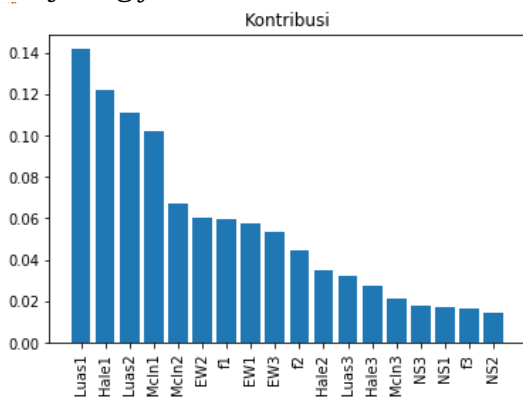
ditunjukkan pada Gambar 3-2. Pada Gambar 3-2 dapat dilihat bahwa data latih memiliki akurasi 76% untuk prediksi tanpa flare, 45% untuk prediksi flare kelas C, 54% untuk flare kelas M, dan 89% untuk flare kelas X. Sedangkan untuk data uji diperoleh akurasi 75% untuk prediksi tanpa flare, 41% untuk prediksi flare kelas C, 45% untuk flare kelas M, dan 77% untuk flare kelas X.



Gambar 3-2: *Confusion matrix* untuk data latih (atas) dan data uji (bawah) selama Januari 1998-Juni 2018 dengan konfigurasi 50 pohon dan 90 daun di masing-masing pohon.

Dengan konfigurasi ini juga diperoleh kontribusi dari tiap parameter daerah aktif yang digunakan untuk prediksi, seperti yang ditunjukkan oleh Gambar 3-3. Indeks 1, 2, dan 3 masing-masing mengindikasikan nilai parameter dalam 24, 48, dan 72 jam menjelang flare sinar-X kelas $\geq C$. Dari Gambar 3-3 dapat

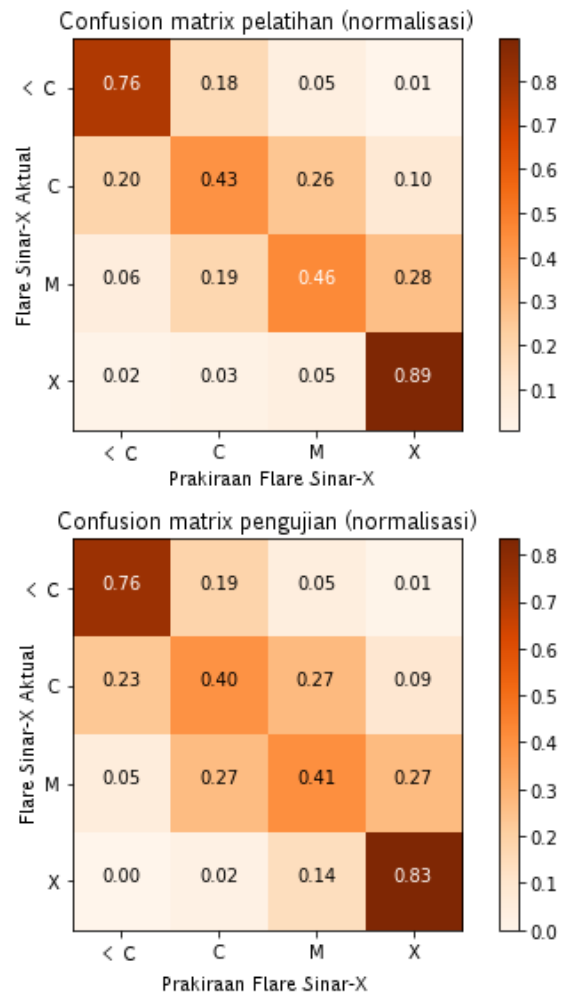
dilihat bahwa luas daerah aktif dalam 24 jam menjelang flare memberikan kontribusi tertinggi pada prakiraan flare, diikuti oleh kelas Hale dalam 24 jam menjelang flare, luas dalam 48 jam menjelang flare, kelas McIntosh dalam 24 jam menjelang flare, dan kelas McIntosh dalam 48 jam menjelang flare. Kontribusi terkecil diberikan oleh posisi lintang dalam 48 jam menjelang flare, jumlah bintang dalam 72 jam menjelang flare, posisi lintang dalam 24 dan 72 jam menjelang flare.



Gambar 3-3: Kontribusi tiap parameter daerah aktif pada prakiraan flare menggunakan algoritma RF dengan konfigurasi 50 pohon dan 90 daun di masing-masing pohon. EW, NS, f, dan McIn masing-masing adalah posisi bujur, posisi lintang, jumlah bintang, dan kelas McIntosh. Indeks 1, 2, dan 3 masing-masing mengindikasikan nilai parameter daerah aktif dalam 24, 48, dan 72 jam menjelang flare sinar-X kelas $\geq C$.


Konfigurasi kedua adalah konfigurasi 500 pohon dan 150 daun di masing-masing pohon yang memberikan akurasi data latih sebesar 71,0% dan F-score data uji sebesar 70,4%. Confusion matrix untuk konfigurasi ini ditunjukkan pada Gambar 3-4. Data latih memiliki akurasi 76% untuk prakiraan tanpa-flare, 43% untuk prakiraan flare kelas C, 46% untuk flare M, dan 89% untuk flare X. Sementara itu, untuk data uji diperoleh akurasi 76% untuk prakiraan tanpa-flare, 40% untuk prakiraan flare

C, 41% untuk flare M, dan 83% untuk flare X.



Gambar 3-4: Confusion matrix untuk data latih (atas) dan data uji (bawah) selama Januari 1998-Juni 2018 dengan konfigurasi 500 pohon dan 150 daun di masing-masing pohon.

Kontribusi dari tiap parameter fisis daerah aktif yang digunakan untuk prakiraan flare dengan konfigurasi ini ditunjukkan pada Gambar 3-5. Luas daerah aktif dalam 24 jam menjelang flare memberikan kontribusi tertinggi pada prakiraan flare, diikuti oleh kelas Hale dalam 24 jam menjelang flare, kelas McIntosh dalam 24 jam menjelang flare, luas daerah aktif dalam 48 jam menjelang flare, dan posisi bujur dalam 48 jam menjelang flare. Kontribusi terkecil diberikan oleh posisi lintang dalam 72, 48, dan 24 jam menjelang flare.



Gambar 3-5: Kontribusi tiap parameter daerah aktif pada prakiraan *flare* menggunakan algoritma RF dengan konfigurasi 500 pohon dan 150 daun di masing-masing pohon. EW, NS, f, dan McIn masing-masing adalah posisi bujur, posisi lintang, jumlah bintik, dan kelas McIntosh. Indeks 1, 2, dan 3 masing-masing mengindikasikan nilai parameter daerah aktif dalam 24, 48, dan 72 jam menjelang *flare* sinar-X kelas $\geq C$.

Kontribusi posisi lintang daerah aktif yang sangat rendah terhadap prakiraan *flare* dapat dipahami karena posisi lintang daerah aktif tidak banyak berubah selama kemunculannya pada piringan Matahari dan daerah aktif hanya muncul di lintang $< 50^\circ$ (Uddin *et al.*, 1991). Walaupun umumnya tidak ada keterkaitan langsung secara fisis antara parameter posisi dengan peristiwa *flare*, posisi bujur daerah aktif cukup berpengaruh terhadap parameter lainnya terutama ketika daerah aktif berada di tepi piringan Matahari. Penentuan luas, jumlah bintik, kelas Hale, dan kelas McIntosh daerah aktif di sekitar tepi piringan Matahari akan menyimpang dari kondisi sebenarnya karena adanya efek proyeksi. Dari Gambar 3-3 dan 3-5 juga dapat dilihat bahwa parameter daerah aktif dalam 72 jam menjelang *flare* berkontribusi sangat sedikit terhadap prakiraan *flare*.

4 KESIMPULAN

Dengan menggunakan data Januari 1998-Juni 2018, telah diperoleh model prakiraan *flare* sinar-X yang dihasilkan suatu daerah aktif untuk 24 jam ke depan berdasarkan masukan posisi, klasifikasi Hale, klasifikasi McIntosh, jumlah bintik, dan luas grup bintik Matahari dalam rentang waktu 72 jam terakhir menggunakan algoritma RF. Konfigurasi 50 pohon dan 90 daun menghasilkan prakiraan *flare* sinar-X kelas $\geq C$ dengan akurasi data latih sebesar 71,9% dan F-score data uji sebesar 70,0%. Sementara itu, konfigurasi 500 pohon dan 150 daun menghasilkan prakiraan dengan akurasi data latih sebesar 71,0% dan F-score data uji sebesar 70,4%. RF dapat memprakirakan kondisi tenang dan *flare* kuat dengan cukup baik, dengan akurasi masing-masing sekitar 75% dan 80%. Hal ini menunjukkan adanya peningkatan akurasi jika dibandingkan dengan akurasi yang dicapai oleh SOLARe (Dani, 2010). Sementara itu, prakiraan kondisi eruptif dan aktif masih perlu ditingkatkan lagi karena akurasinya hanya sekitar 40-45%.

Prakiraan *flare* lebih banyak dipengaruhi oleh kondisi fisis daerah aktif dalam 24 jam terakhir, terutama parameter luas, kelas Hale, dan kelas McIntosh. Namun, luas daerah aktif dalam 48 jam terakhir pun cukup berkontribusi pada prakiraan *flare*.

Parameter fisis daerah aktif yang paling berkontribusi terhadap prakiraan *flare* adalah luas, kelas Hale, kelas McIntosh, jumlah bintik, dan posisi bujur dalam 24 dan 48 jam menjelang *flare*. Sedangkan parameter yang paling sedikit berkontribusi adalah posisi lintang dalam 24 hingga 72 jam menjelang peristiwa *flare* dan parameter lain, kecuali posisi bujur, dalam 72 jam menjelang peristiwa *flare*. Posisi lintang daerah aktif tidak terlalu berpengaruh terhadap prakiraan *flare* karena perubahannya sangat kecil selama kemunculan daerah aktif di piringan

Matahari. Posisi bujur cukup berpengaruh karena berkaitan dengan efek proyeksi ketika daerah aktif berada di tepi piringan Matahari.

Evolusi daerah aktif yang ditunjukkan sebagai perubahan parameter fisik harian saja belum memadai untuk digunakan sebagai masukan dalam prakiraan *flare*. Oleh karena itu, masih perlu dilakukan pengembangan lebih lanjut, misalnya dengan mempertimbangkan perubahan medan magnet daerah aktif dengan resolusi waktu yang lebih tinggi untuk menghasilkan model prakiraan *flare* yang lebih komprehensif.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Kementerian Riset, Teknologi, dan Pendidikan Tinggi atas dukungannya melalui Insentif Riset Sistem Inovasi Nasional *Flagship* LAPAN 2018 berjudul “Pengembangan Sistem Layanan Informasi dan Prediksi Cuaca Antariksa” dengan *group leader* Tiar Dani; tim SWPC atas tersedianya data yang digunakan dalam penelitian ini; Farahhati Mumtahana dan Futikhatun Rohmah atas bantuannya dalam proses kompilasi data; dan kepada Tim Redaksi Jurnal Sains Dirgantara, Mitra Bestari dan rekan-rekan peneliti Pusat Sains Antariksa atas masukan dan diskusinya yang bermanfaat.

DAFTAR RUJUKAN

- Allegrino, A., A.S. Bachmeier, A. Bailey, E. Brunning, H. Bysal, J. Cantril, L. Carey, J.M. Daniels, P. Dash, M. Grotenhuis, M.M. Gunshor, J. Hanna, A. Harris, M. P. Hiatt, J.A. Knaff, J. Li, D.T. Lindsey, E.M. Maturi, K. Micke, J. Mittaz, D. Molenar, J.P. Nelson III, W. Petersen, R. Potash, E. Prins, G. Rancic, D.G. Reinke, C.C. Schmidt, A.J. Schreiner, C. Schultz, D. Sheffler, D. Stettner, W. Straka III, C. Velden, G.S. Wade, S. Wanzong, D. Watson, X. (F.) Wu, dan F. Yu, 2011. *The GOES-15 Science Test: Imager and Sounder Radiance and Product Validations*, dalam NOAA Technical Report NESDIS 141, Washington, D.C. November 2011.
- Bornmann, P.L. dan D. Shaw, 1994. *Flare Rates and the McIntosh Active-Region Classifications*, Solar Physics, 150, 127-146.
- Breiman L., 2010. *Random Forests*, dalam R.E. Schapire (editor), Machine Learning, Kluwer Academic Publishers, 45(1), 5-32.
- Cutler, A., 2014. *Random Forests*, dalam N. Balakrishnan, T. Colton, B. Everitt *et al.* (editor), Wiley StatsRef: Statistics Reference Online, American Cancer Society.
- Cutler, A., Cutler, D.R. Cutler, dan J.R. Stevens, 2012. *Random Forests*, dalam C. Zhang dan Y. Ma (editor), Ensemble Machine Learning: Methods and Applications, Springer US, Boston, MA, 157-175.
- Dani, T., 2016. *SWIFtS*, dalam R. Priyatikanto (editor), SWIFtS Space Weather Information and Forecast Services, Pusat Sains Antariksa, Bandung, 15-23.
- Dani, T., J.T. Nugroho, E.S. Mumpuni, dan N. Suryana, 2010. *Design of X-ray Solar Flare Prediction Based on Sunspot Physical Parameters Using Neural Network*, Proceeding of Earth and Space Sciences Conference. July 2010.
- Dani, T., S. Jasman, dan A.G. Admiranto, 2007. *Analisis Empirik Kejadian Flare Terkait dengan Perubahan Fisik Sunspot*, Majalah Sains dan Teknologi Dirgantara, 2(3), 122-131.
- Emslie, A.G., B.R. Dennis, A.Y. Shih, P.C. Chamberlin, R.A. Mewaldt, C.S. Moore, G.H. Share, A. Vourlidas, dan B.T. Welsch, 2012. *Global Energetics of Thirty-Eight Large Solar Eruptive Events*, The Astrophysical Journal, 759(1), 71.
- Florios, K., I. Kontogiannis, S. -h. Park, J.A. Guerra, F. Benvenuto, D.S. Bloomfield, dan M.K. Georgoulis, 2018. *Forecasting Solar Flares Using Magnetogram-based Predictors and Machine Learning*, Solar Physics, 293(2), 28.
- Gold, T. dan F. Hoyle, 1960. *On the Origin of Solar Flares*, Monthly Notices of the

- Royal Astronomical Society, 120(2), 89-105.
- Hale, G.E., F. Ellerman, S.B. Nicholson, dan A. H. Joy, 1919. *The Magnetic Polarity of Sun-Spots*, The Astrophysical Journal, 49(26), 153.
- Hudson, H. S., 2011. *Global Properties of Solar Flares*, Space Science Reviews, 158(1), 5-41.
- Koehrsen, W., 2017. *Random Forest Simple Explanation*, <https://medium.com/@williamkoehrsen/random-forest-simple-explanation-377895a60d2d>, diakses 4 Juni 2018.
- Künzel, H., 1960. *Die Flare-Häufigkeit in Fleckengruppen Unterschiedlicher Klasse und Magnetischer Struktur*, Astronomische Nachrichten, 285(5), 271.
- Li, R. dan J. Zhu, 2013. *Solar Flare Forecasting Based on Sequential Sunspot Data*, Research in Astronomy and Astrophysics, 13(9), 1118-1126.
- Liu, C., N. Deng, J.T.L. Wang, dan H. Wang, 2017. *Predicting Solar Flares Using SDO/HMI Vector Magnetic Data Products and the Random Forest Algorithm*, The Astrophysical Journal, 856(1), 7.
- McIntosh, P.S., 1990. *The Classification of Sunspot Groups*, Solar Physics, 125(2), 251-267.
- Norquist, D.C., 2011. *An Analysis of the Sunspot Groups and Flares of Solar Cycle 23*, Solar Physics, 269(1), 111-127.
- Parker, E.N., 1963. *The Solar-Flare Phenomenon and the Theory of Reconnection and Annihilation of Magnetic Fields*, Astrophysical Journal Supplement, 8, 177.
- Sammis, I., F. Tang, dan H. Zirin, 2000. *The Dependence of Large Flare Occurrence on the Magnetic Structure of Sunspots*, The Astrophysical Journal, 540(1), 583-587.
- Sulistiani, S., T. Dani, F. Mumtahana, A.G. Admiranto, 2018. *Laporan Evaluasi Penelitian Prakiraan Flare Berdasarkan Klasifikasi McIntosh dan Hale Daerah Aktif*, Pusat Sains Antariksa, Juli 2018.
- Uddin, W., M.C. Pande, dan V.K. Verma, 1991. *The distribution of Sunspots Over the Sun*, Astrophysical and Space Science, 181(1), 111, 115.
- Yu, D., X. Huang, H. Wang, dan Y. Cui, 2009. *Short-Term Solar Flare Prediction Using Sequential Supervised Learning Method*, Solar Physics, 255(1), 91-105.

