

4-3 太陽フレア発生予測

4-3 *Solar Flare Prediction*

西塚直人 久保勇樹 杉浦孔明 田 光江 石井 守

NISHIZUKA Naoto, KUBO Yûki, SUGIURA Komei, DEN Mitsue, and ISHII Mamoru

太陽フレアは、主に黒点群周辺に蓄積された磁気エネルギーの解放により発生する。太陽フレアに伴う X 線放射や高エネルギー粒子放出、地磁気擾乱は我々社会にも影響し、その発生機構の理解と予測精度の向上は重要な課題となっている。しかしながら、いまだフレア発生機構は長年の謎であり、精度よく予測するには至っていない。そこで筆者らは膨大に蓄積された太陽磁場観測画像等に深層学習手法を適用することで、予測精度の向上を図った。その結果、黒点群ごとにおける太陽フレアの決定論的予報を可能にし、従来の人手による約 5 割の予測精度を 8 割まで向上することに成功した。さらに本予測モデルを、深層学習を用いた世界初の太陽フレア予報運用モデルとして世界で初めて活用し、予報結果を公開している。本稿では我々の太陽フレア深層学習予報システム「Deep Flare Net」を紹介し、フレア発生機構を探る新たなアプローチ等についても解説する。

Solar flares take place by the energy release of magnetic field stored around sunspots. X-ray emissions, high energy particles and geomagnetic disturbances originating from solar flares sometimes affect our society. Thus, it is an important task to understand the solar flare mechanism and improve prediction accuracy. Here, we applied deep neural networks to large amount of solar observation images such as magnetograms. As a result, the method enabled deterministic forecasts of flares, and we succeeded in improving accuracy up to 80%, which is better than human hand forecasts of 50%. Furthermore, we started the daily operations of the model, which is the first operational forecasting model using deep neural networks, and released the forecasted results. In this paper, we introduce our solar flare prediction model using deep neural networks, named Deep Flare Net, and a new approach to study the solar flare mechanism using importance ranking analysis of solar features.

1 まえがき

太陽活動は宇宙天気現象の源である。前章(4-1, 4-2)で解説されたコロナ質量放出(CME: Coronal Mass Ejection)や高速太陽風は、いずれも太陽表面での活動が原因となって発生している(図1)。近年、「ひので」衛星などの太陽衛星観測や地上観測によって、太陽表面で起こる詳細な磁気プラズマ活動現象の描像が明らかになってきた。太陽活動は太陽内部で起こるダイナモによって駆動され、表面に浮上してきた磁場が黒点群を形成し、太陽フレアやコロナ質量放出を引き起こす。2017年9月には11年ぶりに、通常の1,000倍の X 線を放出する巨大フレアが発生してニュースにもなった。

太陽フレアは黒点周辺に蓄積された磁気エネルギー

を解放することで発生する太陽系最大の太陽面爆発現象である。黒点の集まりである黒点群は、磁場の浮上とともに数日間で形状は大きく複雑に成長し、歪みのような余剰エネルギーも蓄積する。地震と同様、こうした歪みはある限界値を超えると安定性を失い、大爆

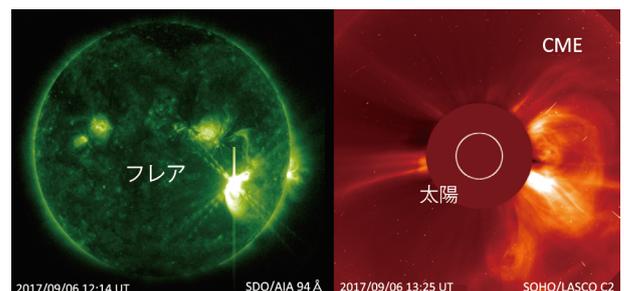


図1 太陽フレアとコロナ質量放出(CME)
(SDO 衛星、SOHO 探査機)

発・大噴出現象へと遷移する。太陽フレアが発生すると、黒点群上空のコロナは数千万度に加熱され、通常の数千～数万倍の X 線や紫外線・電波といった広範な波長域の電磁波、高エネルギーの荷電粒子、磁場を伴った太陽コロナ大気が惑星間空間に放出される。

太陽フレアから放出された電磁波は光速で約 8 分後、高エネルギー荷電粒子は 20 分～2 日後に、コロナ質量放出や高速太陽風による太陽風じょう乱は 2～3 日後に地球に到達する。これらは地球周辺の宇宙環境にも影響を及ぼすことがあり、地磁気や電離圏での嵐を引き起こす原因ともなり得る。過去には、強力な X 線による短波通信障害(デリンジャー現象)や高エネルギー荷電粒子による人体被ばく・電子機器故障、大気変動や電子密度変化に伴う衛星・航空運用や衛星測位誤差への影響、地磁気誘導電流による大規模停電の発生等の事例が報告されている。

宇宙天気の変動は、宇宙利用の進む現代社会において重大な影響を及ぼす可能性があり、宇宙空間の安全利用と宇宙天気変動が引き起こす被害に対するリスク管理のためにも予報による早期対策が必要不可欠である。近い将来、数千機の通信衛星や衛星測位によるサービス利用が見込まれ、地球低軌道や月面での宇宙ビジネスも注目を集める中、有人宇宙活動や航空運用における被ばくの影響も見逃せない。国際民間航空機関(ICAO)では宇宙天気情報利用が既に始まっている。一方で、太陽フレア発生から巨大な磁気嵐・電離圏嵐の発生まで 2,3 日の猶予しかなく、被ばくや通信障害は太陽フレア発生とほぼ同時に被害が発生する。したがって太陽フレアの予測精度向上と予測リード時間の伸長が喫緊の課題である。

2 太陽フレアの発生機構と予測

2.1 太陽フレアの予報と観測データ

近年の「ひので」や SDO (Solar Dynamics Observatory) 衛星といった太陽衛星観測によって、太陽の光球磁場やコロナの高空間時間分解能観測データが誰でも見られるようになった[1][2]。また天候や昼夜に影響されず、高品質で 24 時間定常的に太陽活動の観測と追跡が可能になり、太陽物理や太陽フレア発生機構の理解が飛躍的に進んできた。太陽は約 27 日の自転周期を持ち、太陽黒点は東端リム(太陽画像で向かって左端)から西端リム(右端)へと、約 15 日かけて赤道付近を移動する。その間に黒点群は成長や減衰を繰り返し、時に太陽フレアが発生する。

フレアの規模は、X 線放射強度によって分類される。米国気象観測衛星 GOES 搭載の X 線観測装置によって、1-8Å の X 線強度が 1 桁変わるとに分類され、最

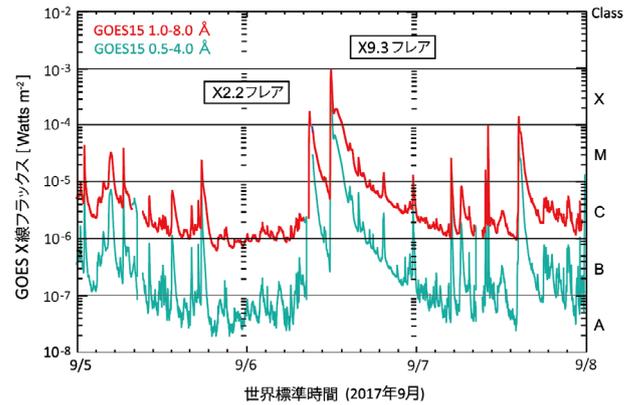


図2 太陽 X 線光度曲線 (GOES 衛星)

大規模を X クラス、中規模を M クラス、小規模を C クラスフレアと呼んでいる。特に X クラスのフレアが発生すると、静穏時の 100～1,000 倍の X 線放射によって短波通信障害が数分～数十分発生する [3]-[5] (図 2)。太陽フレアの発生頻度は 11 年周期とともに変化し、平均的には X クラスで年 2-3 回、M クラスで 20-30 回、C クラスは 300 回発生する。大規模なフレアほど発生数が少ないため、経験則に基づく予測も難しい。

フレアの予測には、黒点周辺に蓄積された余剰エネルギーや、浮上磁場に伴う微小な前兆現象を監視することが重要である。白色光地上観測スケッチをもとに、昔から太陽黒点群は分類されてきた。黒点群は正負の磁気極性が対となることが多く、形状は α 型(単極磁場)、 β 型(双極磁場)、 γ 型(やや複雑な混合極性磁場)、 δ 型(非常に複雑)と分類される [6]。 δ 型黒点では X クラスフレアが発生することが多く、大きな黒点ほど大規模なフレアを発生する傾向にある [7]-[9]。また同じ黒点領域から同規模のフレアが繰り返し発生する傾向があり、長い間経験則に基づいたフレアの予測が行われている。

2.2 太陽フレアの予測の課題と問題点

さらに近年は、太陽観測衛星による多波長高分解能データによって、黒点群付近の光球磁場やコロナの詳細な情報が得られるようになってきた。これらによって、黒点の大きさや形状分類だけでなく、黒点群領域内の正負磁気領域の境界線である磁気中性線の時間発達の様子、その周辺のベクトル磁場解析による磁気的歪み具合の様子、浮上磁場に伴う新しい磁場構造の出現、彩層底部での発光現象などを捉えることができるようになった [10]。それと同時に、コロナ中の高温プラズマの加熱など、新たなフレアの前兆現象と思しき現象が新たに多数発見されている (図 3)。

こうした観測データのビッグデータ化が進む一方で、膨大な量のデータ解析はなかなか進まず、人手による

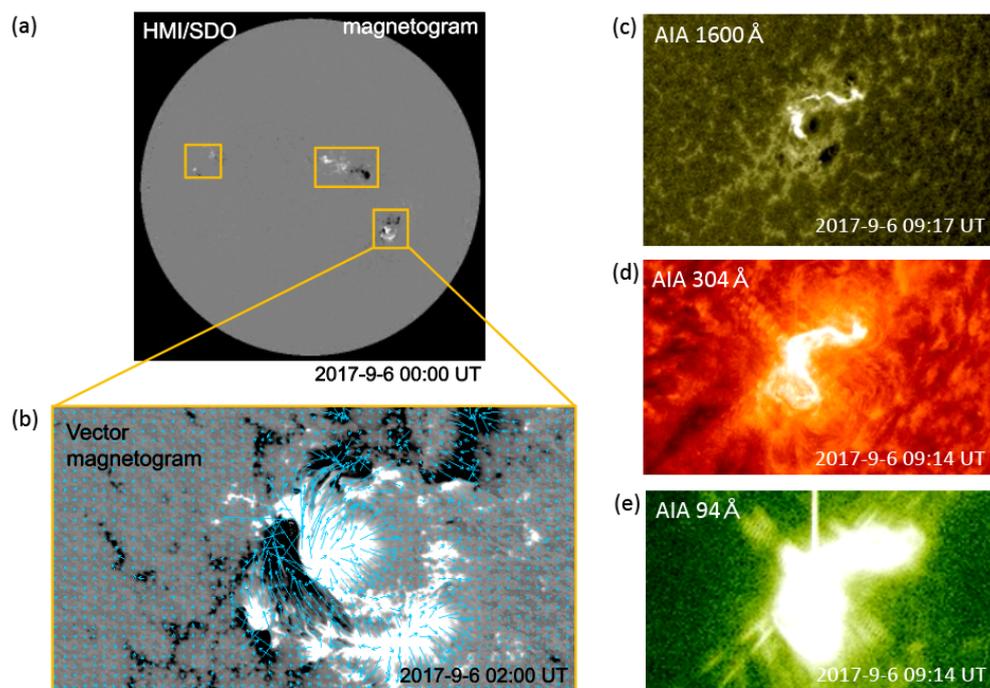


図3 (a) (b) 2017年9月6日に発生したXクラスフレア領域の光球磁場観測データと、(c) - (e) その上空の光球上部～彩層底部、遷移層、コロナの観測データ (SDO 衛星 HMI, AIA 望遠鏡)

予報への活用も不十分だった。定量的な情報処理は人力では難しく、また経験則に基づいた予測は予報を行う専門家個人によっても判断基準に差があり、予報評価と改善にも時間を要するという課題もある。実際、人手を介した太陽フレアの24時間以内の発生予測の場合、3-5割の予測精度であり[11]-[13]、まだ改善の余地がある。また理論数値シミュレーションによる研究も行われているが[14]-[16]、フレア発生機構の解明には至っていない。

これらの課題を解決する方法として、我々は機械学習手法の応用に着目した。機械学習は、人手では扱えない大量データを分析できる特長があり、既知の学習データをもとに傾向を分析して未知のデータの予測や分類をすることができる[17]。深層学習は機械学習の一種で、多層のニューラルネットワーク構造をもとにデータの特徴を学習し、精度良い予測結果を導き出すことができる[18][19]。これらを大量の太陽衛星観測データに適用することで、我々は太陽フレア予測の高精度化とフレア発生機構の解明に迫る挑戦的課題に取り組んだ。

3 太陽フレア予測モデルの開発

3.1 深層学習を用いた太陽フレア予測モデル「Deep Flare Net」

本章では、我々の開発した深層学習技術を応用した太陽フレア予測モデル「Deep Flare Net」について解説

する。本予測モデルは、今後24時間以内に発生する太陽フレアの発生確率や最大規模を、太陽面上の黒点群ごとに求め予報することができる[20]。処理過程は4段階あり、(1) NASA 観測データアーカイブから過去データを取得、(2) 太陽磁場画像から黒点を自動検出、(3) 領域ごとに79個の特徴量を抽出、(4) 深層学習に入力して学習し、最終的に予報確率が出力される(図4)。まず過去データを用いてモデル構築した後、リアルタイム運用システムを作成した。

学習にはSDO衛星観測による視線方向磁場、ベクトル磁場、高温コロナ(131 Å)、光球上部～彩層底部(1,600 Å)の6年間分の約30万枚の画像データとGOES衛星によるX線積分データ(1~8 Å)を用いた。視線方向磁場画像からある閾値を基に黒点群を検出及び同定し、同領域における多波長観測データから計算した特徴量を抽出した。例として、黒点面積や最大磁場強度、磁気中性線の磁場勾配や長さ、ローレンツ力、磁気シア角、余剰磁気エネルギーなどを算出している。さらに彩層底部発光強度、コロナ高温輝線やX線の過去最大値やフレア履歴を用いた。これらの特徴量は日々の予報運用ノウハウ及び過去の太陽物理研究に基づいて選出した。そして抽出特徴量は標準化(規格化)し、フレア発生前データにはフレア発生ラベルを添付した。

予測アルゴリズムには複数の機械学習手法を試した後、試行錯誤の末に層学習技法を応用することで精度向上を図った[20][21]。深層学習は現状最も精度の良い

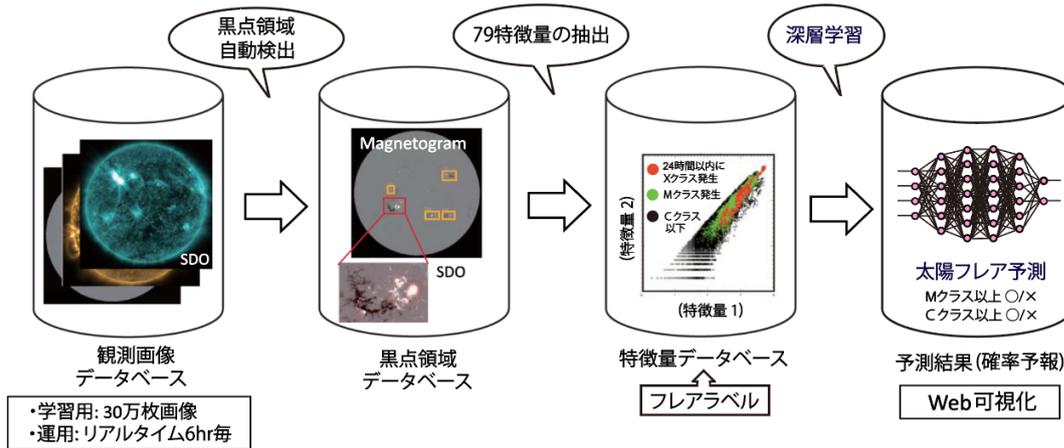


図4 Deep Flare Netの概略図 (Nishizuka et al. 2018 ApJ[20] より引用改訂)

機械学習手法である。宇宙天気予報と機械学習の専門家で連携チームを結成し、音声翻訳に用いられる技法の応用を試みた [22]。活性化関数 (ReLU) やバッチ正規化、スキップ接続といった深層学習技法を組み込み、多層化と精度向上を可能にした。またフレア予測問題は発生自身が稀でインバランス問題であり、損失関数に重みをかけることで予測漏らしを減らすなど、数多くの工夫を盛り込むことで予測精度向上に取り組んだ。

3.2 予測評価と特徴量の重要度ランキング

予測精度評価では、予報運用モデルとして適正な評価ができるよう注意した。我々は特徴量データベースを時系列で分割し、2010-2014年分を学習用、2015年分をテスト用に用いた。別の手法として、ランダムにデータ分割して学習を行う方法もある [17][23] が、時系列のフレア予測の場合、数時間だと磁場構造のような特徴量はほとんど変化しないため、学習用とテスト用の両方にはほぼ同じデータが分配されてしまうため、今回は用いなかった。また時系列分割の場合、未来のデータを使って過去イベントを予測することもない。さらに汎化性能を高めるため、我々は時系列分割したデータセットを基に、学習用データとテスト用データを変えながら精度検証を行う時系列交差検証も提案した [24]。

フレア予測の評価指標としては、スキルスコアの1つ True Skill Statistics (TSS) [25] が多く用いられている。TSSはフレア発生時の的中率からフレア非発生時の非的中率を差し引いたもので、データのイベント率に依存しないため、インバランス問題の評価に適している [26]。予測結果を表1に示す。24時間以内に発生するM(C)クラス以上フレアの予測に対し、TSS=0.80(0.63)を達成した。人手予報ではMクラス以上フレアの予測精度はTSS=0.50であり、「Deep Flare Net」を用

表1 Deep Flare NetによるMクラス以上フレア、Cクラス以上フレアの予測結果

		観測	
		フレア	なし
予測	≧Mクラス	963	4382
	なし	54	25937
		TSS=0.80	
		観測	
		フレア	なし
予測	≧Cクラス	4967	4420
	なし	1171	20778
		TSS=0.63	

いることで大きく精度向上することに成功した。

機械学習では予報に有効な特徴量の重要度ランキングの分析もできる。ここでは予測分類時のジニ不純度の減少量で評価した。ジニ不純度とはデータが一種類だと最小で、複数種が均等に混ざった状態で最大になる。したがって一種類に特定できるような特徴量の予測では、ジニ不純度の減少量は大きく重要度も大きい [27]。この手法を用いて分析した結果、フレア履歴、1日前のX線最大値、磁気中性線の長さとお数、磁束密度、彩層底部発光、平均磁場強度、ベクトル磁場特徴量という順で重要度が大きい傾向にあることが明らかになった [21]。

3.3 Deep Flare Netの予報運用

3.1で説明したDeep Flare Netモデルを基に、我々は2019年から予報運用を開始した。6時間ごとにインターネットを通じて観測データを取得するよう設定し、リアルタイムで取得した磁場画像から黒点群を検出、79個の特徴量を抽出して深層学習モデルに入力する。そして予測された24時間以内に発生する最大規模のフレアを黒点群ごとに可視化してウェブで表示公開する [24]。リアルタイム運用では、ノイズを多く含んだデータや観測データの欠損でエラーが生じることがあり、それらを回避するよう運用システムならではの改

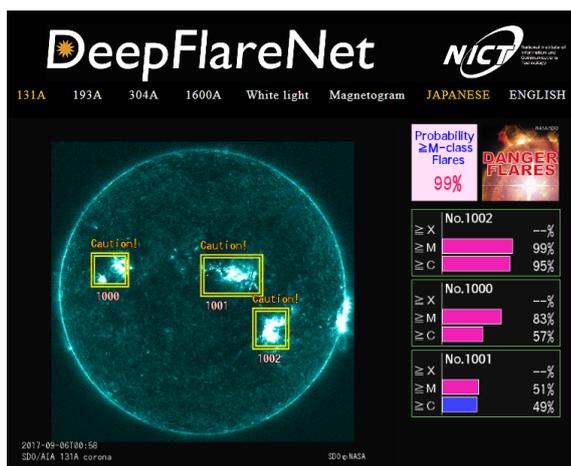


図5 太陽フレア予測運用モデル Deep Flare Net のウェブ画面 (<https://defn.nict.go.jp>; Nishizuka et al. 2021 EPS [24] より引用改訂)

良を組み込んだ。

図5に Deep Flare Net の公開サイトを示す。6時間ごとに更新されたりアルタイムの太陽画像と黒点群として検出された領域を示し、右側には黒点ごとのMクラス/Cクラス以上のフレア発生確率の棒グラフと、太陽全面での発生確率を示している。ここで示す予報確率を使って、50%を閾値としてフレア発生の有無を判別している。その一方、50%を閾値として判別できるように、フレア発生頻度に応じた重み付けをした確率であり、実際のフレア発生確率ではない点に注意頂きたい。また天気予報の晴・曇・雨マークと同様、一般ユーザーにもわかりやすいよう、「静穏・警戒・危険」といった警報マークを表示した。

本予報システムを開発した頃は太陽活動の極小期であり、ほとんどフレアの発生がなかったが、太陽サイクル25が開始してからフレア発生数は徐々に増加し、Mクラスフレアも発生するようになってきた。2019年から予報運用を開始して以降、NICTで行う宇宙天気予報会議でも Deep Flare Net の予報結果は活用している。2021年4月に発生したMクラスフレアでも24時間前に予報的中に成功し、今後活躍の機会は増えると期待される。また運用開始から2年経過し、予報精度評価を行ったところ、運用開始前と同程度の評価精度を達成していることも確認できた[24]。

4 今後の展望

我々は深層学習手法を太陽フレア予測に応用し、24時間以内に発生する太陽フレアを予測する世界初の太陽フレアAI予報運用モデル Deep Flare Net を開発公開することに成功した。同モデルは2019年から運用中であり、NICTの宇宙天気予報会議でも活用されてい

る。大量で高分解能の多波長太陽観測衛星データと最新の深層学習手法とを組み合わせることで、太陽フレア発生前の黒点群周辺の特徴を抽出し、喫緊の課題であった予報的中率の8割到達に成功した。さらに本研究成果はフレア発生機構を解明する新しいアプローチも示した。

従来の太陽研究では、詳細な観測データ解析を基に太陽フレア発生のトリガー機構の候補発見に注力してきた。しかしながらフレア前の微小現象を候補として列挙する一方、どの特徴で何割当てられるのかという検証はなされてこなかった。今回、機械学習を用いたことで初めて各特徴量の重要度が可視化され、比較が可能になった。これは理論数値シミュレーションとの比較にも有効で、予測に有効だと理論予測された特徴量の検証にも使える。一方で、逆に観測的に重要だと示された特徴を数値シミュレーションで詳細解析できる可能性も見えてきた。

太陽フレア予測にも課題は山積している。現在24時間予報を行っているが、今後2日、3日と予報期間を延ばしていく必要がある。その際には数日後の黒点形状がどう発達するか、太陽内部の浮上磁場を含めて予測することが重要になる。また黒点観測のできない太陽東端・西端のフレア発生についても予測できる手法開発が喫緊の課題である。より長期的な、数か月～数年単位の太陽活動予報もニーズがあるだろう。さらに100年に1度起こる超巨大フレアといったデータの少ない極端イベントをいかに予測するかも、今後の課題である。

また人工知能技術の進化の速さも見過ごせない。Deep Flare Net では独自の深層学習手法を用い、太陽物理で有効だと考えられてきた抽出特徴量、予報運用ノウハウを注ぎ込むことで高精度予測に成功した。いわば、太陽研究の歴史に基づいた成功だと言える。その一方で、太陽磁場画像から特徴を自動抽出する純粋AI予報モデルが海外では論文発表され[28][29]、説明可能な人工知能(Explainable AI)の応用も始まろうとしている。これによって益々AI技術と人のノウハウの差は狭まり、今までできなかったような解析も可能になるだろう。

現在、宇宙ビジネスにおいても転換点を迎えている。民間宇宙船で人を輸送し、衛星コンステレーションが打上げられるなど、地球低軌道や月面での宇宙ビジネスが注目を集めている。そうした中、宇宙天気予報の基盤技術となる太陽フレア予測の重要性は増してくる。フレア発生とほぼ同時に起こる通信障害や放射線被ばく、さらにCME到来による衛星運用や衛星測位サービスへの影響など、太陽フレア予測によって被害を防ぐ、また軽減できる余地は大きい。今後は太陽観測データに加え、様々な宇宙環境や社会インフラデータ

と組み合わせたモデル開発を行うことにより、さらに社会に役立つ技術開発を推進したい。

謝辞

本稿の内容は筆者らの査読論文に基づいている。本研究は文部科学省科学研究費補助金 (JP18 H04451) の援助を受けている。また本業務の一部は、総務省委託業務「0155-0099 電波伝搬の観測・分析等の推進」によって行われたものである。

【参考文献】

- 1 T. Kosugi, K. Matsuzaki, T. Sakao, T. Shimizu, Y. Sone, S. Yachikawa, T. Hashimoto, K. Minesugi, A. Ohnishi, T. Yamada, S. Tsuneta, H. Hara, K. Ichimoto, Y. Suematsu, M. Shimojo, T. Watanabe, S. Shimada, J.M. Davis, L.D. Hill, J.K. Owens, A.M. Title, J.L. Culhane, L.K. Harra, G.A. Doschek, and L. Golub, "The Hinode (Solar-B) mission: an overview," *Solar Physics*, vol.243, pp.3-17, June 2007.
- 2 W. Pesnell, B.J. Thompson, and P.C. Chamberlin, "The Solar Dynamics Observatory (SDO)," *Solar Physics*, vol.275, pp.3-15, Jan. 2012.
- 3 R. Maeda and H. Inuki, "Magnitude of short-wave fade-out," *J. Radio Res. Lab.*, vol.18, no.99, pp.467-476, Nov. 1972.
- 4 T. Sato, "Sudden fmin enhancements and sudden cosmic noise absorptions associated with solar X-ray flares," *J. Geomagnetism and Geoelectricity*, vol.27, pp.95-112, 1975.
- 5 C. Tao, M. Nishioka, S. Saito, D. Shiota, K. Watanabe, N. Nishizuka, T. Tsugawa, and M. Ishii, "Statistical analysis of short-wave fadeout for extreme space weather event estimation," *Earth, Planets and Space*, vol.72, article id.173, pp.1-16, Dec. 2020.
- 6 P.S. McIntosh, "The classification of sunspot groups," *Solar Physics*, vol.125, pp.251-267, Sept. 1990.
- 7 I. Sammis, F. Tang, and H. Zirin, "The dependences of large flare occurrence on the magnetic structure of sunspots," *The Astrophysical Journal*, vol.540, pp.583-587, Sept. 2000.
- 8 P.T. Gallagher, Y.-J. Moon, H. Wang, "Active region monitoring and flare forecasting - I. Data processing and first results," *Solar Physics*, vol.209, pp.171-183, Sept. 2002.
- 9 K.D. Leka and G. Barnes, "Photospheric Magnetic Field Properties of Flaring versus flare-quiet active regions. II. Discriminant Analysis," *The Astrophysical Journal*, vol.595, pp.1296-1306, Oct. 2003.
- 10 Y. Bamba, K. Kusano, T.T. Yamamoto, and T.J. Okamoto, "Study on the triggering process of solar flares based on Hinode/SOT observations," *The Astrophysical Journal*, vol.778, article id.48, pp.1-13, Nov. 2013.
- 11 M.D. Crown, "Validation of the NOAA space weather prediction center's solar flare forecasting look-up table and forecaster-issued probabilities," *Space Weather*, vol.10, CiteID S06006, June 2012.
- 12 A. Devos, C. Verbeeck, and E. Robbrecht, "Verification of space weather forecasting at the regional warning center in Belgium," *J. Space Weather and Space Climate*, vol.4, id.A29, pp.1-15, October 2014.
- 13 Y. Kubo, M. Den, and M. Ishii, "Verification of operational solar flare forecast: case of regional warning center Japan," *J. Space Weather and Space Climate*, vol.7, id.A20, pp.1-16, Aug. 2017.
- 14 K. Shibata and T. Magara, "Solar flares: magnetohydrodynamic processes," *Living Rev. Solar Physics*, vol.8, article id.6, pp.1-99, Dec. 2011.
- 15 K. Kusano, Y. Bamba, T.T. Yamamoto, Y. Iida, S. Toriumi, and A. Asai, "Magnetic field structures triggering solar flares and coronal mass ejections," *The Astrophysical Journal*, vol.760, article id.31, pp.1-9, November 2012.
- 16 K. Kusano, T. Iju, Y. Bamba, and S. Inoue, "A Physics-based method that can predict imminent large solar flares," *Science*, vol.369, pp.587-591, July 2020.
- 17 C.M. Bishop, *Pattern Recognition and Machine Learning: Information Science and Statistics*, M. Jordan, J. Kleinberg, and M. Schölkopf, ed., New York: Springer, 1992.
- 18 G.E. Hinton and R.R. Salakhutdinov, "Reducing the dimensionality of data with neural networks," *Science*, vol.313, pp.504-507, July 2006.
- 19 Y. LeCun, Y. Bengio, and G. E. Hinton, "Deep learning," *Nature*, vol.521, pp.436-444, May 2015.
- 20 N. Nishizuka, K. Sugiura, Y. Kubo, M. Den, and M. Ishii, "Deep Flare Net (DeFN) model for solar flare prediction," *The Astrophysical Journal*, vol.858, article id.113, pp.1-8, May 2018.
- 21 N. Nishizuka, K. Sugiura, Y. Kubo, M. Den, S. Watari, and M. Ishii, "Solar flare prediction model with three machine-learning algorithms using ultraviolet brightening and vector magnetograms," *The Astrophysical Journal*, vol.835, article id.156, pp.1-10, Jan. 2017.
- 22 K. Sugiura and H. Kawai, "Grounded language understanding for manipulation instructions using GAN-based classifications," *Proc. IEEE Automatic Speech Recognition and Understanding Workshop (ASRU)*, pp.519-524, Dec. 2017.
- 23 M.G. Bobra and S. Couvidat, "Solar flare prediction using SDO/HMI vector magnetic field data with a machine-learning algorithm," *The Astrophysical Journal*, vol.798, article id.135, pp.1-11, Jan. 2015.
- 24 N. Nishizuka, Y. Kubo, K. Sugiura, M. Den, and M. Ishii, "Operational solar flare prediction model using Deep Flare Net," *Earth, Planets and Space*, vol.73, article id.64, pp.1-12, March 2021.
- 25 A.W. Hansen and W.J.A. Kuipers, "On the relationship between the frequency of rain and various meteorological parameters," *Mededelingen en verhandelingen*, no.81, 's-Gravenhage : Staatsdrukkerij- en Uitgeverijbedrijf, 1965.
- 26 D.S. Bloomfield, P.A. Higgins, R.T.J. McAteer, and P.T. Gallagher, "Toward reliable benchmarking of solar flare forecasting methods," *The Astrophysical Journal Letters*, vol.747, article id.L41 (7pp), March 2012.
- 27 L. Breiman, "Random forests," *Machine Learning*, vol.45, pp.5-32, Jan. 2001.
- 28 X. Huang, H. Wang, L. Xu, J. Liu, R. Li, and X. Dai, "Deep learning based solar flare forecasting model. I. Results for line-of-sight magnetograms," *The Astrophysical Journal*, vol.856, article id.7, (pp.1-11), March 2018.
- 29 E. Park, Y.-J. Moon, S. Shin, K. Yi, D. Lim, H. Lee, and G. Shin, "Application of the deep convolutional neural network to the forecast of solar flare occurrence using full-disk solar magnetograms," *The Astrophysical Journal*, vol.869, article id.91, pp.1-6, Dec. 2018.



西塚直人 (にしづか なおと)

電磁波研究所
電磁波伝搬研究センター
宇宙環境研究室
テニューアトラック研究員
博士(理学)
太陽プラズマ物理、機械学習を用いた太陽フレア予測



久保勇樹 (くぼ ゆうき)

電磁波研究所
電磁波伝搬研究センター
宇宙環境研究室
研究マネージャー/
宇宙天気予報グループ
グループリーダー
博士(学術)
太陽物理学、予報評価技術



杉浦孔明 (すぎうら こうめい)
慶應義塾大学准教授
博士(情報学)
機械知能、マルチモーダル言語処理、知能口
ポティクス



田 光江 (でん みつえ)
電磁波研究所
電磁波伝搬研究センター
宇宙環境研究室
研究員
博士(理学)
宇宙物理学



石井 守 (いしい まもる)
電磁波研究所
電磁波伝搬研究センター
研究センター長
博士(理学)
超高層物理学、大気光学・電波観測