

太陽フレア AI 予報 Deep Flare Net の運用化

○西塚 直人, 久保 勇樹, 杉浦 孔明, 田 光江, 石井 守
 情報通信研究機構 (NICT)

我々は、深層学習を用いた太陽フレアの予測モデル (Deep Flare Net) を開発し、ウェブサイトでの予報配信の運用を開始した。本モデルでは、太陽衛星観測データをもとに黒点磁場の複雑性や彩層発光現象を判別し、今後24時間以内に発生する最大規模のフレアを予測できる。太陽活動は宇宙天気現象の源であり、太陽フレアのより早く正確な予報は、宇宙天気予報にとって重要な課題である。本論文では、我々のAI予報システムの紹介と運用モデル開発の留意点、将来展望について議論する。

1. 背景

太陽フレアが発生すると、強い X 線や紫外線(図 1, 2)、高エネルギー粒子 (陽子・電子)、コロナ質量放出に伴う太陽風擾乱が宇宙空間に放出される。時にそれらは社会にも影響を及ぼし、衛星故障や被ばく、衛星測位誤差の増大や通信異常の原因にもなる。太陽フレアや宇宙天気の予報は、宇宙利用が増大する現代社会において、リスク管理という観点で今後ますます重要になると考えられる。

太陽フレアの発見は 100 年以上も前のことだが、未だにその発生機構は解明されていない。近年、太陽観測衛星「ひので」や SDO 衛星の活躍により、定常的にコロナや磁場の観測ができることで、その発生機構が少しずつ解明されてきた。しかしながら、観測データが増大する一方で、人手による十分な予報精度の向上にはつなげていない。

宇宙天気予報や太陽フレアの予報は、国内で




図 1: 2017 年 9 月の太陽フレア (右図) と発生黒点 (左図) (SDO 衛星 HMI 望遠鏡、AIA 望遠鏡)

は NICT で、また世界では国際宇宙環境サービス (ISES) に加盟する 18 か国で行われている。どの国も人手による予報が行われ、的中率は 3~5 割程度 (スキルスコアで TSS~0.5) ^{1), 2)} である。精度向上のため、近年、統計的手法、機械学習を用いた手法、数値シミュレーションによる物理的予測手法などが開発検討されている。

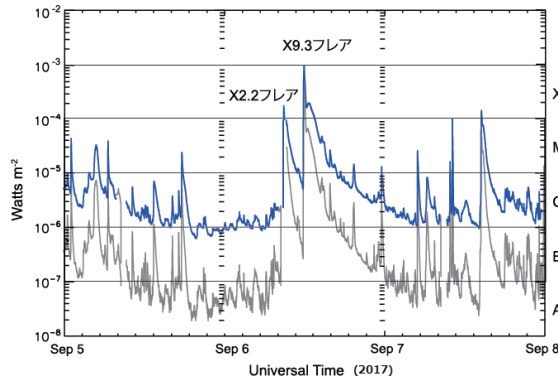


図 2: 2017 年 9 月の太陽活動度、軟 X 線光度曲線 (GOES 衛星)

機械学習を用いると、コンピュータに学習データを読み込ませて、自動的に未知のデータを予測することができる。また、人の情報処理能力を超えて複雑なデータをもとに予測できる点が特長だ。これによって、現在、定量的に解析できていないデータを有効に予報に活用したり、予報結果を次の予報にフィードバックしたり、自動化や予報の高頻度化などができるようになる。さらに、この新しいアプローチによって、太陽フレアの発生機構のさらなる解明が進むと期待される。

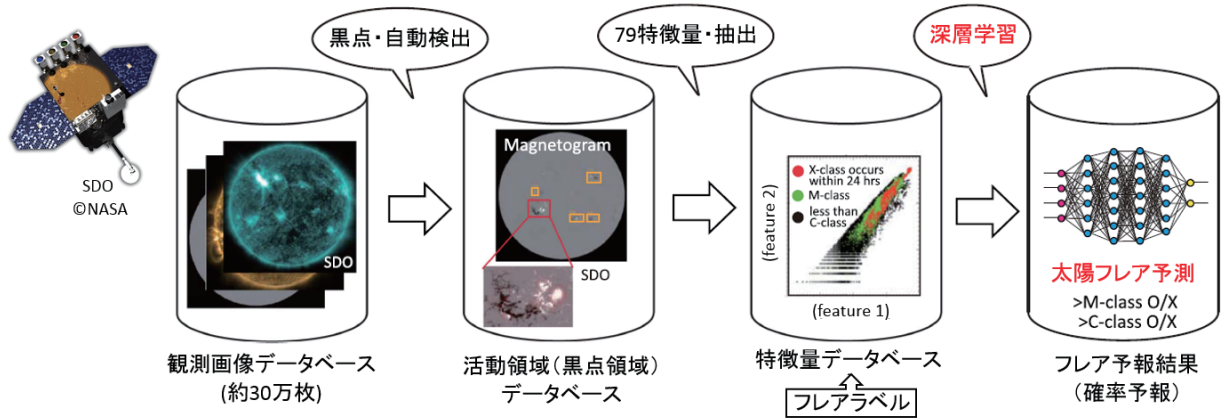


図 3: 太陽フレア予測モデル Deep Flare Net の流れ図³⁾ (Nishizuka et al. 2018 ApJ から引用)

2. 予報モデル Deep Flare Net の開発

そこで我々は、深層学習を用いた太陽フレアモデル Deep Flare Net の開発を行った^{3), 4)}。本モデルにより、24 時間以内に発生する最大規模の太陽フレアを黒点ごとに確率予報することができる。主な流れとして、まず(1) SDO 衛星観測データサーバから 6 年分の太陽画像約 30 万枚を取得し、(2) 磁場画像をもとに黒点領域を自動検出した。(3) さらに各領域から 79 個の特徴量を抽出し、(4) 深層学習モデルに入力することでフレアの発生確率の予報を可能にした。

予報運用モデルの開発にあたっては、評価手法に特に留意した。まず予測精度評価の指標として、太陽フレアの予測モデル開発にて広く用いられているスキルスコア、True Skill Score (TSS)を採用した。さらに予報運用と近い条件で予測評価を行うために、特徴量データベースを時系列に分割し、2010-2014 年データを学習用に、2015 年をテスト用に用いた。

運用形式の評価手法でも人手を上回る精度を達成するため、我々は3つの工夫を行った。1つ目は、磁場画像に加えて新たな波長データの画像(コロナ画像と彩層低部画像)を用いた。2つ目に、特徴量として高温コロナの発光情報や、リアルタイム予測に有効な 1,2 時間前の X 線量やコロナ発光情報を追加した。3つ目には、機械学習アルゴリ

ズムとして、サポートベクターマシンや最近傍法等のベーシックな手法⁵⁾から、深層学習へと改良を行った。深層学習には、近年、機械学習の分野で開発された技法を応用し、Residual Net 等の技術を導入することで精度向上に成功した。

3. 予報運用システムの開始

今年 4 月には、Deep Flare Net 予報ウェブサイトの運用を開始した。一般ユーザーにもわかりやすい表示を心掛けた。例えば、晴れ・曇・雨のマークのように、危険・注意・静穏のアラートマークで危険度を知らせる。また黒点領域毎に、いわゆる降水確率のようにフレア発生確率をグラフで表す。スタンフォード大学/NASA から準リアルタイム

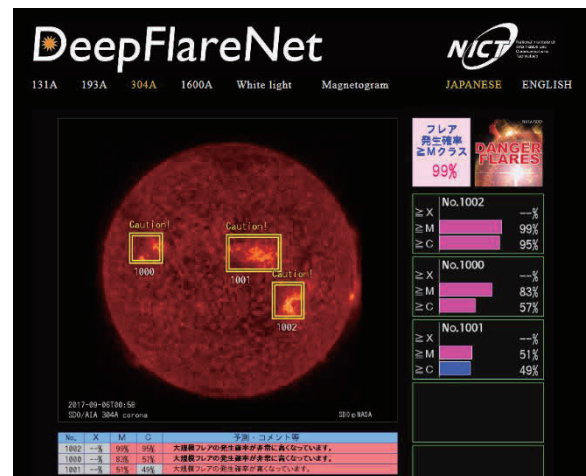


図 4 : Deep Flare Net のウェブ画像の例 (<https://defn.nict.go.jp>)

データを取得しながら、現在は6時間毎に予測を行い、その表示の更新を行っている。

4. 予報精度の評価

まず、過去データを用いた運用形式での予報結果を示す(表1)。データベースを時系列分割して、2010-2014年を学習用、2015年をテスト用として用いた。TSSを用いて評価した結果、Mクラス以上のフレアの予測ではTSS=0.80、Cクラス以上のフレア予測ではTSS=0.63を達成した。表1の右上欄と左下欄の値は予測ミスを示すが、両者はトレードオフの関係にあり、一方を減らすと、もう一方が増加する。今回TSSが大きくなるよう最適化した結果、フレアの見逃しは少なくなったが、やや過剰見積もりの傾向となった。

ここで、本予報においてフレア予測の判断基準は発生確率50%を閾値としていた。この値を変えることで、予報モデルの信頼度をある程度コントロールできる。ユーザーの利用目的に応じて、閾値を変えながらモデルを選択することができる。例えば、過剰予報とを感じる際には閾値を80%など高めに引き上げればよく、一方で見逃しを避けたいければ、50%のままでよい。

≧M-class		Observation	
		flare	no
Prediction	flare	963	4382
	no flare	54	25937
TSS= 0.80			
≧C-class		Observation	
		flare	no
Prediction	flare	4967	4420
	no flare	1171	20778
TSS= 0.63			

表 1: 過去データを用いた予報運用形式での太陽フレアの予報結果と TSS による評価。

次に、リアルタイム予報運用での結果を表2に示す(2019年1~5月データを利用)。Mクラス以上の太陽フレアの発生は観測されなかったため、TSSによる評価はない。Cクラス以上のフレアに関しては、TSS=0.82を達成した。これは、過去データをもとに予報運用形式で評価した結果と似た傾向にあり、リアルタイム運用でも人手による予報精度(TSS~0.5)を超える精度を達成し、かつ時系列分割を用いた予報運用形式での評価手法の妥当性が確認された。

≧M-class		Observation	
		flare	no
Prediction	flare	0	25
	no flare	0	491
TSS= none			
≧C-class		Observation	
		flare	no
Prediction	flare	26	24
	no flare	4	463
TSS= 0.82			

表 2: リアルタイム予報運用での太陽フレアの予報結果と TSS による評価。

5. まとめと将来展望

我々は、深層学習を用いた太陽フレア予測モデル Deep Flare Net (DeFN) を開発した。本モデルは、24時間以内に発生する最大規模の太陽フレアを準リアルタイムで自動的に予報することができる。4月からはウェブサイトでの予報運用も開始し、運用を行いながら予測精度の検証を行っている。過去データを用いた運用形式での予測精度評価、および2019年1~5月のリアルタイム予報結果を用いた評価では、人手による予報精度(TSS~0.50)を上回る精度(TSS~0.80)を達成することに成功した。

本予報モデルの特長は、黒点領域ごとに太陽フレアの発生確率予報を行うことができる点にある。太陽フレア予測のための予報確率の閾値は、ユーザーの利用目的に応じて50%から自由に変更することができる。Deep Flare Netの予報ウェブサイトは、一般ユーザーにもわかりやすい表示を心がけているが、ご覧頂いた方々の意見を参考に、今後も予報モデルの改良と、表示方法の改善とを行っていききたい。

衛星運用者や有人宇宙ミッション運用者にとっては、太陽フレアによるX線だけでなく、プロトンや電子といった高エネルギー粒子の予報情報も重要である。高エネルギーのプロトンは、その生成機構（加速機構）が太陽フレアの発生機構よりも未解明であり、粒子と現象間の8桁ものスケールギャップが物理的な数値シミュレーションをも困難にしている。非常に挑戦的な課題であるが、機械学習手法を用いた新しいアプローチは、打開の道を拓く可能性がある。今後、衛星運用の効率化や宇宙探査の支援にもなるよう、太陽フレア予測モデルからコロナ質量放出や高エネルギー粒子の予測モデルへの拡張にも挑戦していききたい。

参考文献

- 1) Crown, M. D., 2012, Space Weather, 10, S06006
- 2) Kubo, Y., Den, M., & Ishii, M. 2017, J. Space Weather Space Climate, 7, A20
- 3) Nishizuka, N., Sugiura, K., Kubo, Y. et al., 2018, Astrophys. J., 858, 113,
- 4) 西塚直人, 天文月報 2019年, 第112巻, 第6号, 385
- 5) Nishizuka, N., Sugiura, K., Kubo, Y. et al., 2017, Astrophys. J., 835, 156