

# 深層学習による太陽フレア予測

## Deep Flare Net



西 塚 直 人

〈情報通信研究機構・電磁波研究所 〒184-8795 東京都小金井市貫井北町 4-2-1〉  
e-mail: nishizuka.naoto@nict.go.jp

太陽フレアは、主に黒点付近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、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、いまだ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観測磁場画像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、黒点毎の確率予報を可能にし、従来の人手による約5割の予報精度を8割まで向上することに成功した。本稿では我々の深層学習予測モデル（Deep Flare Net）を紹介し、観測データから得られる特徴量の重要度ランキング解析からフレアの発生機構を探る新たなアプローチについても解説する。

### 1. はじめに

太陽面爆発フレアは、太陽系最大の爆発現象であり、天体プラズマ現象の中で最も観測データに富んだ現象である。100年以上もの観測の歴史があり、近年は「ひので」やSDO衛星による衛星観測により、常時高分解されたコロナや磁場の状態を知ることができるようになった。一方、宇宙利用とICT化の進む現代社会において、太陽フレアのもたらすX線放射、高エネルギー粒子や地磁気擾乱といった現象は、しばしば我々社会に影響を及ぼすものである。2017年9月には、11年ぶりに巨大フレアが発生してニュースにもなった。また、ICAO（国際民間航空機関）における宇宙天気情報の利用義務化が進むなか、太陽フレア発生機構の理解と予測精度の向上は喫緊の課題である。

宇宙天気とは、太陽フレアに伴う上述のような自然現象から我々社会の通信・測位や電力といったインフラ影響までの全体を指し、日本では電離層よりも下層大気に対する予報を天気予報<sup>1)</sup>、そ

れ以外を宇宙天気予報として区別している。宇宙天気予報は、元は電波通信の警報から始まり、今から約30年前の国際宇宙ステーション建設開始頃にこのように呼ばれるようになった。初期は白色光観測による黒点形状の分類をもとに、人手による予測が行われてきたが<sup>2)</sup>、近年は観測データのビッグデータ化と機械学習手法の発展普及により、太陽フレア予測に機械学習を適用した研究が、世界的なトレンドになりつつある<sup>3),4)</sup>。

機械学習は、人手では扱えないような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<sup>5)</sup>。深層学習も機械学習の一種で、多層のニューラルネットワーク構造をもとに、入力データの特徴をより深く学習し、精度のよい予測結果を出すことが可能である<sup>6),7)</sup>。従来の太陽物理学では、ある典型的もしくは極端な例のイベント解析や数値モデリングが主流であった。しかしそれだけでは太陽フレアの全体像を得ることは難しく、必要十分な予測手法の確立に

至っていない。太陽フレア予測への機械学習や深層学習手法の応用は、太陽フレアの発生機構を理解するための新しいアプローチとして期待される。

## 2. 太陽黒点の成長とフレア発生

### 2.1 フレア発生機構のシナリオ

太陽フレアの発生機構の概要を図1に示す。太陽ダイナモが源となって太陽内部で磁場が生成され、磁束管の浮上によって太陽表面に黒点が形成される。黒点には正負の極性があり、その境界線（磁気中性線と呼ばれる）上空には磁気ループ（アーケード）構造ができる（STEP1）。黒点の成長とともに黒点面積は増大しながら、磁気中性線を境に反対方向のプラズマの流れが生じて、磁気ループ構造は歪みつつエネルギーを蓄積する。また新たな浮上磁場の出現や別の流れによって、黒点の磁場構造は複雑化する（STEP2）。磁気ループ構造の上空には、振れた磁束管が形成され、H $\alpha$ フィラメントやプロミネンスとして観測される。この振れた磁束管は、初期には磁場の力によって上空に飛び出す力と引き留める力がつりあっている。しかし、磁気ループが歪むことで黒点に十分

磁気エネルギーが蓄積されると、平衡不安定な状態になる。そのような状態で新たな浮上磁場が出現すると、全体の磁場構造が変化し、その結果、磁束管噴出がトリガーされる。噴出する磁束管下部のコロナでは、磁気リコネクションによる磁場のつなぎ変えとエネルギー変換が雪崩的に起こり、プラズマの加熱と粒子加速により、多波長の電磁パルスと高エネルギー粒子が惑星間空間に放出される（STEP3）<sup>9)</sup>。

フレアの発生機構の解明は、太陽物理学の長年の課題である。上述した太陽フレアの理解も、多くの研究者の努力の賜物である。例えば、地上観測や衛星観測による多波長高分解能観測が行われ、詳細なデータ解析が行われた。一方で、それらの観測から得られたアイデアをもとに、物理モデルに基づいた数値シミュレーション研究が行われている<sup>10), 11)</sup>。これらの手法は、ある特定の太陽フレアの発生機構とその素過程を解明するには有効である。しかし、より全般的な太陽フレアの発生機構を網羅し、精緻な予測モデルを確立するまでには至っていない。

### 2.2 太陽フレアの予報運用

現在、太陽フレアの予報運用は、著者の所属する情報通信研究機構の宇宙天気予報センターにて行われている。1日1回、毎日14時半に予報会議が開催され、1-2名の予報官と数名の研究者によって人手により行われる。そして、今後24時間以内に発生する最大規模の太陽フレアを予測する。

太陽フレアの規模は、米国気象観測衛星GOESに搭載された軟X線観測装置（1.0-8.0 Å）の値に基づいて5段階にクラス分けされる。太陽フレアの規模とは、地震のマグニチュードのようにエネルギーが1桁変わるとにクラス分けされ、最大規模のものをXクラス、中規模をMクラス、小規模をCクラスと呼ぶ（図2、表1）。フレア発生頻度は、11年の黒点周期にあわせて変化するが、Xクラスで年2-3回、Mクラスで20-30回、Cクラスは300回というように小さいものほど頻発し

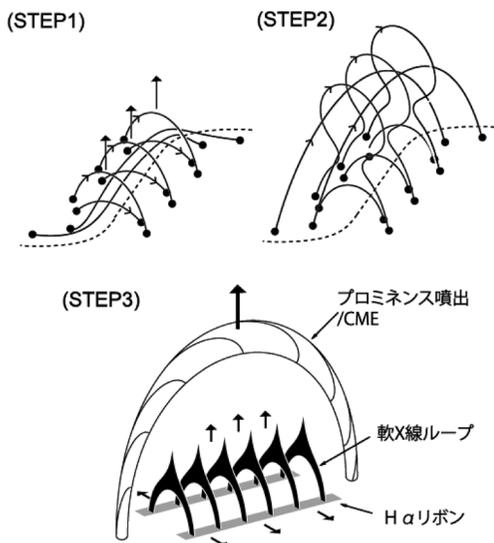


図1 太陽フレア発生の概念モデル<sup>8)</sup>。

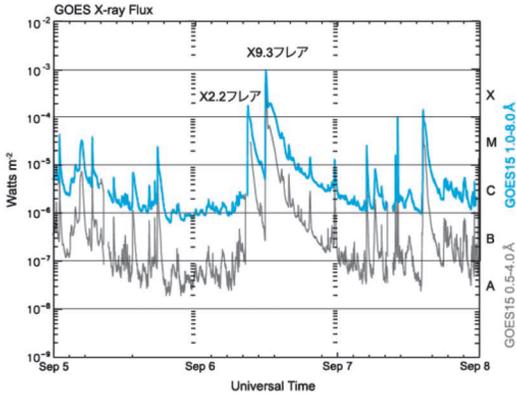


図2 2017年9月の大規模太陽フレアを含む3日間の軟X線量観測 (GOES/NOAA).

表1 太陽フレアのクラス分けと発生頻度.

フレアの規模	最大X線量 $F_X$ [ $W/m^2$ ]	年間発生頻度
X	$10^{-4} < F_X$	3回
M	$10^{-5} < F_X < 10^{-4}$	30回
C	$10^{-6} < F_X < 10^{-5}$	300回
B	$10^{-7} < F_X < 10^{-6}$	3,000回
A	$10^{-8} < F_X < 10^{-7}$	

ている。逆に大規模なフレアは稀な現象であり、後述する機械学習分野ではインバランス問題とよばれる。大規模なフレアが起こると、通常の100~1,000倍のX線が地球に降り注ぎ、短波通信の異常（デリンジャー現象）や衛星測位誤差などが発生する。

予報会議ではGOES衛星の軟X線量観測の他に、太陽黒点形状や、NASAのSDO衛星によって観測されたコロナ極端紫外線動画、視線方向磁場とベクトル磁場画像を確認することで予報を行っている（詳細は表2参照）。黒点形状はマッキントッシュ分類<sup>12)</sup>に基づき、単極磁場を $\alpha$ 型、双極磁場を $\beta$ 型、やや複雑な極性磁場を $\gamma$ 型、非常に複雑だと $\delta$ 型と分類する。Xクラスフレアを発生するのは大きな $\delta$ 型黒点であることが多い。また傾向として、太陽フレアの活動度は次の日も続くことが多い。逆に言うと、活動度の上昇下降のタイミングをいかに言い当てるかが腕の見せど

表2 NICT予報会議で確認する太陽黒点の特徴.

- ①白色光：黒点面積，黒点形状 ( $\alpha\beta\gamma\delta$ )
- ②軟X線：フレア実績，背景値
- ③光球磁場：磁気中性線の勾配・長さ  
磁気構造の複雑性，  
磁気シア角，浮上磁場
- ④彩層底部：1600Å連続光での増光
- ⑤リム観測：東端領域の回り込み

ころである。

また、黒点領域の蓄積されたエネルギー量やトリガー現象を観測的に把握することが、フレアの予測にとって重要だ。例えば、大きなフレア前には、黒点の磁気中性線が長く明瞭になってきたり、磁気中性線の周囲にシア（歪み）が溜まったり、彩層底部で頻繁に光ったりする<sup>13), 14)</sup>。これらを確認するために、ベクトル磁場の水平磁場成分を確認したり、紫外線1600Å連続光を見たりする。また、新たに東端から出現する活動領域についても、SDO衛星では足元の磁場はまだ見えないが、別の衛星観測（STEREO）による太陽裏面での活動度を参考に予測を行っている。

### 2.3 現状の太陽フレア予測の問題点

従来、太陽フレアの予測は人手による経験的手法、統計的な手法、物理モデルに基づいた数値シミュレーションによる手法といった3手法による研究が行われてきた。しかしながら、人手による予測精度は約3-5割程度に留まっている<sup>2), 15), 16)</sup>。新たな観測装置が増え、黒点磁場やコロナの高分解能観測データがリアルタイムで取得できるようになってきた。その一方で、1日1.5TBを超える観測データの解析は人手では追い付かず、予報に十分活かされていなかったためである。理論数値シミュレーション研究も進んできてはいるが、太陽内部の磁場状態がわからず、依然予報は難しい。

近年、第4のアプローチとして、人工知能(AI)技術である機械学習を応用した予測手法の開発が着目されている。機械学習は、人工知能と統計学の研究が融合してできた分野で、大量のデータを

処理するのに向いている。また、過去の大量のデータをもとに学習モデルを作成し、未知（新出）のデータの予測や分類を行うことができる<sup>5)</sup>。統計学との違いは、統計学は現象の理由説明を第一にするが、機械学習は予測スコア（詳細は4.1章）を最大化することを第一にしている点である。中でも、深層学習は既存のアルゴリズムよりも予測精度を遙かに上げることに成功し、碁でプロ棋士に勝つなど成長目覚ましい。また画像データを直接入力して、画像解釈から分類予測までできるようになり、社会普及を急速に加速させた。

筆者らは、この機械学習手法を太陽フレア予測に応用した。機械学習を太陽観測データに適用することで、今まで処理できていなかった大量データをリアルタイムで解析しながら予測できるようになる。今まで専門家の経験や直観に頼っていた部分が定量的な予測になり、判断基準も明確化され、個人差もなくなる。自動化することで、1日1回から予測頻度を増やすこともでき、各回の予測結果を次にフィードバックすることも可能になる。網羅的に全データを解析することで、フレア発生の必要十分条件を知ることもでき、新たな特徴量を導入することで、未知の太陽フレアの発生機構の解明に迫ることも期待される。

筆者らは、まず古典的な3つの機械学習手法の適用によって機械学習の応用可能性を探った（サ

ポートベクターマシン、最近傍法、ランダムフォレストを利用)<sup>17)</sup>。過去データを用いて評価した結果、人手を上回る予測精度が達成できる可能性が示された。一方で、実運用形式での予報評価を行うと、まだ精度不十分であることがわかってきた。そこで次章からは、新たに深層学習を用いた手法を開発し、どのように精度向上を図ってきたかを紹介したい。

### 3. フレアの深層学習予測モデル

#### 3.1 予測モデルの概要

本章では、筆者らが開発した深層学習を適用した太陽フレア予測モデル、Deep Flare Net（略称DeFN）について紹介する<sup>18)</sup>（図3）。このモデルは、太陽面上の各黒点領域で、今後24時間以内に起こる太陽フレアの発生確率をクラス別に求め、最大規模のフレアを予報する。

まず本モデルを理解するために、顔認識技術の例を考えてみよう。顔認識の場合、まず写真から目・鼻・口といった部位を見つけ出し、各部位の特徴を解析する。そして別の写真で似た特徴をもつ領域を、同じく目・鼻・口と識別する。フレアの予測も原理は同じで、太陽画像から黒点領域を検出し、その特徴を解析する。そして過去のフレア発生領域と似た特徴をもつ領域が現れた時、フレアの発生確率が高いと予測する。

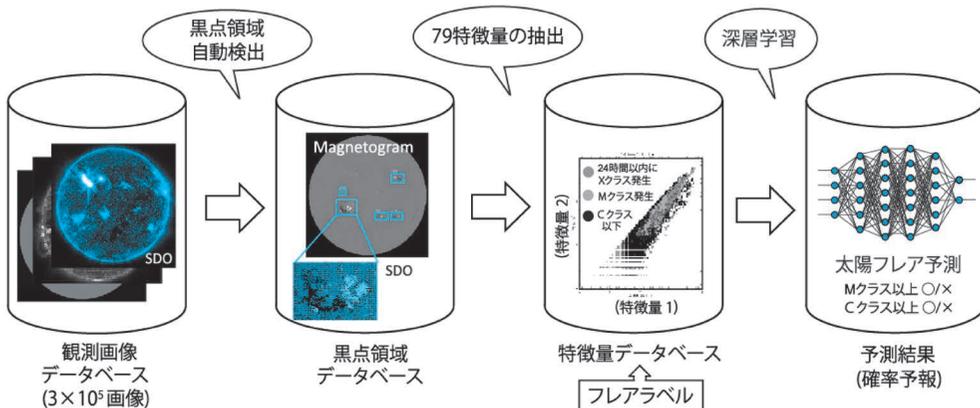


図3 太陽フレア予測モデル (Deep Flare Net) (文献18から引用改訂)。

ここで特徴データに目・鼻・口といった正解データをつけたり、太陽フレアを24時間以内に発生したかといった正解データをつけたりすることをラベル付けと呼ぶ。地味で時間と労力を要する部分であるが、モデルの精度を大きく左右する大事な作業である。こうした正解つき学習データを用いた機械学習を“教師あり機械学習”といい、今最も社会応用が進んでいる。

### 3.2 観測データからの特徴量の抽出

次に黒点領域の特徴を具体的にみていこう。筆者らの用いた太陽観測データは、2010-2015年に観測されたSDO衛星の視線方向磁場、ベクトル磁場、コロナ、彩層底部を表す約30万枚の画像と、GOES衛星の軟X線量データである。磁場画像から黒点領域を検出し、同領域の79個の特徴を抽出した。抽出する特徴としては、日々の予報会議で着目している特徴に加え、過去のフレア予測論文の中で使用された特徴も採用した。できるだけ多くの特徴を網羅的に採用することで、予測精度を上げたり、予測に有効な特徴量の順位を調べたりした。つまり本モデルには、予報運用ノウハウと太陽物理の知識を全て注ぎ込んだと言ってもよい。

黒点磁場の視線方向成分からは、黒点サイズや最大磁場強度、磁場勾配、磁気中性線の長さ・本数、24時間の変化量などを抽出した。また水平磁場成分からは、ローレンツ力や磁気シア角度、余剰磁気エネルギーなどを見積もった(図4)。1600 Å フィルターでの彩層底部画像からは、発光強度や面積を調べた。軟X線と同程度の1千万度の131 Å輝線のコロナ画像やGOESのX線データ(1-8 Å)からは、各領域での過去の放射量最大値や平均値、フレア履歴といった活動度の特徴を抽出した。

従来の研究では磁場画像だけをもとに予測を行うことが多かったが、本モデルは、このように新たに1600 Åと131 Åのコロナ・彩層画像を追加した。また後述する特徴量ランキングから、フレア

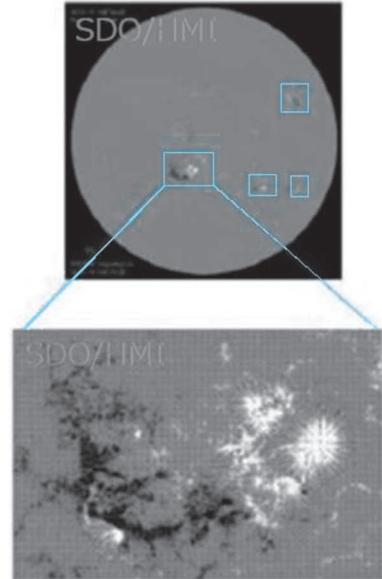


図4 太陽フレア予測モデルで用いたベクトル磁場(水平磁場成分)データの例。

履歴やX線量が有効だとわかったので、X線や131 Åの1,2時間前データなど19特徴量を新たに採用し、リアルタイム予測のための改良を行った。

### 3.3 深層学習による予測

機械学習を用いたリアルタイム予測を実現するため、筆者らは機械学習の中でも現状最大性能を有する深層学習を用いて精度向上を図った。深層学習<sup>6),7)</sup>は英語でDeep Neural Network(略称DNN)と呼び、ニューラルネットワークの層を3層以上に増やすことで「深い」学習を可能にしたものである。筆者は、機械学習手法の専門家と協力し、音声翻訳に用いられている技術を太陽フレア予測に応用することを試みた。

図5はニューラルネットワークの構造を表す。左側から観測特徴量(X)を入力し、右側で太陽フレアの発生確率(Y)を出力する。各層では式(1)のような線形変換と非線形変換を繰り返しながら、より良い特徴の抽出と分類を行う。

$$y=f(x; W, b)=f(Wx+b) \tag{1}$$

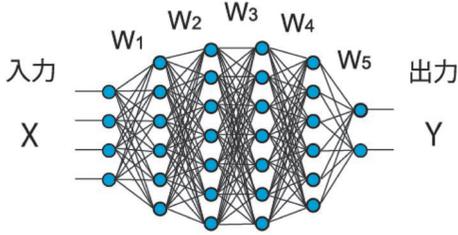


図5 ニューラルネットワークの概要.

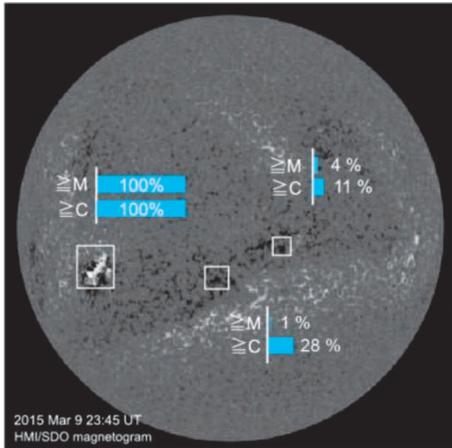


図6 黒点領域ごとの太陽フレアの確率予測.

ここで  $W$  は線形変換行列 (重み),  $f$  は活性化関数と呼ばれる非線形関数である. 図5で各点を結ぶ直線は線形の足し算を意味している. また最終層のみ以下のソフトマックス関数

$$\text{Softmax}(x_i) = \frac{\exp(x_i)}{\sum_{j=1}^N \exp(x_j)} \quad (2)$$

を作用することで, フレア発生確率を算出し, 50%との大小関係をもとに, 各黒点領域でのフレアの発生を予測する (図6).

学習モデルでは, 正解ラベルをもとに答え合わせをしながら予測誤差 (とスキルスコア) を計算し, 誤差を最小化 (スコアを最大化) する方向に線形変換係数 (重み) の修正を繰り返すことで, 最適な予測モデルを見つけ出す. 一般的に, ニューラルネットワークは層数が多いほど, また, 入力データの次元 (特徴量の数) が増えるほど性能

が上がる. しかし同時に, 計算コストも要求される計算精度も上がり, 過学習・勾配消失といった問題も生じる. 過学習とは, 過度に学習データに適合しすぎると上手く予測できなくなることである. また損失関数の勾配消失が起こると, 誤差逆伝搬法による重みパラメータの修正ができず, 同じく予測精度が上がらない. 本モデルでは, 深層学習の最近の技法をもとに, ReLU<sup>19)</sup> という活性化関数やバッチ正規化<sup>20)</sup>, スキップ接続<sup>21)</sup> といった手法を組み込むことによって, 8層のニューラルネットワーク構造を達成した. また過剰予測の傾向があったので, 誤差関数として用いる交差エントロピーに重みをかけたりするなど, 試行錯誤による工夫を行った.

AI技術で性能が上がる理由は, 人より優れた記憶力や計算力の他に, 学習の繰り返しが速いことである. 一方でAI技術も万能ではなく, まだ自分で学習手法を学ぶことができない. 親や教師が子供や生徒に教えるように, AIも良質の教材データを与えて教えてあげない限り成長しない. どれだけ人のノウハウをつぎ込むかで性能が決まってくるところに, ある種の面白み (と苦勞) がある.

## 4. 太陽フレアの予測結果

### 4.1 予測結果とスキルスコア

予測性能の指標として, ここでは True Skill Statistics (TSS)<sup>22)</sup> というスキルスコアを用いた

$$\text{TSS} = \frac{TP}{TP + FN} - \frac{FP}{FP + TN} \quad (3)$$

(図7(a) 参照). このスコアは, 太陽フレアの起きた場合の的中率から起きなかった場合の非的中率を引き算したもので, インバランスな予測問題の評価に適している. また, フレア有無のデータ量比に依存しないため, 異なるデータを用いた論文比較にも便利である.

次に, 学習モデルを使って予測評価するには, データベースを学習用と評価用に分割する必要が

(a)

		観測	
		フレア	なし
予測	フレア	TP	FP
	なし	FN	TN

(b)  $\geq M$ クラス

		観測	
		フレア	なし
予測	フレア	963	4382
	なし	54	25937

TSS=0.80

(c)  $\geq C$ クラス

		観測	
		フレア	なし
予測	フレア	4967	4420
	なし	1171	20778

TSS=0.63

図7 太陽フレア予測の分割表<sup>18)</sup>.

ある．やってみると，この学習評価データの作り方に予測の難易度が依存することに気づいた．筆者らは最初，特徴量データをランダムに混ぜて7:3に分割する手法を用いた．機械学習分野で一般的に用いられる手法で，サポートベクターマシン等を用いてTSS=0.8-0.9の結果を得ることに成功した<sup>17)</sup>．しかし，より予報運用形式に近い時系列分割による予測評価を行うと，TSS=0.2-0.3の精度しか得られないこともわかった．この理由は，ランダムにデータを学習用と評価用に分割した場合，隣り合う1時間差のデータが学習用と評価用の両方に入ってしまう得からである<sup>23)</sup> (図8)．グローバルな黒点磁場は1時間ではほぼ変化しないため，予め正解を知った場合が起こり得て，実際よりもスコアが良く出てしまうことが起こり得る．

そこで筆者らは，さらなる精度アップの必要に迫られ，前述のように①新波長データの追加(131 Å)，②リアルタイム予測に有効な新特徴量

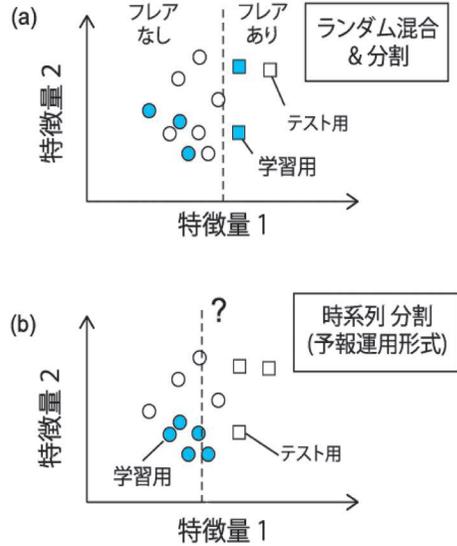


図8 学習用データとテスト用データの分割手法.

の追加 (19個)，③深層学習による予測アルゴリズムの強化の3点セットで精度向上を図ったのである．運用形式で行った予測評価の結果を図7(b)-(c)に示すが，結果としてMクラス以上のフレア予測で，約8割 (TSS=0.8) の予測精度の達成に成功した<sup>18)</sup>．Cクラス以上ではTSS=0.63と少し低くなるが，これはCクラスフレアが発生する場合としない場合とのデータの境界が曖昧であることに起因している．Xクラスの予測に関しては，深層学習を単純に適用するにはイベント数が足りないため，予測評価は今後の課題とした．

#### 4.2 特徴量のランキング

ここで，何の特徴量が予測に有効であるかを知りたくはないだろうか．通常の深層学習モデルでは予測過程はブラックボックスである．しかし本モデルでは，物理的な特徴量を手動で計算して入力しているため，ランキングを解析できるのが特長である．79個の特徴量から1つずつ省きながら予測スコアを比較すると順位は出せるのだが，ここでは別途Extremely Randomized Trees (ERT)<sup>24)</sup> というアンサンブル学習 (ランダムフォレストの派生モデル) を用いた重要度 (Importance) のラ

表3 特徴量の重要度ランキング<sup>17)</sup>

順位	特徴量	重要度
1.	Xhis	0.0519
2.	Xmax1d	0.0495
3.	Mhis	0.0365
4.	TotNL	0.0351
5.	Mhis1d	0.0342
6.	NumNL	0.0341
7.	Usflux	0.0332
8.	CHArea	0.0235
9.	Bave	0.0230
10.	Xhis1d	0.0224
11.	TotBSQ	0.0199
12.	VUSflux	0.0196
13.	Bmax	0.0193
14.	MeanGAM	0.0179
15.	dt24SavNCPP	0.0171

ランキング結果を示す<sup>17)</sup>(表3)。

この特徴量の重要度は、各ノードの分類識別でジニ不純度がどれだけ減少したかをもとに評価される<sup>25), 26)</sup>。ジニ不純度とは、データが純粋だと最も小さく、均一に混ざっていると最大になる。ただ特徴量ランキングはモデル毎に異なり、ERTとDeFNの結果が必ずしも一致しないことは留意してほしい。また線形モデルのランキングは人の直観に近いが、非線形では必ずしもそうでないとも言われている。

表3の重要度の高い特徴は、上位からフレア履歴(Xhis, Mhis)や過去のX線最大値(Xmax1d)、次に磁気中性線の長さ(TotNL)や本数(NumNL)、磁束密度(Usflux)、そして彩層底部発光(CHArea)に平均磁場強度(Bave)、ベクトル磁場特徴量(TotBSQ, MeanGAM, dt24SavNCPP)といった順であった。端的には、太陽フレアは同じ領域から繰り返し発生しやすく、次に磁気エネルギーの蓄積や前兆現象として観測される特徴が重要そうである。今回新たに選んだ磁気中性線の長さや本数、彩層底部発光の特徴が重要であることが示されたのは新しく、また過去データとして約30万もの大量のデータを網羅的に解析した例も初めてである。

## 5. 今後の展望

今まで見てきたように、太陽フレアの発生機構の理解と予測の新しいアプローチとして、機械学習手法の有効性が明らかになってきた。過去データを用いて運用形式の予測評価を行っても、従来の人手の予測精度を超えることが示された。次の段階として、現在は実運用への導入を図りつつ、リアルタイムで人手による予測結果と比較して検証を行っている。

残った課題も多い。一番の関心は、深層学習でよく用いられる画像特徴量を用いた予測手法との比較だ。畳み込みニューラルネット(略称CNN)によって太陽磁場画像から特徴量を自動的に抽出し、フレアを予測するモデルが現在複数開発されている<sup>27)-30)</sup>。筆者らのDeFNモデルは、これらCNNモデルと同等かそれ以上の性能をもつ。これは一重に、太陽研究の歴史のお蔭だ。逆に開発途中で他のモデルに精度が及ばなかった当初は、人手による特徴量はAIに勝てないのかと何度も打ちひしがれた。また今後、フレアの予測時間を、今の24時間から短くしたり長くしたりすることで予測精度がどのように変わるか調べるのも大事だ。

さらに、物理モデルに基づいた数値シミュレーションとの共同研究も今後検討したい課題である。例えば、数値シミュレーションによるコロナ中の観測されていない特徴量を機械学習に入力したらどうなるかとか、逆に重要度ランキングの高い特徴量を数値シミュレーションで詳細解析して物理的な理由を追及してみるなど面白くないだろうか。一方、観測家の方々には、是非今まで見たことのない観測データを撮りためて頂き、機械学習に入力できるようになると面白そうである。

本研究を始めるまで、機械学習は筆者にとって未知の分野で、修士の学生に戻ったような気持ちで一から勉強した。機械学習専門家らとは、異分野間コミュニケーションの難しさもある。研究す

るにも新規開拓分野なので、試行錯誤で悩むことも多いが、わくわく感や刺激も多い。是非若い人を中心に、新たなアプローチとして一緒に挑戦して貰えると嬉しく思う。

謝 辞

本稿の内容は筆者の査読論文に基づいており、共同研究者の杉浦孔明氏には多くのご助言頂き感謝申し上げます。また本研究は文部科学省科学研究費補助金 (JP18H04451) より援助を受けている。

参考文献

- 1) 昭和二十七年法律第六十五号, 気象業務法, 第二条
- 2) Crown, M. D., 2012, SpWea, 10, 6006
- 3) Bobra, M., & Couvidat, S., 2015, ApJ, 798, 135
- 4) Muranushi, T., et al., 2015, SpWea, 13, 778
- 5) Bishop, C. M., 2006, Pattern Recognition and Machine Learning (Springer: New York)
- 6) Hinton, G. E., et al., 2006, Neural Computation, 18, 1527
- 7) LeCun, Y., et al., 2015, Nature, 521, 436
- 8) Priest, E. R., & Forbes, T. G., 2002, A&AR, 10, 313
- 9) Shibata, K., & Magara, T., 2011, Living Rev. Sol. Phys., 8, 6
- 10) Kusano, K., 2012, ApJ, 760, 31
- 11) Inoue, S., et al., 2014, ApJ, 788, 182
- 12) McIntosh, P. S., 1990, Sol. Phys., 125, 251
- 13) Moon, Y. -J., et al., 2004, JKAS, 37, 41
- 14) Bamba, Y., et al., 2013, ApJ, 778, 48
- 15) Devos, A., et al., 2014, JSWSC, 4, 29
- 16) Kubo, Y., et al., 2017, JSWSC, 7, 20
- 17) Nishizuka, N., et al., 2017, ApJ, 835, 156
- 18) Nishizuka, N., et al., 2018, ApJ, 858, 113
- 19) Nair, V., & Hinton, G. E., 2010, in Proc. 27<sup>th</sup> Int. Conf. Machine Learning, eds. Furnkranz, J., Joachims, T., (Omnipress, Madison) 807
- 20) Ioffe, S., & Szegedy, C., 2015, in Proc. 32<sup>nd</sup> Int. Conf. Machine Learning, eds. Bach, F., & Blei, D., (JMLR.org) 448
- 21) He, K., et al., 2016, IEEE Conf. Computer Vision and Pattern Recognition (IEEE) 770
- 22) Hanseen, A. W., & Kuipers, W. J. A., 1965, Mededelingen en verhandelingen, 81, 3
- 23) Nishizuka, N., et al., 2018, in IAU Symp 335, Space Weather of the Heliosphere, eds. Foullon, C., & Malandraki, O. E., (Cambridge University Press) 310
- 24) Geurts, P., 2006, Mach. Learn, 63, 3
- 25) Breiman, L., 2001, Mach. Learn, 45, 5
- 26) Louppe, G., et al., 2013, in Advances in Neural Infor-

- mation Processing Systems 26 (NIPS 2013), eds. Burges, C. J. C., et al., (Curran Associates, Inc., New York) 431
- 27) Huang, X., 2018, ApJ, 856, 7
- 28) Jonas, E., 2018, Sol. Phys., 293, 48
- 29) Nagem, T. A. M. H., et al., 2017, in Proc. Computing Conf. 2017, (Curran Associates, Inc., New York) 697
- 30) Park, E., et al., 2018, ApJ, 869, 91

Solar Flare Prediction by Deep Neural Networks: Deep Flare Net

Naoto NISHIZUKA

National Institute of Information and Communications Technology, 4-2-1 Nukui-Kitamachi, Koganei, Tokyo 184-8795, Japan

Abstract: Solar flares release magnetic energy stored around sunspot regions. X-ray emissions and high energetic particles in association with flares can affect our social infrastructure, so it is important to understand the occurrence mechanism of solar flares and predict them more accurately. Here we introduce our solar flare prediction model using deep neural networks, named Deep Flare Net (DeFN), which improved the prediction skill score, the true skill statistics (TSS) from 0.5 by human forecasts to 0.8. We also introduce the feature ranking of importance, calculated by a machine-learning technique, and discuss a new approach to reveal the flare occurrence mechanism.