

# FLARE-SSM：クラス不均衡下における 長期時系列予測のための深層状態空間モデル

高木 裕輔<sup>1,a)</sup> 長嶋 隼矢<sup>1,b)</sup> 杉浦 孔明<sup>1,c)</sup>

## 概要

正確で信頼性の高い太陽フレア予測は、重要インフラへの影響を最小限に抑えるために不可欠であるが、現在でも太陽フレア予測の性能は依然として十分ではない。本研究では、72 時間以内に発生する最大の太陽フレアクラスを予測するタスクを扱う。既存手法は、フレアクラス間における発生頻度の不均衡に対する十分な対処がなされていない。そこで本研究では、複数の深層状態空間モデルに基づく太陽フレア予測モデルを提案する。さらに frequency & local-boundary-aware reliability loss (FLARE loss) を導入し、クラス不均衡下における予測性能および予測の信頼性を向上させる。約 11 年間の太陽活動周期を網羅する複数波長の太陽画像からなるデータセットにおいて実験を行った。結果として、提案手法は標準評価指標である Gandin-Murphy-Gerrity score と true skill statistic の両方で、ベースライン手法を上回った。

## 1. はじめに

太陽フレアは、GPS システム、通信ネットワーク、宇宙機、電力網などの重要インフラに深刻な影響を与える現象である [1, 3]。特に、キャリントン級のフレア [2] が発生した場合、その経済的被害額は 0.6 兆から 2.6 兆ドルに達すると推定されている [10]。このような背景から、太陽フレアの正確かつ信頼性の高い予測は極めて重要である。一方、現在も依然として太陽フレア予測は性能が十分ではない。

本研究では、72 時間以内に発生する最大の太陽フレアクラスを予測するタスクを扱う。予測結果を用いる典型的なユースケースは、航空機の進路変更や運航調整、送電網の保護措置、衛星の安全モード移行、および測位システムの誤差補正等の計画的な実施である。

72 時間以内に発生する最大の太陽フレアクラスを予測するタスクは容易ではない。実際、Gandin-Murphy-Gerrity score (GMGS) [4] と Brier Skill Score (BSS) [14] において、2010 年から 2015 年における専門家による 24 時間予測

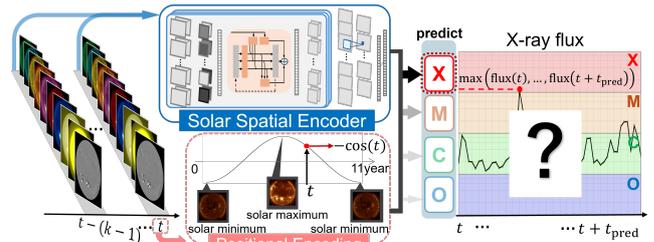


図 1: 提案手法の概要

は  $BSS_{\geq M} = 0.16$  および  $GMGS = 0.48$  程度である [7, 11]。24 時間以内の予測であっても、専門家による予測が不十分であることを考慮すると、72 時間以内における最大フレアクラスを予測するタスクは、さらに困難であると考えられる。太陽フレア予測の既存手法 [20, 17] は、24 時間の予測において良好な結果が報告されているが、フレアクラスの発生頻度の不均衡に対する十分な対処がなされていない。

そこで本研究では、深層状態空間モデルに基づく太陽フレア予測モデルを提案する。これに FLARE loss を導入し、クラス不均衡下における予測性能および予測の信頼性を向上させる。既存手法との主要な違いは、クラスの発生頻度やサンプルの影響度に基づいて重み付けを行う FLARE loss を用いる点および、11 年に渡る太陽活動周期に基づく、入力時刻の埋め込みを用いる点である。FLARE loss により、クラス不均衡下における分類性能の向上と、学習の進行に伴う決定境界付近のサンプルに対する過学習が抑制されると考えられる。また、位置埋め込みにより、太陽活動周期における入力時刻の位相情報を明示的にモデルに与えることで、予測性能の向上が期待される。

提案手法の新規性は以下である。

- frequency & local-boundary-aware reliability loss (FLARE loss) を導入する。これは (i) influence function [15] に基づく重みを BSS loss [6] に導入した IB BSS loss, (ii) クラスごとの重みを BSS loss に導入した Weighted BSS loss, および (iii) サンプルが決定境界に及ぼす影響を調整する IB loss [15] からなる。
- 11 年に渡る太陽活動周期に基づく、入力時刻の埋め込みを用いた太陽フレアの 72 時間予測を行う。

図 1 に提案手法の概要を示す。本手法では、AIA および HMI の多波長画像と、時刻  $t$  を入力する。画像は Solar

<sup>1</sup> 慶應義塾大学

a) yusuke.10.06@keio.jp

b) ng\_sh@keio.jp

c) komei.sugiura@keio.jp

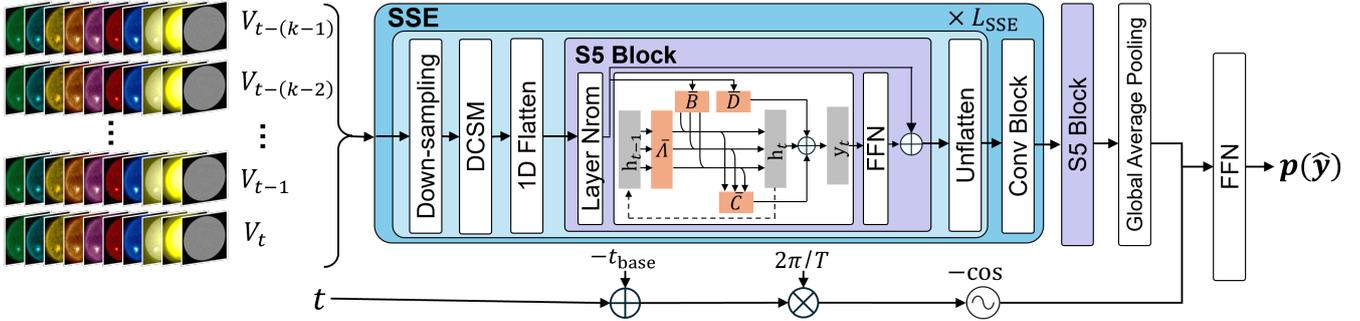


図 2: 提案手法のモデル図

Spatial Encoder によって特徴量が抽出され、時刻は 11 年に渡る太陽活動周期に基づく埋め込みに変換される。2つのモジュールの出力を統合し、4 種類の太陽フレアクラス (X, M, C, および O) に対応する予測確率を出力する。

## 2. 問題設定

本研究では、72 時間以内に発生する最大の太陽フレアクラスを予測するタスクを扱う。本タスクを多クラス分類問題として定式化する。具体的には、太陽フレアを期間内におけるピーク時の X 線フラックス (単位時間あたりの光子の発生数) に基づき、X, M, C および O の 4 クラスに分類する。本アプローチは、太陽フレア予測分野における標準的な手法 [8, 12, 18] に準拠したものである。本タスクでは、太陽フレアのクラスを正確に分類することが望ましい。

入力は、Helioseismic and Magnetic Imager (HMI) [16] 画像および 9 つの波長における Atmospheric Imaging Assembly (AIA) [9] 画像である。出力は、4 つの太陽フレアクラスのそれぞれに対応する予測確率である。

## 3. 提案手法

本研究では、Deep Space Weather Model [20] を拡張し、72 時間以内に発生する最大の太陽フレアクラスを予測するモデルを提案する。また、クラス不均衡下において予測確率の信頼性向上のため、サンプル毎の重み付けを用いた損失関数である Weighted BSS loss および IB BSS loss を導入する。Weighted BSS loss および IB BSS loss を用いた学習は、予測確率の信頼性が重視されるクラス不均衡が存在するタスクにおいて、広く適用可能であると考えられる。

### 3.1 アーキテクチャ

図 2 に提案手法のモデル構造を示す。本手法の主要モジュールは、Solar Spatial Encoder (SSE) [20] である。モデルの入力画像を  $\mathbf{x} = (\mathbf{V}_{t-(k-1)}, \mathbf{V}_{t-(k-2)}, \dots, \mathbf{V}_t) \in \mathbb{R}^{k \times C \times H \times W}$  と定義する。ここで、 $\mathbf{V}_t \in \mathbb{R}^{C \times H \times W}$  は時刻  $t$  における  $C$  チャンネルの画像を表しており、 $k$ ,  $H$ , および  $W$  はそれぞれ履歴長、画像の高さ、および幅を表す。 $\mathbf{V}_t$  の各チャンネルは HMI 画像およびいずれかの波長の AIA 画像に対応する。最新の入力画像の時刻  $t$  も入力とする。

SSE では、マルチチャンネルの太陽画像列に対し、各チャンネルの重要性を動的に重み付けしつつ、長期間にわたる時空間的な依存関係を効率的に抽出する。本モジュールにより、活動領域の微細な変化や黒点周辺のパターンを

捉えることが可能となり、フレア発生予測の精度向上に寄与することが期待される。

また、太陽活動には約 11 年の周期性が存在し、活動期には高強度の太陽フレアが高頻度で発生することが知られている [5]。この太陽活動周期における入力時刻の位相情報を明示的にモデルの入力に取り入れることにより、特に発生頻度の低いフレアクラスに対する予測性能の向上が期待される。入力  $t$  に対する埋め込み  $\phi$  を以下の式で定義する。

$$\phi = -\cos\left(2\pi \frac{t - t_{\text{base}}}{T}\right) \quad (1)$$

ここで、 $t_{\text{base}}$  および  $T$  は太陽活動周期の開始時期および周期長である。 $\mathbf{h}_{\text{SSE}}$  および  $\phi$  を用い、太陽フレアクラスの予測確率  $\mathbf{p}(\hat{\mathbf{y}})$  は以下のように得られる。

$$\mathbf{p}(\hat{\mathbf{y}}) = \text{FFN}[\text{SSMBlock}(\mathbf{h}_{\text{SSE}}; \phi)] \quad (2)$$

ここで、SSMBlock は長嶋ら [20] に基づくものである。また、FFN は順伝播層を表す。

### 3.2 損失関数

#### 3.2.1 IB loss

IB loss [15] は、クラス不均衡下における決定境界の過学習を防ぐことを目的とした、影響関数に基づくサンプル毎の重み付けを行う損失関数である。提案手法において、最後の隠れ層のノード  $\mathbf{h} \in \mathbb{R}^L$  を、 $\mathbf{h}$  の直後の全結合層の重み行列を  $\mathbf{W}$  とするとき、予測確率は  $\mathbf{p}(\hat{\mathbf{y}}) = \text{softmax}(\mathbf{W}\mathbf{h})$  で表される。ここで  $L$  は最後の隠れ層のノード数である。このとき、交差エントロピー損失に対する IB loss は以下の式で表される。

$$L_{\text{CE}}^{\text{IB}} = \frac{1}{|\mathcal{B}|} \sum_{(\mathbf{x}, \mathbf{y}) \in \mathcal{B}} \gamma(\mathbf{y}) \frac{L_{\text{CE}}(\mathbf{y}, \mathbf{p}(\hat{\mathbf{y}}))}{\|\mathbf{p}(\hat{\mathbf{y}})\|_1 \|\mathbf{h}\|_1} \quad (3)$$

ここで、 $L_{\text{CE}}$ ,  $\mathbf{y}$ , および  $\mathcal{B}$  は、それぞれ 1 サンプルに対する交差エントロピー損失、正解ラベルの one-hot ベクトル、およびバッチを表す。また、 $\gamma(\mathbf{y})$  は正解ラベルのクラスにおけるサンプル数に反比例する項である。

#### 3.2.2 Weighted BSS loss

Weighted BSS loss は、BSS loss [14] に対して、クラスのサンプル数に反比例する重みを適用する損失関数である。BSS loss は、予測確率の信頼性を重視するタスクにおいて有効であるが、サンプル数が多いクラスの損失が支配的になり、サンプル数が少ないクラスにおける予測性能が低下する問題がある。本研究では、この問題を軽減するた

めに Weighted BSS loss を導入する。1 サンプル分の BSS loss は以下の式で定義される。

$$L_{\text{BSS}}(\mathbf{p}(\hat{\mathbf{y}}), \mathbf{y}) = \sum_{k=1}^K (p(\hat{y}_k) - y_k)^2 \quad (4)$$

式 (4) を基に、Weighted BSS loss を以下のように定義する。

$$L'_{\text{BSS}} = \frac{1}{|\mathcal{B}|} \sum_{(x,y) \in \mathcal{B}} \gamma(\mathbf{y}) L_{\text{BSS}}(\mathbf{p}(\hat{\mathbf{y}}), \mathbf{y}) \quad (5)$$

### 3.2.3 IB BSS loss

IB BSS loss は、BSS loss に対して Park ら [15] と同様に、サンプル毎の影響度に基づく重み付けを行う損失関数である。BSS loss は予測と正解ラベルの二乗誤差を最小化するため、学習が進むにつれて予測が 1 または 0 に 2 乗のオーダーで近づき、過学習を起しやすという問題がある。本研究では、BSS loss において影響度の大きいサンプルの寄与を抑制することで、過学習に起因する誤った予測を軽減し、予測の信頼性を維持することを目的とし、IB BSS loss を導入する。以下では予測確率に対して交差エントロピー損失ではなく、BSS loss を用いた場合のサンプル毎の影響度を考慮した損失関数を導出する。はじめに、予測確率を最後の全結合層の重みの  $(k, l)$  要素で微分すると、以下の式となる。

$$\frac{\partial L_{\text{BSS}}}{\partial w_{kl}} = 2h_l p(\hat{y}_k) \left\{ \Delta_k - \sum_{j=1}^N \Delta_j p(\hat{y}_j) \right\} \quad (6)$$

ここで、 $\Delta_k = p(\hat{y}_k) - y_k$  である。

この結果を用いて、Park ら [15] と同様の手順により IB weighting factor は以下の式のように求められる。

$$\sum_{k=1}^K \sum_{l=1}^L \left| \frac{\partial L_{\text{BSS}}}{\partial w_{kl}} \right| = 2 \|\mathbf{p}(\hat{\mathbf{y}}) \odot \{\mathbf{\Delta} - \mathbf{1}(\mathbf{\Delta} \cdot \mathbf{p}(\hat{\mathbf{y}}))\}\|_1 \|\mathbf{h}\|_1 \quad (7)$$

ここに、 $\mathbf{\Delta} = \mathbf{p}(\hat{\mathbf{y}}) - \mathbf{y}$  である。これを用い、以下のよう  
に IB BSS loss を定義する。

$$L_{\text{BSS}}^{\text{IB}} = \frac{1}{|\mathcal{B}|} \sum_{(x,y) \in \mathcal{B}} \gamma(\mathbf{y}) \frac{L_{\text{BSS}}(\mathbf{p}(\hat{\mathbf{y}}), \mathbf{y})}{2 \|\mathbf{p}(\hat{\mathbf{y}}) \odot \{\mathbf{\Delta} - \mathbf{1}(\mathbf{\Delta} \cdot \mathbf{p}(\hat{\mathbf{y}}))\}\|_1 \|\mathbf{h}\|_1} \quad (8)$$

ここで、 $\odot$  および  $\mathbf{1}$  はそれぞれ、アダマール積およびすべての要素が 1 の  $\mathbf{y}$  と同じ形状のベクトルを表す。

### 3.2.4 FLARE loss

本研究では、クラス不均衡下における分類性能の向上と、学習の進行に伴う決定境界付近のサンプルに対する過学習の抑制を目的として、全体として以下の損失関数を用いる。

$$L = (L'_{\text{CE}} + L_{\text{CE}}^{\text{IB}}) + \lambda_{\text{BSS}} (L'_{\text{BSS}} + L_{\text{BSS}}^{\text{IB}}) \quad (9)$$

ここで、 $L'_{\text{CE}}$  および  $\lambda_{\text{BSS}}$  は Weighted CE loss および、CE loss に対する BSS loss の重みを表す。なお、学習における収束の安定性を考慮し、IB loss および IB BSS loss は学習前半では適用しない。

## 4. 実験

### 4.1 実験設定

本研究では、モデルの訓練、検証、およびテストに

表 1: 提案手法における実験設定

Epoch	20
Batch size	64
Optimizer	AdamW( $\beta_1 = 0.9, \beta_2 = 0.95$ )
Learning rate	$4.0 \times 10^{-5}$
Weight decay	$5.0 \times 10^{-2}$
$\lambda_{\text{BSS}}$	3.0
$t_{\text{base}}$	2008/12/01 00:00 UTC
$T$	48,204

表 2: ベースライン手法との定量的比較結果

Method	GMGS $\uparrow$	BSS $_{\geq M}$ $\uparrow$	TSS $_{\geq M}$ $\uparrow$
CNN-LSTM	0.359 $\pm$ 0.036	<b>0.434</b> $\pm$ 0.123	0.380 $\pm$ 0.095
Deep SWM [20]	0.418 $\pm$ 0.085	0.024 $\pm$ 0.275	0.409 $\pm$ 0.142
Ours	<b>0.484</b> $\pm$ 0.084	0.353 $\pm$ 0.089	<b>0.447</b> $\pm$ 0.127

FlareBench [20] を用いた。本ベンチマークは 11 年の太陽活動周期を含む多様な状態を網羅しており、特定の太陽活動の時期に依存しない公平な評価が可能である。FlareBench における正解ラベルは、24 時間以内の最大フレアクラスであるが、本研究ではこれを 72 時間以内の最大フレアクラスに置き換えた。また、奇数時刻のデータを除外することで、2 時間間隔のデータセットを構成した。

データセットは、2011 年 6 月から 2024 年 4 月までの約 13 年にわたって収集された 56,616 サンプルで構成されている。各サンプルは HMI 画像 1 枚および波長毎の AIA 画像 9 枚の合計 10 チャンネルのデータである。サンプルの系列は 2 時間間隔である。クラスラベルの欠損および 25% 以上の画像欠損により 8,721 サンプルを除いた。結果、47,895 サンプルをモデルの訓練および評価に用いた。25% 未満の画像の欠損があったサンプルに対して、欠損したチャンネルの画像をすべての画素値が 0 の画像で代替した。正解ラベルが X, M, C, および O クラスのサンプルの数は、それぞれ 2,131, 10,986, 16,608 および 18,170 であった。長嶋ら [20] と同様に、データセットを時系列交差検証により訓練集合、検証集合、およびテスト集合に分割した。訓練集合はモデルのパラメータ更新に、検証集合はハイパーパラメータの調整に、テスト集合はモデルの評価に使用した。

表 1 に実験で用いた設定を示す。訓練可能なパラメータ数は約 242M、積和演算数は約 2.1G であり、訓練には、メモリ 24GB 搭載の GeForce RTX 4090  $\times$  1 および Intel Core i9-14900F を使用したところ訓練時間は 1.5 時間程度、1 サンプルあたりの推論時間は 11ms 程度であった。検証集合に対して、各エポックごとに GMGS スコアを計算した。最終的なテスト集合での評価には、検証集合において最も高い GMGS スコアを示したモデルの結果を使用した。

### 4.2 定量的結果

表 2 に提案手法とベースラインの定量的比較結果を示す。各指標の値は、時系列交差検証における fold1, fold2, および fold3 を用いて求めた平均と標準偏差を示す。また、表中の太字の数値は各指標における最も高い数値を表す。

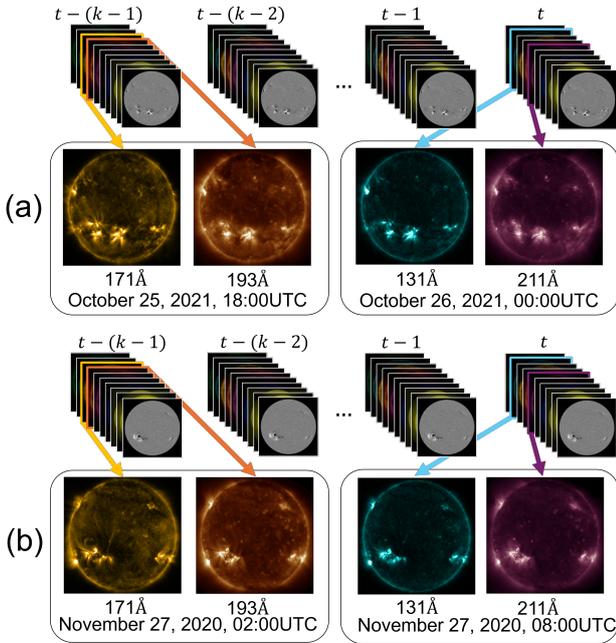


図 3: 提案手法における定性的結果

CNN-LSTM および Deep Space Weather Model (Deep SWM) [20] をベースライン手法とした。太陽フレア予測において、CNN および LSTM を組み合わせた手法が広く用いられている [13, 17]。そのため、Sun ら [17] が提案したモデルと類似する CNN-LSTM をベースラインに採用した。Deep SWM は、HMI および AIA の 10 チャンネルからなる太陽画像を用い、24 時間以内の最大フレアクラス予測タスクにおいて良好な結果を示しているため選択した。

GMGS [4],  $BSS_{\geq M}$  [14], および  $TSS_{\geq M}$  [7] を評価尺度とした。これらは、本タスクにおける標準的な評価尺度であるため採用した [8, 12, 18, 19]。ここで、GMGS は、フレアクラスに対して公平な評価を保証する指標である。また、 $BSS_{\geq M}$  は M クラス以上および M クラス未満のフレアの予測確率の信頼性を評価する指標であり、 $TSS_{\geq M}$  は M クラス以上および M クラス未満のフレアにおいて、予測精度のバランスを評価する指標である。

表 2 に示す通り、主要評価尺度である GMGS について、提案手法、CNN-LSTM、および Deep SWM はそれぞれ 0.484, 0.359, および 0.418 であった。提案手法は、CNN-LSTM に対して 0.125 ポイント、Deep SWM に対して 0.066 ポイント上回るスコアであった。また、 $TSS_{\geq M}$  については、提案手法、CNN-LSTM、および DSWM がそれぞれ 0.447, 0.380, および 0.409 であり、提案手法は CNN-LSTM より 0.067 ポイント、DSWM より 0.038 ポイント上回った。したがって、ベースライン手法と比較して提案手法が上回る結果を得た。GMGS において、ベースライン手法との性能差は統計有意であった ( $p < 0.05$ )。

### 4.3 定性的結果

図 3 の (a) および (b) に、それぞれ X クラスおよび M クラスのフレアを正しく予測した例を示す。各行には、時刻  $t - (k - 1)$  における 171 Å および 193 Å の AIA 画像と、時

表 3: Ablation study の結果。PE および HM はそれぞれ位置埋め込みおよび GMGS と  $BSS_{\geq M}$  の調和平均を表す。

Model	PE	$L_{CE}^{IB}$	$L'_{BSS}$	$L_{BSS}^{IB}$	GMGS ↑	$BSS_{\geq M}$ ↑	$TSS_{\geq M}$ ↑	HM
(i)		✓	✓	✓	0.399	0.414	0.367	0.407
(ii)	✓		✓	✓	0.390	0.427	0.272	0.407
(iii)	✓	✓		✓	0.286	<b>0.551</b>	0.308	0.377
(iv)	✓	✓	✓		0.381	0.411	0.242	0.395
ours	✓	✓	✓	✓	<b>0.484</b>	0.353	<b>0.447</b>	<b>0.408</b>

刻  $t$  における 131 Å および 211 Å の AIA 画像をそれぞれ示している。(a) に、2021 年 10 月 26 日 00:00 UTC における入力画像を示す。提案手法は 72 時間以内の最大のフレアクラスを X クラスと予測した。約 63 時間後に X クラスのフレアが観測されたため、正しい予測であった。(b) には、2020 年 11 月 27 日 08:00 UTC における入力画像を示す。提案手法は M クラスと予測し、約 53 時間後に M クラスのフレアが観測され、こちらも正しい予測であった。

### 4.4 Ablation Studies

Ablation study として以下の 4 つの検証を行った。

- (i) 位置埋め込みによる性能への寄与を調べるため、位置埋め込みを用いずに学習させた。
- (ii) IB loss ( $L_{CE}^{IB}$ ) を取り除くことで、性能にどの程度の差が生じるかを調査した。
- (iii) Weighted BSS loss ( $L'_{BSS}$ ) を用いなかった場合の性能を調査するため、Weighted BSS loss をクラスの重みを考慮しない通常の BSS loss に置き換えた。
- (iv) IB BSS loss ( $L_{BSS}^{IB}$ ) を用いなかった場合の性能を調べるため、IB BSS loss を除外した。

表 3 に ablation studies の結果を示す。モデル (i) では、GMGS および  $BSS_{\geq M}$  がそれぞれ 0.085 および 0.080 減少した。したがって、位置埋め込みが性能に寄与していることが示唆される。またモデル (ii), (iii), (iv) のいずれにおいても、GMGS および  $BSS_{\geq M}$  の調和平均が低下しており、提案手法における損失関数がいずれも性能に寄与していることが示唆される。

### 5. おわりに

本研究では、72 時間以内に発生する最大の太陽フレアクラスを予測する、多クラス分類タスクを扱った。

本研究の貢献は次の通りである。(i) influence function に基づく重みを BSS loss に導入した IB BSS loss, クラスごとの重みを BSS loss に導入した Weighted BSS loss, およびサンプルが決定境界に及ぼす過剰な影響を抑制する IB loss から構成される、FLARE loss を導入した。(ii) 11 年に渡る太陽活動周期に基づく入力時刻の埋め込みを用いた、太陽フレアの 72 時間予測を行った。(iii) 提案手法は GMGS および  $TSS_{\geq M}$  においてベースライン手法を上回る結果を得た。

### 謝辞

本研究の一部は、JSPS 科研費 23K28168 の助成を受けて実施されたものである。

## 参考文献

- [1] Bhattacharjee, S. et al.: Supervised Convolutional Neural Networks for Classification of Flaring and Nonflaring Active Regions Using Line-of-sight Magnetograms, *The Astrophysical Journal*, Vol. 898, No. 2, Article 98, pp. 1–16 (2020).
- [2] Cliver, E. W. and Dietrich, W. F.: The 1859 space weather event revisited: limits of extreme activity, *Space Weather*, Vol. 11, No. 2, pp. 74–79 (2013).
- [3] Deshmukh, V., Berger, T., Meiss, J. and Bradley, E.: Shape-based Feature Engineering for Solar Flare Prediction, *AAAI*, Vol. 35, No. 17, pp. 15293–15300 (2021).
- [4] Gandin, L. S. and Murphy, A. H.: Equitable Skill Scores for Categorical Forecasts, *Monthly Weather Review*, Vol. 120, pp. 361–370 (1992).
- [5] Hathaway, D. H.: The Solar Cycle, *Living Reviews in Solar Physics*, Vol. 7, No. 1, Article 1, pp. 1–65 (2010).
- [6] Kaneda, K. et al.: Flare Transformer: Solar Flare Prediction using Magnetograms and Sunspot Physical Features, *ACCV*, pp. 1488–1503 (2022).
- [7] Kubo, Y. et al.: Verification of operational solar flare forecast: Case of Regional Warning Center Japan, *J. Space Weather Space Clim.*, Vol. 7, Article 20, pp. 1–29 (2017).
- [8] Leka, K. D. et al.: A Comparison of Flare Forecasting Methods. III. Systematic Behaviors of Operational Solar Flare Forecasting Systems, *The Astrophysical Journal*, Vol. 881, No. 2, Article 101, pp. 1–23 (2019).
- [9] Lemen, J. R., Title, A. M. et al.: The Atmospheric Imaging Assembly (AIA) on the Solar Dynamics Observatory (SDO), *Solar Physics*, Vol. 275, No. 1, pp. 17–40 (2012).
- [10] Maynard, T., Smith, N. and Gonzalez, S.: Solar storm risk to the North American electric grid, Technical report, Lloyd’s (2013).
- [11] Murray, S. A., Bingham, S. et al.: Flare forecasting at the Met Office Space Weather Operations Centre, *Space Weather*, Vol. 15, No. 4, pp. 577–588 (2017).
- [12] Nishizuka, N. et al.: Solar Flare Prediction Model with Three Machine-learning Algorithms using Ultraviolet Brightening and Vector Magnetograms, *The Astrophysical Journal*, Vol. 835, No. 2, Article 156, pp. 1–27 (2017).
- [13] Nishizuka, N., Sugiura, K. et al.: Deep Flare Net (DeFN) Model for Solar Flare Prediction, *The Astrophysical Journal*, Vol. 858, No. 2, Article 113, pp. 1–24 (2018).
- [14] Nishizuka, N. et al.: Reliable Probability Forecast of Solar Flares: Deep Flare Net-Reliable (DeFN-R), *The Astrophysical Journal*, Vol. 899, No. 2, Article 150, pp. 1–24 (2020).
- [15] Park, S., Lim, J., Jeon, Y. and Choi, J. Y.: Influence of Balanced Loss for Imbalanced Visual Classification, *ICCV*, pp. 735–744 (2021).
- [16] Scherrer, P. et al.: The Helioseismic and Magnetic Imager (HMI) Investigation for the Solar Dynamics Observatory (SDO), *Solar Physics*, Vol. 275, No. 1, pp. 207–227 (2012).
- [17] Sun, P., Dai, W. et al.: Solar Flare Forecast Using 3D Convolutional Neural Networks, *The Astrophysical Journal*, Vol. 941, No. 1, Article 1, pp. 1–8 (2022).
- [18] Zhang, S. et al.: A novel solar flare forecast model with deep convolution neural network and one-against-rest approach, *Advances in Space Research*, Vol. 74, No. 7, pp. 3467–3480 (2024).
- [19] Zheng, Y. et al.: Solar Flare Prediction with the Hybrid Deep Convolutional Neural Network, *The Astrophysical Journal*, Vol. 885, No. 1, Article 73, pp. 1–14 (2019).
- [20] 長嶋隼矢, 杉浦孔明: 深層状態空間モデルによる太陽フレア予測: 多波長太陽画像からの表現学習と大規模ベンチマークの構築, 第 28 回画像の認識・理解シンポジウム (2025).