

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

長嶋 隼矢^{1,a)} 杉浦 孔明^{1,b)}

概要

正確かつ信頼性の高い太陽フレア予測は、電波障害や人工衛星の損傷等のインフラ被害緩和に不可欠だが、未だ大きな課題である。既存の手法は、物理特徴量に依存するため、太陽画像からの直接的な表現学習が不足し、フレア発生前の微細な特徴を捉えられない。一方、画像から直接表現学習する手法においては、正確な予測に不可欠な長距離の時空間依存関係を十分にモデル化することに課題がある。本研究では、10 個の波長で観測された太陽画像と長距離の時空間依存関係を初めて扱う、複数の深層状態空間モデルに基づく手法を提案する。また、黒点等の重要領域を保持しつつ空間情報を圧縮する、2 段階マスキングを用いた事前学習手法を導入する。さらに、11 年間の太陽活動周期を網羅する大規模公開ベンチマークを構築した。本研究では、正確性と信頼性に関する 3 つの評価指標において、提案手法がベースライン手法および専門家を越える予測性能を達成することが示された。

1. はじめに

太陽フレアに代表される大規模な太陽活動は、GPS システムなどの電子機器の障害や、電力網への影響など、様々な影響をもたらす [4, 7]。大規模な太陽フレアによる経済的損害は、0.6 兆ドルから 2.6 兆ドルに達すると推定されている [16]。したがって、これらの潜在的リスクを軽減するため、正確で信頼性の高い太陽フレア予測は重要である。

本研究では、24 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多クラス分類問題として定式化する。しかし、この予測タスクは容易ではない。例えば、完璧な予測に対して 1 を返す GMGS (Gandin-Murphy-Gerrity Score) や BSS (Brier Skill Score) において、2010 年から 2015 年にかけて行われた専門家の予測性能は、それぞれ $GMGS = 0.48$, $BSS_{\geq M} = 0.16$ 程度にとどまっていることが報告されている [11, 17]。

既存手法は表現学習や時系列モデリングに課題を抱えている。従来の物理特徴量に基づく手法 [3, 30, 14] では、画像からの表現学習ができないため、フレア発生直前の細かな特徴を捉えることが困難である。一方で、画像から直接表現学習する手法 [21, 1] においては、正確な予測に不可欠な長期の時空間依存関係をモデル化することに課題がある。

したがって、本研究では、(1) 重要領域が疎に存在する太陽画像の時系列から直接表現を学習し、(2) 深層状態空間モデルを拡張して長距離の時空間依存関係を捕捉することにより、既存手法の物理量に基づく限界を回避し、フレア発生前の状態を表す表現の獲得および正確な予測に不可欠な長距離の時空間依存関係の捕捉を実現する。

提案手法における新規性は次の通りである。

- 複数チャンネルからなる多波長太陽画像に対し、各チャンネルに選択的な重み付けを行い、長距離の時空間依存性を捉える Solar Spatial Encoder を提案する。
- 太陽自転周期を超える詳細な時系列特徴および長距離の時系列依存性を正確に捕捉するため、深層状態空間モデルを拡張した Long-range Temporal State Space Model を導入する。
- 黒点などの重要であるが疎な画像領域の表現学習を行うため、疎な画像に特化した Masked Autoencoder による事前学習手法である Sparse MAE を提案する。
- 特定の太陽活動期間に偏った評価を避けるため、太陽フレア予測のための大規模ベンチマークを構築した。

2. 問題設定

本研究では、24 時間以内に発生する最大の太陽フレアのクラスを予測するタスクを扱う。ここで、太陽フレアクラスとは X 線ピーク値による太陽フレアの等級を指す。本タスクの入力は Helioseismic and Magnetic Imager (HMI)[26] および Atmospheric Imaging Assembly (AIA)[13] による 9 波長の画像から構成され、出力は 4 種類の太陽フレアクラスのいずれかに対応する予測確率である。

本研究は、太陽の黒点領域の画像ではなく全体画像を用いた太陽フレア予測に着目している。さらに、本問題を回帰問

¹ 慶應義塾大学

^{a)} ng_sh@keio.jp

^{b)} komei.sugiura@keio.jp




図 1: 提案手法のネットワーク図

題ではなく分類問題として扱う。いずれの選択も、次の 24 時間以内の最大フレアクラスを予測するという太陽フレア予測の標準的な手法に沿ったものである [18, 12, 36, 35]。

3. 提案手法

本研究では、多波長太陽画像を用いて 24 時間以内に発生する最大の太陽フレアクラスを分類するために、深層状態空間モデルを拡張した新たな手法を提案する。図 1 に示す。本手法は、時空間特徴抽出を行う Solar Spatial Encoder (SSE), 長距離の時系列依存関係を捉える Long-range Temporal State Space Model (LT-SSM), および疎な画像に特化した事前学習モデル Sparse MAE の 3 つの主要モジュールから構成される。また、SSE は Depth-wise Channel Selective Module (DCSM) および Spatio-Temporal State Space Model (ST-SSM) を含む。

ここで、本モデルにおける入力 $\mathbf{x} \in \mathbb{R}^{k \times C \times H \times W}$ は、 $\mathbf{x} = (\mathbf{V}_{t-k+1}, \mathbf{V}_{t-k+2}, \dots, \mathbf{V}_t)$ である。ここで、 t, C, k, H , および W はそれぞれ時刻、チャンネル数、履歴長、画像の高さ、および画像の幅を表す。また、 $\mathbf{V}_t \in \mathbb{R}^{C \times H \times W}$ は時刻 t における C チャンネルの画像を表し、各チャンネルは異なる波長に対応している。

3.1 Solar Spatial Encoder

SSE は、入力 $\mathbf{x} \in \mathbb{R}^{k \times C \times H \times W}$ から時空間的特徴を効率的に抽出し、出力は $\mathbf{h}_{\text{sse}} \in \mathbb{R}^{L \times D}$ である。ここで、 L および D はそれぞれ系列の長さの特徴次元を表す。従来の太陽フレア予測手法 [22, 4, 15] は、短い時系列履歴や少数のチャンネルに依拠しているため、十分な時空間情報を活用できず、微細なフレア前兆パターンの検出や複雑な太陽現象のモデル化に限界があった。これに対し、SSE は深層状態空間モデルを拡張し、広範な時空間スケールと多数のチャンネルを計算負荷を抑えつつ用いることが可能である。

SSE は多段階の階層構造を持つ。まず 3 次元畳み込みによるダウンサンプリング層を $\mathbf{x}$ に適用し、空間解像度を低減して $\mathbf{h}_{\text{sse}}^{(0)} \in \mathbb{R}^{D \times C \times H^{(0)} \times W^{(0)}}$ を生成する。その後、 L_{SSE} 段階（すなわち、各段階 l ($1 \leq l \leq L_{\text{SSE}}$) において、以




図 2: (a) 元画像 V_t の例。 (b) 標準偏差が上位 $\alpha\%$ のパッチを強調表示した可視化、多くの場合、太陽黒点領域に対応する。 (c) 空間レベルのマスクングの説明図。 (d) 提案する Sparse MAE によって再構成された画像。

下の処理を順次実行する。

- (1) 3 次元畳み込みにより $\mathbf{h}_{\text{sse}}^{(l-1)}$ の空間解像度をダウンサンプリングし、 $\mathbf{h}_{\text{ds}}^{(l)}$ を得る。
- (2) DCSM により、2 次元および 3 次元畳み込みとチャンネル重み付けを用いて $\mathbf{h}_{\text{ds}}^{(l)}$ における時空間特徴を捕捉し、 $\mathbf{h}_{\text{dcs}}^{(l)}$ を得る。
- (3) ST-SSM が $\mathbf{h}_{\text{dcs}}^{(l)}$ における長距離依存関係を捉え、 $\mathbf{h}_{\text{sse}}^{(l)}$ を出力する。

最終段階の後、 $\mathbf{h}_{\text{sse}}^{(L_{\text{SSE}})}$ は 2 次元畳み込み層を通し、平坦化されることで SSE の出力 $\mathbf{h}_{\text{sse}} \in \mathbb{R}^{L \times D}$ が得られる。

3.2 Depth-wise Channel Selective Module

DCSM では、各チャンネルを独立に処理し、その重要度に応じて選択的に重み付けを行う。多波長太陽画像では、各チャンネルが大気各層で発生する異なる物理過程を表す。全チャンネルを均等に扱うと、フレア発生に関する重要な手がかりを捉えきれず、予測性能が低下する恐れがある。

この問題に対処するため、DCSM はまず並列に実行される 2 次元および 3 次元畳み込みにより時空間の特徴を抽出し、その特徴を用いて各チャンネルごとに重み付けを行い、より情報量の多いチャンネルを強調する。

3.3 Spatio-Temporal State Space Model

ST-SSM は、多チャンネルかつ長期の時系列太陽画像における時空間の長距離依存関係を捉えるため、深層状態空間モデルを拡張する。具体的には、時間不変かつ multi-input, multi-output 構造を有する S5[29] を採用しており、多チャンネルで入力が多波長の連続信号とみなせる太陽画像の効率

表 1: 定量的結果.

手法	テスト期間	GMGS↑	BSS _{≥M} ↑	TSS _{≥M} ↑
Flare Transformer [10] (w/o PF)	2014-2017 (4 years)	0.220 ± 0.116	-1.770 ± 0.225	0.198 ± 0.371
DeFN-R [20]	2014-2015 (2 years)	0.302 ± 0.055	0.036 ± 0.982	0.279 ± 0.162
CNN-LSTM	2019-12-01 - 2022-11-30 (3 years)	0.315 ± 0.166	0.272 ± 0.259	0.330 ± 0.306
DeFN [19]	2014-2015 (2 years)	0.375 ± 0.141	0.022 ± 0.782	0.413 ± 0.150
Flare Transformer [10] (full)	2014-2017 (4 years)	0.503 ± 0.059	0.082 ± 0.974	0.530 ± 0.112
Ours	2019-12-01 - 2022-11-30 (3 years)	0.582 ± 0.032	0.334 ± 0.299	0.543 ± 0.074
Human Experts [11, 17]	2000-2015 (16 years)	0.48	0.16	0.50

的なモデル化に適している。

ST-SSM は, DCSM の出力 $\mathbf{h}_{\text{dcs}}^{(l)} \in \mathbb{R}^{D \times C^{(l)} \times H^{(l)} \times W^{(l)}}$ を入力とし, $\mathbf{h}_{\text{st}}^{(l)} \in \mathbb{R}^{D \times C^{(l)} \times H^{(l)} \times W^{(l)}}$ を出力する。

さらに, Transformer の feed-forward network に類似した機構を提供するため, SSM ブロック (SSMBlock($\cdot$)) を導入する。入力 $\mathbf{z}$ に対して, SSM ブロックは次式により計算される。

$$\mathbf{z}' = \text{SSM}(\text{LN}(\mathbf{z})) + \mathbf{z}, \quad (1)$$

$$\text{SSMBlock}(\mathbf{z}) = \text{MLP}(\text{LN}(\mathbf{z}')) + \mathbf{z}', \quad (2)$$

ここで, LN および MLP は, それぞれレイヤー正規化および多層パーセプトロンを示す。

次に, $\mathbf{h}_{\text{dcs}}^{(l)}$ を入力として, ST-SSM はまず空間およびチャネル次元を平坦化し転置することで, $\tilde{\mathbf{h}}_{\text{st}}^{(l)} \in \mathbb{R}^{(C^{(l)} \cdot H^{(l)} \cdot W^{(l)}) \times D}$ を得る。その後, SSM ブロックを $\tilde{\mathbf{h}}_{\text{st}}^{(l)}$ に適用して $\hat{\mathbf{h}}_{\text{st}}^{(l)}$ を得る。最後に, $\hat{\mathbf{h}}_{\text{st}}^{(l)}$ を転置および次元を整えることで, $\mathbf{h}_{\text{st}}^{(l)} \in \mathbb{R}^{D \times C^{(l)} \times H^{(l)} \times W^{(l)}}$ が得られる。

3.4 Sparse MAE

本手法では, 重要な情報領域が疎である画像における特徴を捉え, 重要な特徴を圧縮するための事前学習手法として Sparse MAE を提案する。Sparse MAE は従来の MAE[9] を拡張し, 太陽画像特有の特性を考慮したモジュールである。MAE はビデオの表現学習など多くの領域で成功を収めている [25, 6, 33, 34, 5, 32, 23] が, 空間情報を圧縮する過程で, 太陽画像に直接適用すると固有の課題が生じる。例えば, 太陽フレア予測において重要な黒点領域などが完全にマスクされてしまうと, 周辺情報のみからこれらの領域を再構成することが困難になる。

Sparse MAE はこの課題に対処するため, 事前学習時に二段階のマスクング戦略を採用する。

この事前学習において, 入力 $\mathbf{x}_{\text{pre}} \in \mathbb{R}^{m \times C \times H \times W}$ は $\mathbf{x}_{\text{pre}} = (\mathbf{V}_{t-m+1}, \mathbf{V}_{t-m+2}, \dots, \mathbf{V}_t)$ と定義され, m ($> k$) は事前学習で用いられるより長い履歴長を示す。 $t-m+1$ から t までの各時刻に対して, 事前学習モデルは $\mathbf{x}_{\text{pre}}$ 内の各 $\mathbf{V}_t$ を独立に処理する。

空間マスクングでは, 図. 2(a) および (b) に示すように,

標準偏差が高いパッチ (上位 $\alpha\%$) を抽出し, これらが黒点領域に対応するため, 低いマスクング比率 r_l でマスクし, 残りは高い比率 r_h ($r_h > r_l$) でマスクする。

特徴マスクングでは, 空間マスクング後の特徴に対して比率 r_f で追加のマスクングを行う。これにより, 黒点領域が完全にマスクされた場合でも再構成することが可能となり, 重要情報の再構成精度が向上する。

各時刻についてこの手順を適用し, LT-SSM で用いられる中間特徴の系列 $\mathbf{h}_{\text{pre}} = (\mathbf{h}_{t-m+1}, \dots, \mathbf{h}_{t-1}, \mathbf{h}_t)$ を得る。 $\mathbf{h}_t$ は t の情報を埋め込んだ D_{pre} 次元の特徴量である。

3.5 Long-Range Temporal State Space Model

LT-SSM は, 太陽画像に対して事前学習で得られた中間特徴における, 太陽自転周期にまたがる長距離の時間依存性を正確に捉える。本モデルは深層状態空間モデルを拡張することで, これらの時間方向の長距離依存関係を効率的にモデル化し, 中間特徴 $\mathbf{h}_{\text{pre}}$ から $\mathbf{h}_{\text{lt}} \in \mathbb{R}^{L \times D}$ を得る。

LT-SSM は, L_{LT} 個の SSM ブロックから構成される。各段階 l ($1 \leq l \leq L_{\text{LT}}$) の SSM ブロックは $\mathbf{h}_{\text{lt}}^{(l)}$ を出力する。最初の SSM ブロックは $\mathbf{h}_{\text{pre}}$ に対して SSMBlock を適用して出力を得て, それ以降は各ブロックが直前のブロックの出力に SSMBlock を適用する。最後に, 出力 $\mathbf{h}_{\text{lt}}^{(L_{\text{LT}})}$ は 1 次元畳み込み層によりチャネル次元が調整され, 最終出力 $\mathbf{h}_{\text{lt}}$ が生成される。

SSE および LT-SSM の出力である $\mathbf{h}_{\text{sse}}$ と $\mathbf{h}_{\text{lt}}$ は系列方向に沿って統合され, これにより入力 $\mathbf{x}$ に対応する太陽フレアクラスの予測確率 $p(\hat{\mathbf{y}})$ が以下の式で得られる:

$$p(\hat{\mathbf{y}}) = \text{FFN}(\text{SSMBlock}([\mathbf{h}_{\text{sse}}; \mathbf{h}_{\text{lt}}])), \quad (3)$$

ここで, FFN は feed-forward network を示す。

損失関数においては, 交差エントロピー損失に加え, [10] で提案された GMGS および BSS 損失を用いた。

4. 実験

4.1 FlareBench

太陽フレア予測のための標準的なデータセット [18, 2] は, 多様な太陽活動状態を網羅していない。その結果, そのようなデータセットで学習されたモデルは, 特定の期間




図 3: 提案手法の成功例.

の太陽活動に対してバイアスを示す可能性がある．さらに，多くのデータセットには，小さく低解像度の太陽黒点パッチしか含まれていない．これらの制限に対処するため，我々は太陽フレア予測のための新しいベンチマークである FlareBench を提案する．FlareBench は，11 年間の太陽活動サイクル全体をカバーしており，多様な太陽活動状態下でのモデル評価を可能にする．FlareBench は，太陽フレア予測における標準的なアプローチ [18, 12, 36] である，次の 24 時間以内の最大フレアクラスの予測に焦点を当てている．さらに，時系列交差検証をモデル評価に使用し，結果が特定の期間に偏らないようにしている．また，FlareBench で HMI と AIA を使用する理由は，HMI による光球磁場の観測と AIA による多層コロナ大気の観測データを同時に使用することが，効果的な太陽フレア予測に不可欠であるためである．

4.2 定量的結果

提案手法とベースライン手法の定量的結果を，表 1 に示す．各指標の値は，時系列交差検証を用いて求めた平均と標準偏差を表す．また，Kubo ら [11] によって報告された，2000 年から 2015 年までの日々の予報業務における人間の専門家の性能も表 1 に示す．表 1 より，提案手法は GMGS, $BSS_{\geq M}$, $TSS_{\geq M}$ でそれぞれ 0.582, 0.334, 0.543 を達成した．提案手法はベースラインの中で最も高いスコアを示した Flare Transformer [10] と比較し，GMGS で 0.079, $BSS_{\geq M}$ で 0.252, $TSS_{\geq M}$ で 0.013 ポイント上回る性能を示した．提案手法は CNN-LSTM と比較して GMGS において統計的に有意な差を示した ($p < 0.05$)．ただし，テスト期間が異なるため，他のベースラインとの直接的な統計的比較はできなかった．特筆すべきは，人間の専門家の性能をも GMGS で 0.102, $BSS_{\geq M}$ で 0.174, $TSS_{\geq M}$ で 0.043 上回ったことである．

4.3 定性的結果

図 3 は，提案手法による X クラスフレア予測の成功例を

表 2: Ablation study: モジュールにおける影響.

モデル (D) (S) (L)	GMGS $\uparrow$	$BSS_{\geq M}\uparrow$	$TSS_{\geq M}\uparrow$
(i) ✓ ✓	0.330 ± 0.029	-0.084 ± 0.487	0.381 ± 0.018
(ii) ✓ ✓	0.342 ± 0.180	0.320 ± 0.052	0.438 ± 0.165
(iii) ✓ ✓	0.371 ± 0.094	0.392 ± 0.053	0.413 ± 0.060
(iv) ✓ ✓	0.494 ± 0.129	0.232 ± 0.630	0.462 ± 0.175
(v) ✓ ✓ ✓	0.582 ± 0.032	0.334 ± 0.299	0.543 ± 0.074

示す．図中では， $t-k$ から t までの時刻における 131 Å, 193 Å, 304 Å の極端紫外線画像，正解ラベル，ベースラインの CNN-LSTM と提案手法による予測を示している．(a) と (b) は成功した X クラス予測の例を示す．

4.4 Ablation Studies

表 2 は，LT-SSM, DCSM, および ST-SSM という主要な 3 モジュールが性能に与える影響を示している．本研究では，(i) LT-SSM を除外，(ii) DCSM を除外，(iii) ST-SSM を除外，(iv) SSE 全体 (DCSM と ST-SSM の両方) を除外，(v) すべてのモジュールを組み込んだ完全なモデルの 5 種類の構成を比較した．なお，(D), (S), (L) はそれぞれ DCSM, ST-SSM, LT-SSM を表す．

GMGS に関しては，モデル (i), (ii), (iii), (iv) は，完全なモデル (v) に比べそれぞれ 0.252, 0.240, 0.211, 0.088 ポイント低い性能を示した．これらの結果は，各モジュールが全体の性能向上に寄与しており，特に LT-SSM が最も大きな影響を及ぼすことを示唆している．

一方， $BSS_{\geq M}$ のみを最大化することは，太陽フレアクラス分布のクラス不均衡 (O および C クラスが多数を占める) により誤解を招く可能性がある．主要クラスを中心に予測するだけで高い $BSS_{\geq M}$ が得られても，重要でありながら発生頻度の低い M および X クラスに対する性能が低下する恐れがある．したがって，GMGS と $BSS_{\geq M}$ の両者を改善し，頻出クラスと希少な高影響イベントの双方において優れた性能を実現するバランスが重要である．

5. おわりに

本研究では，深層状態空間モデルを拡張し，多波長太陽画像における長距離の時空間依存関係と疎な重要領域の特徴を捉える手法を導入した．また，太陽活動周期の全 11 年を網羅する大規模ベンチマークを構築し，短期間データセットに起因する評価の偏りを軽減した．さらに，本手法は GMGS, $BSS_{\geq M}$, および $TSS_{\geq M}$ において専門家を上回る性能を初めて達成した．展望としては，圧縮を伴わない全解像度の太陽画像を導入し，より微細な空間情報を活用することでさらなる性能向上を図る予定である．

謝辞

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

参考文献

- [1] Abed, A. K., Qahwaji, R. et al.: The automated prediction of solar flares from SDO images using deep learning, *Advances in Space Research*, Vol. 67, No. 8, pp. 2544–2557 (2021).
- [2] Angryk, R. A., Martens, P. C., Aydin, B., Kempton, D. et al.: Multivariate time series dataset for space weather data analytics, *Scientific Data*, Vol. 7, No. 1, p. 227 (2020).
- [3] Barnes, G., Leka, K. D., Schrijver, C. J. et al.: A COMPARISON OF FLARE FORECASTING METHODS. I. RESULTS FROM THE “ALL-CLEAR” WORKSHOP, *The Astrophysical Journal*, Vol. 829, No. 2, p. 89 (2016).
- [4] 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, p. 98 (2020).
- [5] Chen, H., Wang, J., Shao, K., Liu, F., Hao, J., Guan, C. et al.: Traj-MAE: Masked Autoencoders for Trajectory Prediction, *ICCV*, pp. 8351–8362 (2023).
- [6] Cheng, J., Mei, X. et al.: Forecast-MAE: Self-supervised Pre-training for Motion Forecasting with Masked Autoencoders, *ICCV*, pp. 8679–8689 (2023).
- [7] 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).
- [8] Gu, A. and Dao, T.: Mamba: Linear-Time Sequence Modeling with Selective State Spaces, *COLM* (2024).
- [9] He, K., Chen, X., Xie, S., Li, Y., Dollár, P. et al.: Masked Autoencoders Are Scalable Vision Learners, *CVPR*, pp. 15979–15988 (2022).
- [10] Kaneda, K. et al.: Flare Transformer: Solar Flare Prediction using Magnetograms and Sunspot Physical Features, *ACCV*, pp. 1488–1503 (2022).
- [11] Kubo, Y. et al.: Verification of operational solar flare forecast: Case of Regional Warning Center Japan, *Journal of Space Weather and Space Climate*, Vol. 7, p. A20 (2017).
- [12] 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, p. 101 (2019).
- [13] 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).
- [14] Li, X. et al.: Prediction of Large Solar Flares Based on SHARP and High-energy-density Magnetic Field Parameters, *The Astrophysical Journal Supplement Series*, Vol. 276, No. 1, p. 7 (2024).
- [15] Li, X., Zheng, Y., Wang, X. et al.: Predicting Solar Flares Using a Novel Deep Convolutional Neural Network, *The Astrophysical Journal*, Vol. 891, No. 1, p. 10 (2020).
- [16] Maynard, T., Smith, N. and Gonzalez, S.: Solar storm risk to the North American electric grid, Technical report, Lloyd’s (2013).
- [17] Murray, S. A., Bingham, S., Sharpe, M. and Jackson, D. R.: Flare forecasting at the Met Office Space Weather Operations Centre, *Space Weather*, Vol. 15, No. 4, pp. 577–588 (2017).
- [18] 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, p. 156 (2017).
- [19] Nishizuka, N., Sugiura, K., Kubo, Y., Den, M. and Ishii, M.: Deep Flare Net (DeFN) Model for Solar Flare Prediction, *The Astrophysical Journal*, Vol. 858, No. 2, p. 113 (2018).
- [20] Nishizuka, N., Kubo, Y. et al.: Reliable Probability Forecast of Solar Flares: Deep Flare Net-Reliable (DeFN-R), *The Astrophysical Journal*, Vol. 899, No. 2, p. 150 (2020).
- [21] Pandey, C. et al.: Solar Flare Forecasting with Deep Neural Networks using Compressed Full-disk HMI Magnetograms, *IEEE Big Data*, pp. 1725–1730 (2021).
- [22] Park, E. et al.: Application of the Deep Convolutional Neural Network to the Forecast of Solar Flare Occurrence Using Full-disk Solar Magnetograms, *The Astrophysical Journal*, Vol. 869, No. 2, p. 91 (2018).
- [23] Pei, G., Chen, T., Jiang, X., Liu, H., Sun, Z. et al.: VideoMAC: Video Masked Autoencoders Meet ConvNets, *CVPR*, pp. 22733–22743 (2024).
- [24] Pesnell, W. D., Thompson, B. J. and Chamberlin, P. C.: *The Solar Dynamics Observatory (SDO)*, pp. 3–15 (2012).
- [25] Reed, C. J., Gupta, R. et al.: Scale-MAE: A Scale-Aware Masked Autoencoder for Multiscale Geospatial Representation Learning, *ICCV*, pp. 4088–4099 (2023).
- [26] Scherrer, P., Schou, J. 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).
- [27] Schou, J. et al.: Design and Ground Calibration of the Helioseismic and Magnetic Imager (HMI) Instrument on the Solar Dynamics Observatory (SDO), *Solar Physics*, Vol. 275, No. 1, pp. 229–259 (2012).
- [28] Shibata, K. and Magara, T.: Solar Flares: Magnetohydrodynamic Processes, *Living Reviews in Solar Physics*, Vol. 8, No. 1, p. 6 (2011).

- [29] Smith, J. et al.: Simplified State Space Layers for Sequence Modeling, *The Eleventh International Conference on Learning Representations* (2023).
- [30] Toriumi, S. and Wang, H.: Flare-productive active regions, *Living Reviews in Solar Physics*, Vol. 16, No. 1 (2019).
- [31] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L. u. et al.: Attention is All you Need, *NeurIPS* (Guyon, I., Luxburg, U. V., Bengio, S., Wallach, H., Fergus, R., Vishwanathan, S. and Garnett, R., eds.), Vol. 30 (2017).
- [32] Wang, L., Huang, B., Zhao, Z., Tong, Z. et al.: Video-MAE V2: Scaling Video Masked Autoencoders with Dual Masking, *CVPR*, pp. 14549–14560 (2023).
- [33] Yang, H., He, T., Liu, J., Chen, H. et al.: GD-MAE: Generative Decoder for MAE Pre-Training on LiDAR Point Clouds, *CVPR*, pp. 9403–9414 (2023).
- [34] Yin, K. et al.: SCE-MAE: Selective Correspondence Enhancement with Masked Autoencoder for Self-Supervised Landmark Estimation, *CVPR*, pp. 1313–1322 (2024).
- [35] 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).
- [36] Zheng, Y., Li, X. and Wang, X.: Solar Flare Prediction with the Hybrid Deep Convolutional Neural Network, *The Astrophysical Journal*, Vol. 885, No. 1, p. 73 (2019).