

河合敏輝 (Toshiki Kawai) 今田晋亮 (Shinsuke Imada) ISEE, Nagoya University

Deep Learning

大量のデータから特徴を抽出し、 分類問題・回帰問題などを解く

ニューラルネットワーク(NN)の層を 重ねることで実現

通常のNNの他に、画像処理に特化 した「畳み込みNN」や、 時系列データ向けの 「リカレントNN」などがある



Liu et al. 2015



https://becominghuman.ai/deep-learning-made-easy-with-deep-cognition-403fbe445351

Application example of Deep Learning 1

<u>フレアの発生予測</u>フレア発生前の太陽の状態&フレアの発生有無・規模



Authors	使用観測データ	TSS (24h)
Muranushi et al. 2015	半球磁場 (map) +X-ray (total)	0.75 ± 0.07 (X-class)
Huang et al. 2018	活動領域磁場(map)	0.714 (X-class)
Nishizuka et al. 2018	活動領域磁場 +極端紫外線 (map)	0.80 (≥M-class)





<u>衛星に搭載された分光器の温度によるずれを補正</u>

Kamio et al. 2010

分光器の温度&スペクトルのずれ



ひので衛星に搭載された極端紫外線撮像分光器 (EIS)における、 最大70 km/sのDoppler速度のずれをRMS4.4 km/sに抑えることに成功

Abstract of this study

深層学習を「コロナ加熱問題」に応用







Radiative Intensityの変化(衛星の観測結果)から Flare Energyを算出するよう Deep Neural Network (DNN)に学習させる.

Introduction - Coronal Heating Problem



Introduction - Coronal Heating Models

Wave Heating







発生したフレアを余すことなく検出し、 それぞれのエネルギーを正確に求める必要がある



frequency [/erg/day/active-region]

10-18 Uemura 2018 $F_{in} = 5.6 \times 10^4 < 1 \times 10^7 \,[erg/cm^2/s^2]$ 10-20 $\alpha > 2$ 10-22 $\alpha > 2$ が ~10²³ [erg]まで保持される 場合、活動領域を加熱するのに十分な 10-24 Energy fluxが存在する。 10-26 検出とエネルギー導出が 10-30 正確にできていない可能性。 10²⁶ 1025 1029 1028 1030 1027 10^{2} mermal energy lerg

フレアのエネルギーごとの発生頻度分布は冪乗則に従う。 α > 2を満たす場合、より小さなフレアによる加熱が支配的となる。 (Shimizu 1995)

 $dN/dE = E^{-\alpha} \times \text{Const.}$

Previous Research – Nano-flare Heating Model



フレアのコロナ加熱への寄与を測定するために、 フレアの検出とエネルギー導出を正確に行う 手法を開発すること。



1. コロナループを模した流体シミュレーション

2. シミュレーションで作成したDatasetを用いてDNNを学習

3. 既存の手法と学習させたDNNの精度を比較

Method – Simulation Setting



Simulation result



がループの足元に伝わる **4.** 彩層が加熱され、密度の高いプラズマがループ頂 上へと向かって注入される

Method – Pseudo-observation



Method – Existing Method



Method – New Method



Method - Comparison

Assumptions

Existing method (no deep learning) Proposed method (based on deep learning)

1. コロナループがナノフレアによって 5MKに加熱される

560 sample learning (Simulation condition)

2. フレアのエネルギーはループの熱エ ネルギーの変化量に等しい



Result & Discussion – Comparison



Summary

Purpose

フレアのコロナ加熱への寄与を測定するために、フレアの検出と エネルギー導出を正確に行う手法を開発すること。

Method

コロナループを模した一次元流体シミュレーションの疑似観測と 深層学習を用いた手法を提案し、シミュレーションにおいて既存の 手法との精度の比較を行った。

Result

既存の手法ではフレアのエネルギーが10²⁵ erg程度より小さくなると エネルギー導出を正しく行うことができなくなった。

一方で、提案した手法ではそのような微小なフレアでも比較的正確に エネルギーを導出することができた。

Future work

実際の観測に提案した手法を適用するため、様々な 条件でのシミュレーションを用いてDatasetを作成する。



The corona is heated by smaller flares dominantly.



Simulation (CANS)

cross section = 3 [Mm^2] loop length = 60 [Mm] flare duration = 120 [s] Spectrum (CHIANTI)

temperature range : 0.3 – 30 [MK] wavelength range : 6 – 60 [A]

flare equations: $H_{\rm f} = H_{\rm f0} \cdot q(t) \cdot f(x)$

$$q(t) = \frac{1}{4} \left\{ 1 + \tanh \frac{t}{0.1\tau_0} \right\} \left\{ 1 - \tanh \left(\frac{t - \tau_{\rm f}}{0.1\tau_0} \right) \right\}$$
$$f(x) = \frac{1}{\sqrt{2\pi}} \exp \left[-\frac{(x - L)^2}{2w_{\rm f}^2} \right] \cdot \frac{1}{2} \left\{ 1 + \tanh \left(\frac{x - 20\mathcal{H}_0}{3\mathcal{H}_0} \right) \right\}$$

Derivation of thermal energy



Neural Network



Optimizer - Adam

$$m_{t+1} = \beta_1 m_t + (1 - \beta_1) \nabla E(\mathbf{w}^t)$$
$$v_{t+1} = \beta_2 v_t + (1 - \beta_2) \nabla E(\mathbf{w}^t)^2$$
$$\hat{m} = \frac{m_{t+1}}{1 - \beta_1^t}$$
$$\hat{v} = \frac{v_{t+1}}{1 - \beta_2^t}$$
$$\mathbf{w}^{t+1} = \mathbf{w}^t - \alpha \frac{\hat{m}}{\sqrt{\hat{v}} + \epsilon}$$

acceleration of learning by inertia term

improve precision by decaying of learning rate

$$(\alpha = 0.01, \beta_1 = 0.9, \beta_2 = 0.999)$$
 Kingma et al., 2015

Output of DNN



Detection (single flare)



True Skill Score

Huang et al. 2018

 Table 3

 Contingency Table for Binary Solar Flare Forecasting

	Forecasting Flaring	Forecasting Nonflaring
Observed Flaring	True Positive (TP)	False Negative (FN)
Observed Nonflaring	False Positive (FP)	True Negative (TN)

TP rate = TP / (TP + FN)

```
FP rate = FP / (FP + TN)
```

```
TSS=TP rate - FP rate
```