

深層学習による宇宙天気予報の ための太陽フレア予測

西塚直人

情報通信研究機構
電磁波研究所宇宙環境研究室

Facebook, Twitterで宇宙天気の
日報・臨時情報・ニュース配信してます。



内容

1. 太陽フレア予測モデル開発と社会の反応
2. 国際的な宇宙天気予報
3. 太陽フレアの予測と機械学習入門
4. 太陽フレア予測へのAI技術応用
5. 太陽フレア予測へのAI技術応用2
～**深層学習**を用いた改良～
6. まとめ




1. 太陽フレア予測モデル開発と 社会の反応

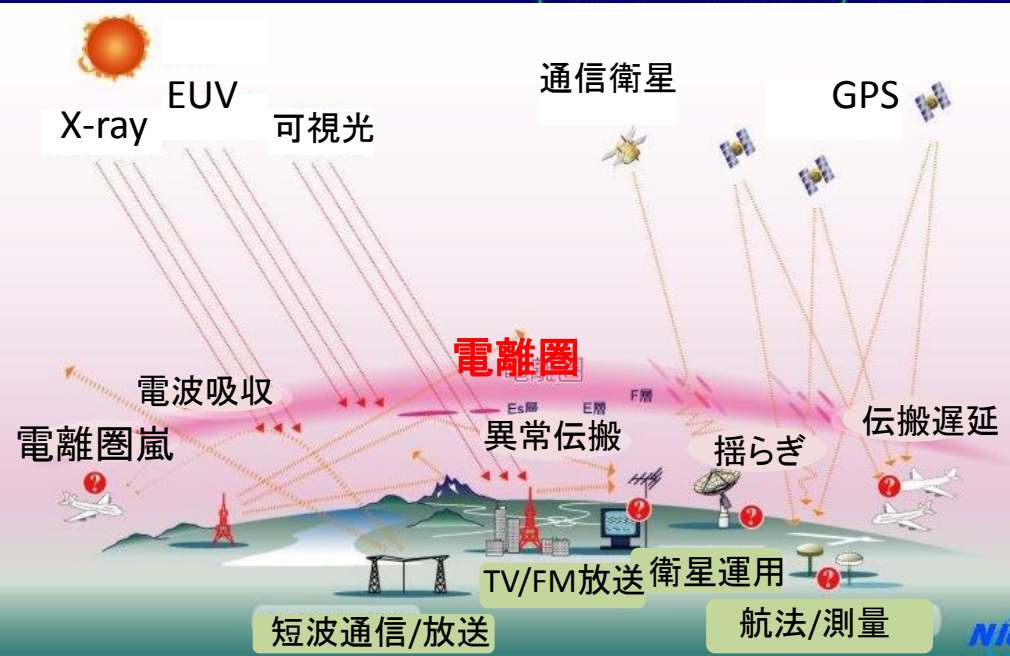
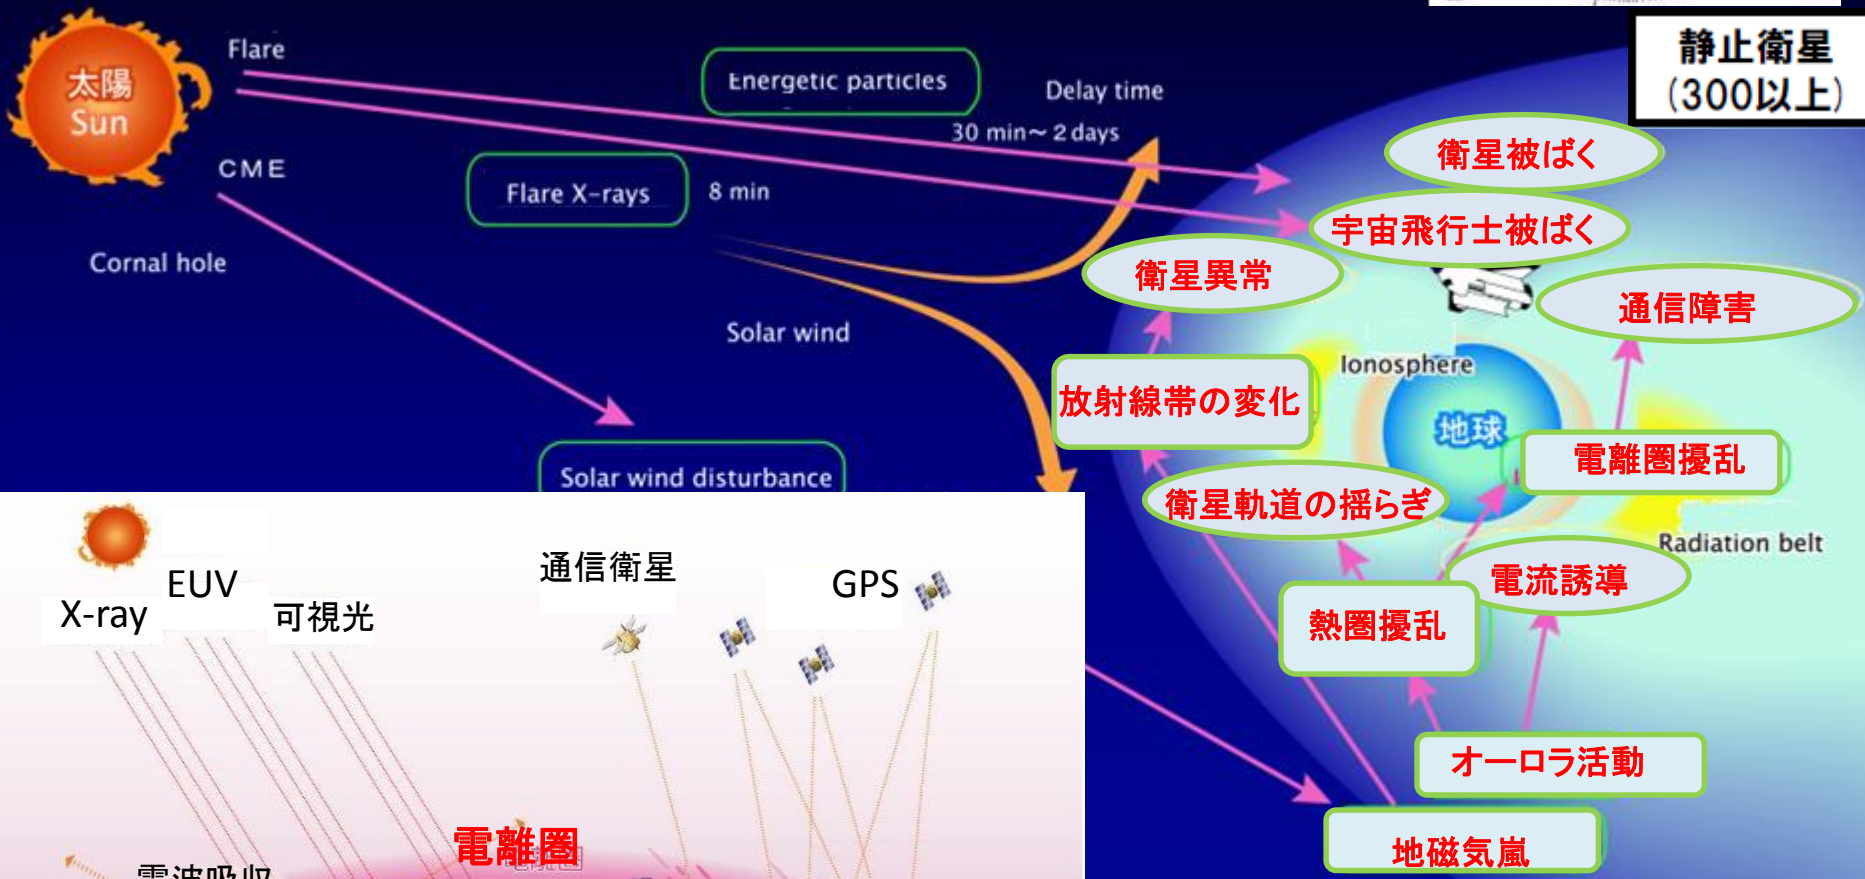


宇宙天気ターゲット

宇宙環境に起因する衛星障害




静止衛星
(300以上)



電離層(電離圏)の電波伝搬障害






X9.3フレア

SDO/AIA (NASA)

SDO/AIA 94 2011-09-10 10:02:28 UT
1回目のフレアは11年ぶりの大きさ



SDO/AIA 94 2017-09-09 22:00:48 UT

SDO/AIA (NASA)

2回目の大規模フレアが4日後に発生

フレアに伴い、高温プラズマの大量放出

なんでも
『太陽フレアのせい』

太陽
↓




高エネルギー
粒子

CME
(コロナ質量放出)


■ AI技術を用いた太陽フレア予測モデル開発

(Nishizuka et al. 2017, 2018 ApJ)


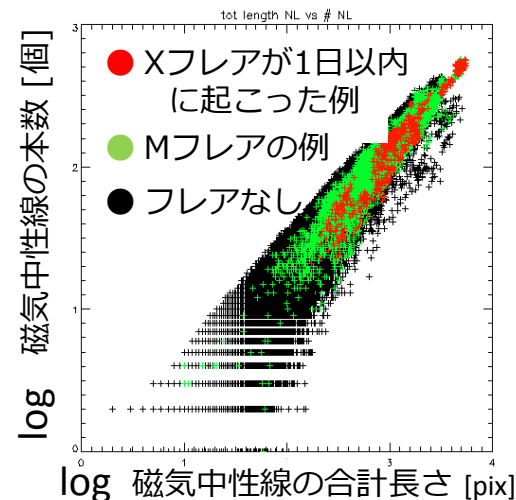


Yohkoh, 軟X線


1日の衛星データ：1.5TB以上
→人の処理能力を越えた膨大なデータ




単純な黒点:穏やか 複雑な黒点:フレア起きる!
・・・のような判断を、AIにさせる。



磁場画像



ベクトル磁場



磁気中性線

機械学習

従来: TSS=0.5



A.I. TSS=0.80 ($\geq M$)

(TSS=1 で100%的中)

学習データ：過去6年分の
30万枚の太陽画像
(4k×4k)。黒点領域を自動検出し、特徴量を抽出。

- ・ 現在、深層学習(Deep Learning)モデルを開発、論文投稿・特許申請中。
- ・ **Deep Flare Net (DeFN, ↑)**のリアルタイム運用化、8月頃予定。

[プレスリリース] 宇宙天気予報の精度を上げる技術の開発！(2017年1月26日)

▶ プレスリリース

ツイート いいね! 2

宇宙天気予報の精度を上げる技術の開発

～機械学習とビッグデータで、太陽フレアの発生予測を8割へアップ～

2017年1月26日

国立研究開発法人情報通信研究機構

ポイント

- 機械学習とビッグデータを用いた手法が、太陽フレアの予測にも有効であることを実証
- いまだに解明されていない太陽フレアの発生メカニズムを解明する鍵が得られた
- 従来よりも早い予報が可能になり、宇宙天気の影響による災害の早期対策へ貢献

NICTは、電磁波研究所及び先進的音声翻訳研究開発推進センターにおいて、機械学習とビッグデータを用いた予測モデル開発により、宇宙天気予報の精度を格段に上げることに成功しました。


NICTでは宇宙天気予報を毎日配信していますが、予報精度の向上が長年の課題でした。今回、複数の機械学習の手法を太陽観測データ解析に応用することで、大量の情報処理による統計的な太陽フレアの予測を可能にしました。その結果、従来の人の手による5割程度の手法に比べると、8割を超える世界トップクラスの精度まで予測精度を上げることができました。また、太陽フレア発生前に現れる特徴を、統合的に機械学習によるデータ分析から明らかにしました。そのことにより、太陽フレアの謎を解く鍵が得られたとともに、従来の一昨日の予報からリアルタイム予報への道が拓け、宇宙天気の影響による災害に対して、より早期の対策準備ができるように実用化を進めます。

この成果は、米国の専門誌「*The Astrophysical Journal*」に、1月25日(水)(日本時間1月26日(木)午前2時)に掲載されます。なお、本研究の一部は、JSPS科研費(JP15K17620)の助成により実施されました。



図1: 宇宙天気予報Webサイト >
<http://swc.nict.go.jp/contents/index.php>

西塚ら *Astrophysical Journal* 2017 論文掲載



2. 国際的な宇宙天気予報

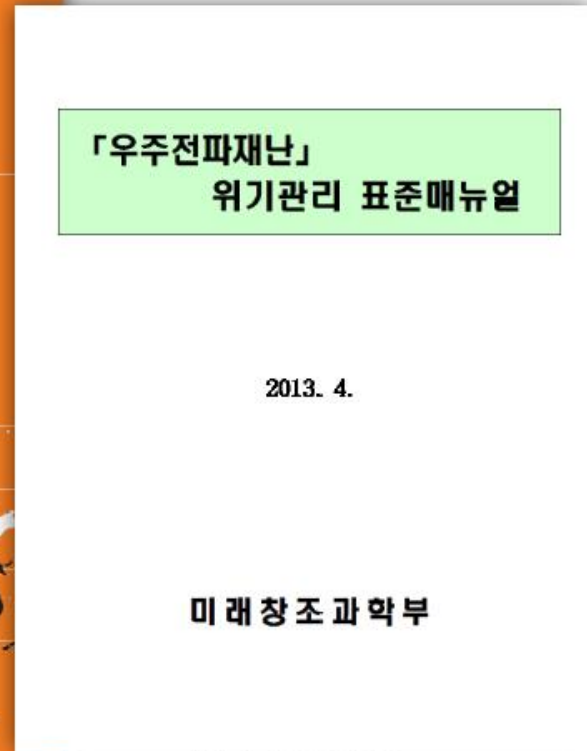
■ 各国の宇宙天気の影響の経済インパクト見積



極端宇宙天気:工学システムやインフラへの影響 (英国・王立工学アカデミー)



宇宙天気 その地球及びビジネスへの影響 (ロイズ)




「宇宙電波障害」
危機管理標準マニュアル
(韓国・未来創造科学部)⁶

日本はGDPに対して世界で1番、宇宙天気に弱い国という試算もある。


■ 宇宙天気情報の航空機運用への利用義務化

- ・ **国際民間航空機関 (ICAO)** にて、火山や気象情報と同じく宇宙天気情報も航空運用に使うよう、ルール改訂が進められている。
- ・ 1機の航路変更で200万円の損失。
- ・ 既に英米では、民間・行政で使われている。
- ・ **2020年代**には義務化の見込み。
- ・ **ICAO宇宙天気センター** 選出プロセスが進行中。



HF通信障害(デリンジャー現象)

↑太陽X線



HF通信障害(極冠吸収)

↑太陽高エネルギー粒子

2012年1月23日 アメリカ民間 航空機が飛行ルート変更

Delta diverts polar flights due to solar storm | Reuters - Mobile First

REUTERS

WestlawNext

"IT MEANS VE PRODUCT AT"

Delta diverts polar flights due to solar storm

2012年1月23日

Delta Air Lines jet takes off (and a Northwest Airline jets parked) at gates at the Minneapolis St Paul International Airport in Minneapolis, Minnesota October 30, 2008. Credit: Reuters/Chris Wedel

(Reuters) - Delta Air Lines was diverting some flights on polar routes between Detroit and Asia to avoid disruptions to aircraft communications by a strong solar radiation storm, the airline said on Tuesday.

The storm, considered the strongest since 2005, has caused minor disruptions for U.S. airlines, and Delta said it altered routes for "a handful"

2011 was ninth-warmest year since 1880 - NASA
The, Jan 19 2012

US airlines seen profitable despite economic woes
Wed, Jan 19 2012

US airlines boost domestic long-haul fares
Fri, Jan 13 2012

Related News

Sun hurls strong geomagnetic storm toward Earth
Mon, Jan 23 2012

2011 was ninth-warmest year since 1880 - NASA
The, Jan 19 2012

US airlines seen profitable despite economic woes
Wed, Jan 19 2012

US airlines boost domestic long-haul fares
Fri, Jan 13 2012

WestlawNext

THE EVIDENCE IS MOUNTING.

MORE REUTERS RESULTS FOR:

airline polar route

lot aims for record-breaking polar flight

Glass build-up found in NATO F-16 engine - US

Build-up found in NATO F-16 engine: US official

going green to shrink fuel costs

Reuters

Twitter RSS YouTube

Login or register

Latest from My Blog

2015年11月にスウェーデンで 太陽嵐のために1時間以上航 空運用ストップ

CBCnews | Technology & Science

Home World Canada Politics Business Health Arts & Entertainment Technology & Science

Technology & Science Quirks & Quarks Blog Spark Photo Galleries

Solar storm knocks out flight control systems in Sweden, grounds planes

Flights disappeared from radar screens

The Associated Press Posted: Nov 04, 2015 3:38 PM ET | Last Updated: Nov 04, 2015 3:40 PM ET

2177 shares

Facebook

Twitter

Reddit

Google

Share

Email

Aviation officials say a solar storm knocked out the air traffic control systems in Sweden on Wednesday, prompting them to close the country's airspace for more than an hour.

The civil aviation authority said the solar storm created disturbances in the Earth's magnetic field, which affected radar installations in southern Sweden, which were reported in neighbouring countries.

Agency spokesman Per Froberg said flights disappeared from radar screens in Swedish air traffic control towers during the blackout, which lasted about an hour until 5:30 p.m. local time (11:30 a.m. ET). Froberg said it was unclear why the impact was so severe, adding the last time something similar happened in Sweden was in 1999.

"We're working on sorting out the delays. We can't examine the cause right now. We have our hands full," he said.

He couldn't say how many flights were affected, but the country's main airports listed dozens of delays.

Parked aircraft are seen at Stockholm Arlanda Airport in a photo from March 2015. Swedish airspace was closed for an hour Wednesday after a solar storm knocked out air traffic control systems. (Johan Nilsson/Associated Press)

Stay Conn

Mobile Face

Top News

■ 国際宇宙環境サービス (ISES)



国際協力によって宇宙天気予報を推進。
現在、18カ国が加盟。

(⇒) NICTウェブページ

http://swc.nict.go.jp/forecast/isesforecast_e.html

フレア、地磁気、プロトンの予報情報を共有

- Quiet : B-class以下, ■ Eruptive: 最大C-class
- Active: M-class, ■ Major Flare Expected: X-class

[Present Space Weather Forecast from ISES]

Tokyo [Japan] (0600UT)	Flare forecast on :20(1days)	Quiet
	Magnetic forecast on :20(/days)	Quiet
	Proton forecast on :20(/days)	Quiet
Beijing [China] (0630UT)	Flare forecast on :20(2days)	Quiet
	Magnetic forecast on :20(2days)	Quiet
	Proton forecast on :20(2days)	Quiet
Bandung [Indonesia] (0800UT)	Flare forecast on :20(1days)	Quiet
	Magnetic forecast on :20(1days)	Quiet
	Proton forecast on :20(1days)	Quiet
Brussels [Belgium] (1110UT)	Flare forecast on :20(2days)	Quiet
	Magnetic forecast on :20(2days)	Quiet
	Proton forecast on :20(2days)	Quiet
Sydney [Australia] (0000UT)	Flare forecast on :20(1days)	Quiet
	Magnetic forecast on :20(1days)	Quiet
	Proton forecast on :20(1days)	Quiet
Jeju [Republic of Korea] (0200UT)	Flare forecast on :20(1days)	Quiet
	Magnetic forecast on :20(1days)	Active condition expected
	Proton forecast on :20(1days)	Quiet
Boulder [USA] (0330UT)	Flare forecast on :20(1days)	Quiet
	Magnetic forecast on :20(1days)	Active condition expected
	Proton forecast on :20(1days)	Quiet

■ IAUシンポジウム S335




太陽フレア
太陽ダイナモ
太陽風

宇宙線
系内惑星天気

スーパーフレア
系外惑星

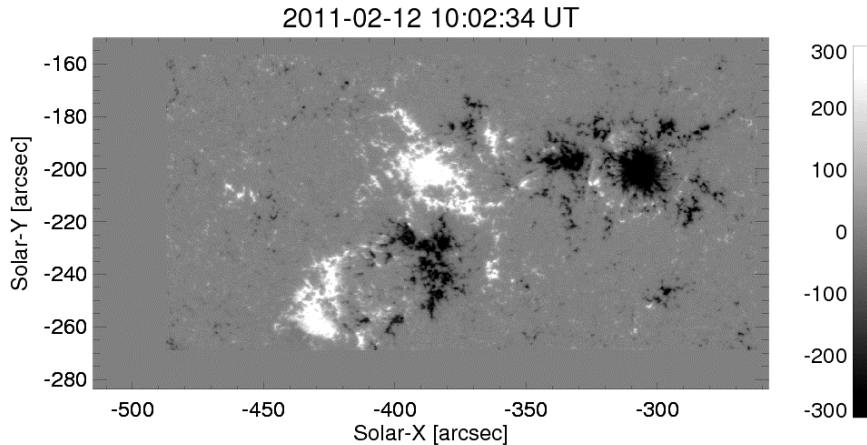
2017年7月@Exeter, UK





3. 太陽フレアの予測と 機械学習入門

■ 太陽フレアの発生と予測

黒点成長とエネルギー蓄積(Hinode/SOT)




フレア観測(Hinode/XRT)




太陽フレア
(野辺山電波
ヘリオグラフ
NoRH)

これから1日間に、最大どの規模のフレアが発生するのか？を予測する



■ 宇宙天気予報の現状

2013年9月～2014年8月 黒点数とフレア予測適中率




人手を介した予測:
的中率~60-80%

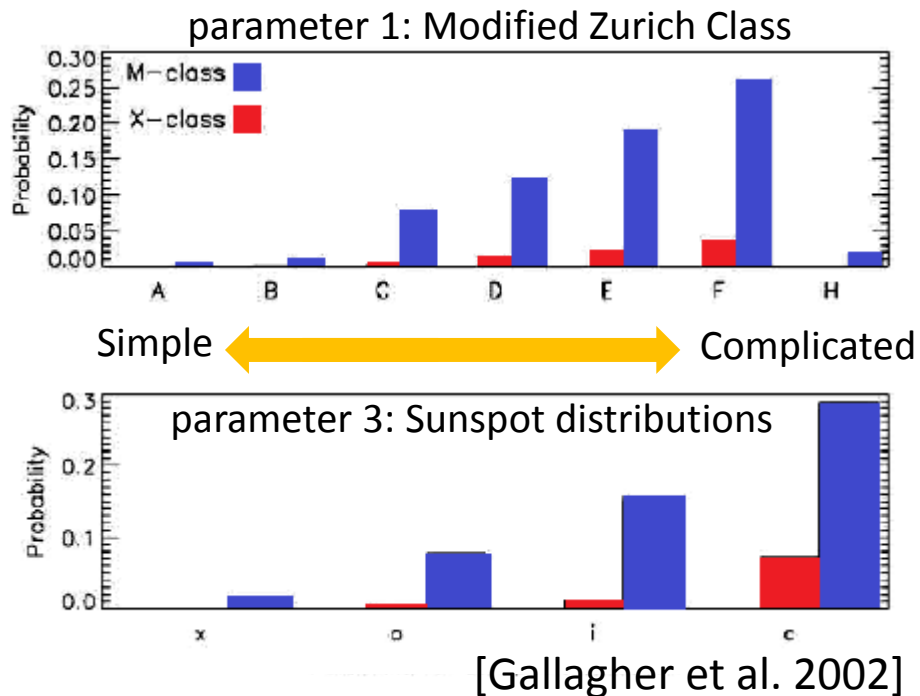
スキルスコア:
TSS~0.5
(-1.0 < TSS < 1.0)



■ 黒点のMcIntosh分類と太陽フレア予測



[McIntosh 1990]








太陽フレアは従来、白色光で観測される黒点形状から予測されていた。


より大きく複雑な黒点ほど、大規模なフレアを発生させる傾向がある。

■ Xクラスフレア発生1時間前の磁場構造

標準的なフレアモデル構造は20%程度にすぎない。他の80%は、磁気シア(歪み)が強い領域がXクラスフレアを発生。でも中にはシアのない領域でもXクラス発生。



局所的なシア
30-40% [14 events]



シア領域のないフレア (!?)
20% [8 events]

長い磁気中性線と強い
磁気シア
(標準構造?) 20%
[8 events]

複雑なシア構造
20%
[8 events]

■ 太陽フレア予測でのチェック点

人手による予報にて

① 白色光：黒点面積、黒点形状 ($\alpha\beta\gamma\delta$)

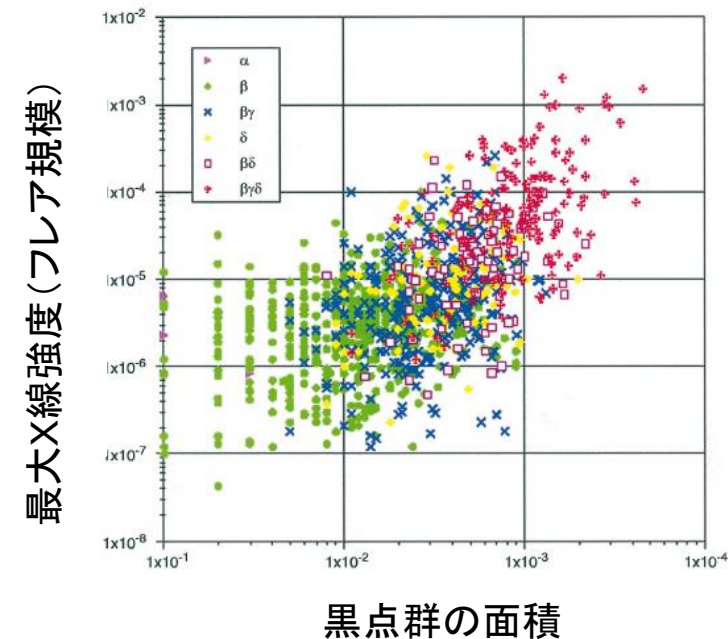
② 軟X線：フレア実績、背景値

③ 光球磁場：磁気中性線の勾配・長さ
磁場構造の複雑性
磁気シア角，浮上磁場

④ 彩層底部：1600 Å 連続光での増光

⑤ リム観測：東端領域の廻り込み

[Sammis et al. 2000]

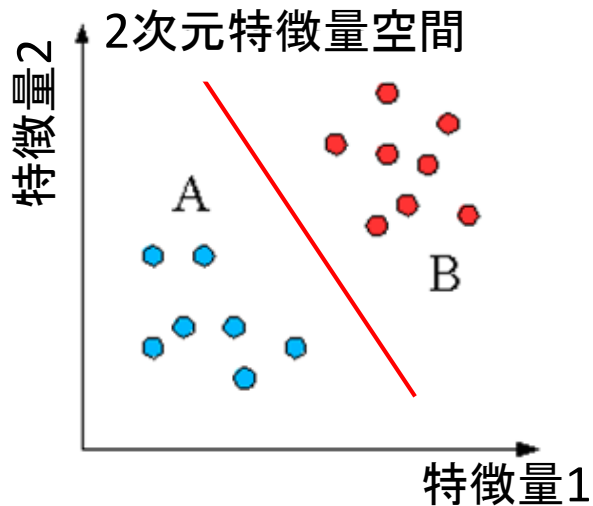


- ・観測データ量が膨大であり、人の処理能力を超えている!!
- ・毎日の予報結果を、次へより効果的にフィードバックしたい
- ・自動システムを用いたリアルタイム予報(< 24時間)
- ・統計的に、フレア発生を決める物理機構は何か？

■ 機械学習とは

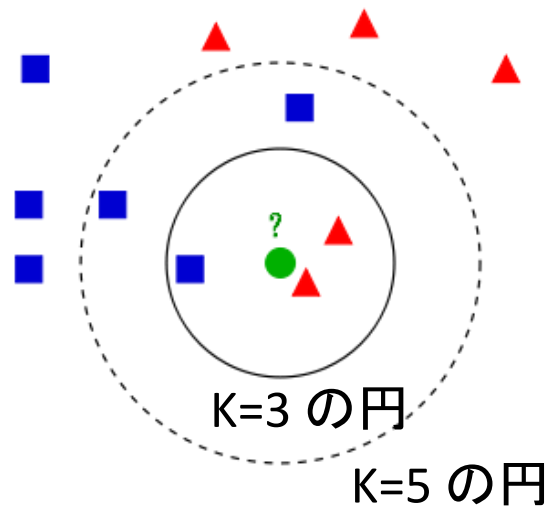
- (1) コンピュータでアルゴリズムを構築し、**学習データ**を読み込ませて、**自動的に**今あるデータを分類 & まだ見ぬデータを予測できる。
- (2) **ヒトの情報処理能力を超えて**、複雑なデータを分類 & 予測できる。

① サポートベクターマシン(SVM)



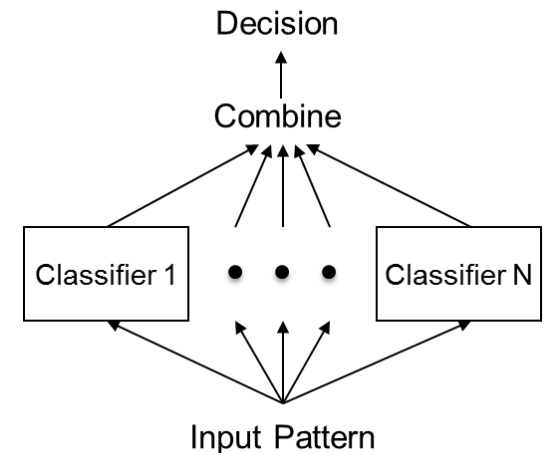
1次関数で分割・区別

② k-最近傍法 (k-NN)



半径kの円内での多数決

③ アンサンブル学習 (ERT: ex. random trees)



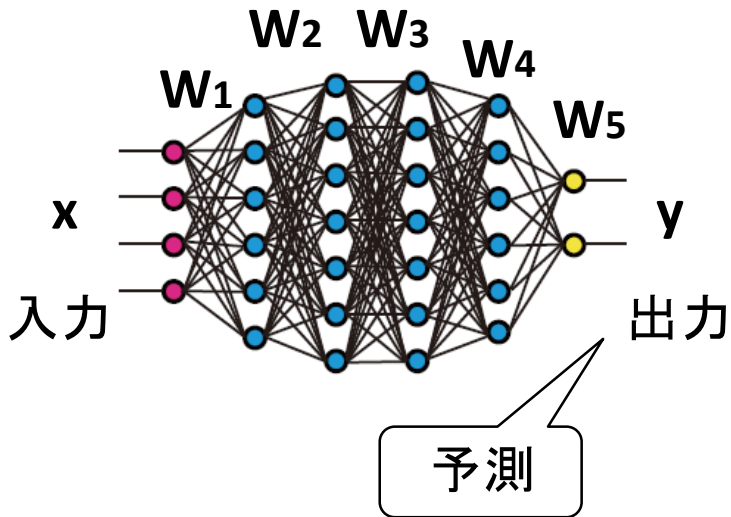
弱学習器の組合せ

■ 機械学習とは

- (1) コンピュータでアルゴリズムを構築し、**学習データ**を読み込ませて、**自動的に**今あるデータを分類 & まだ見ぬデータを予測できる。
- (2) **ヒトの情報処理能力を超えて**、複雑なデータを分類 & 予測できる。

[Nishizuka+2018 ApJ]

★ ニューラルネット (NN)



- 各層ごとに入力データの線形 & 非線形変換を繰り返す

$$y = f(Wx + b) = f(a_0x^n + a_1x^{n-1} + \dots)$$




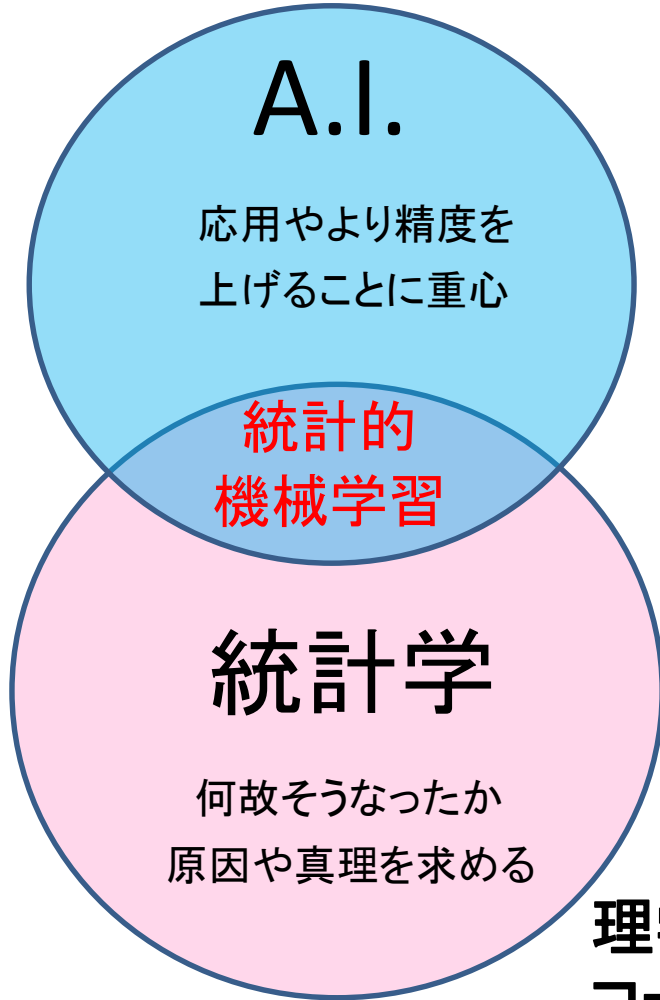
線形 (行列)

非線形: データを曲線で分割する。もしくは分割しやすいように空間を曲げる。



- パラメータ(重み) W_i は損失関数を最小化するように最適化する (\approx 2乗誤差, クロスエントロピー).
- ⇒ 多項式フィッティングに似ている。
入力データの次元が大きいと**過学習**になる。

■ 統計学と機械学習


工学的・ビュツフェ的



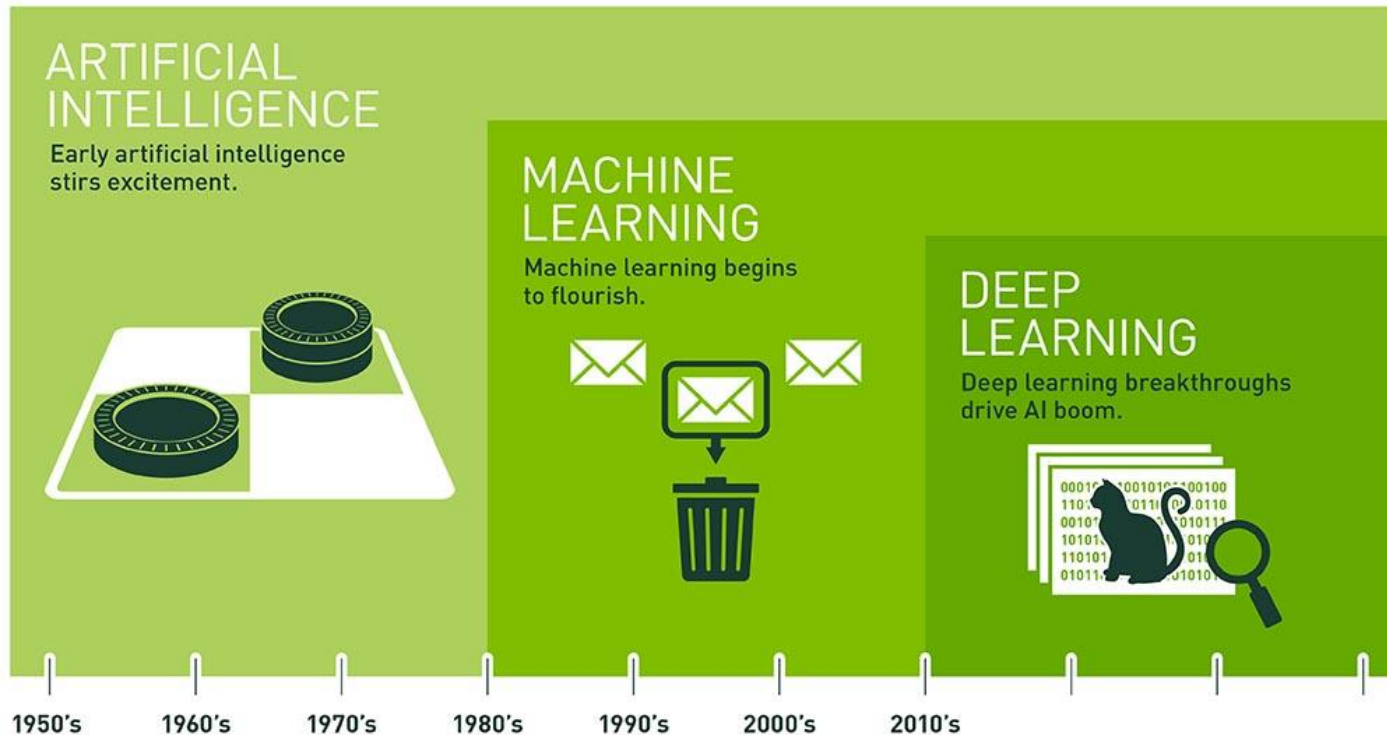
Deep Neural Network
(深層学習)



理学的
コース料理的



「AI」「機械学習」「深層学習」何が違うの？




Since an early flush of optimism in the 1950s, smaller subsets of artificial intelligence – first machine learning, then deep learning, a subset of machine learning – have created ever larger disruptions.



(出典: NVIDIAの公式ブログ)

- ・深層学習(Deep-learning)のメリット: 精度をもっとも高くできる。
デメリット: 中身がBlack Box。結果の理由を説明しづらい。

機械学習の参考文献



機械学習の参考文献(英語)



↑PDFが無料でダウンロードできます。

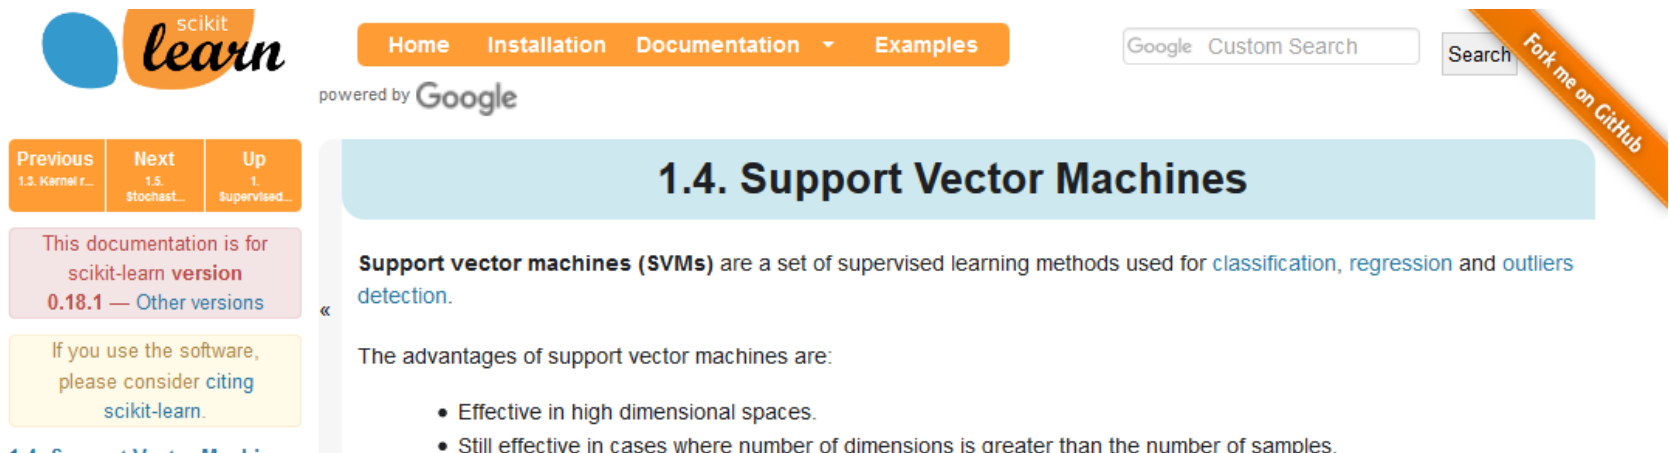
Deep-Learningの参考文献



■ 機械学習を始めるにあたって心掛け

- (1) **まず実行**。習うより慣れろ。理解(数式)は後からでいい。
- (2) 最初から高精度を狙わない。まずは、すごく精度が悪くても構わない。その後から、こつこつ改善。
- (3) あらかじめ**ゴールを設定**する。例えば、『このスコアを超えると予報に使える』、『このスコアを超えると世界一』など。それに向けて改善。

↓まずはpython3.5でscikit-learnをインストール



The screenshot shows the scikit-learn documentation page for Support Vector Machines (SVMs). The page features a navigation bar with links for Home, Installation, Documentation, and Examples. A search bar is visible in the top right corner. The main content area is titled "1.4. Support Vector Machines" and includes a definition of SVMs as supervised learning methods used for classification, regression, and outliers detection. It also lists the advantages of SVMs, such as being effective in high-dimensional spaces and still effective when the number of dimensions is greater than the number of samples. A sidebar on the left contains navigation links for previous and next sections, as well as a note about citing the software.

scikit-learn powered by Google

Home Installation Documentation Examples

Google Custom Search Search Fork me on GitHub

1.4. Support Vector Machines

Support vector machines (SVMs) are a set of supervised learning methods used for [classification](#), [regression](#) and [outliers detection](#).

The advantages of support vector machines are:


- Effective in high dimensional spaces.
- Still effective in cases where number of dimensions is greater than the number of samples.

Previous 1.3. Kernel r... Next 1.5. Stochast... Up 1. Supervised...

This documentation is for scikit-learn version 0.18.1 — Other versions

If you use the software, please consider citing scikit-learn.

4. 太陽フレア予測へのAI技術応用



■ 太陽フレアAI予測モデル研究機関

アメリカ

- ①スタンフォード大学 (SDO衛星開発グループ)
- ②カソリック大学、NASA/GSFC 宇宙天気研究所
- ③アラバマ大学、NASA/MSFC
- ④ニューメキシコ大学、ニューメキシコ空軍
- ⑤ビッグベアー観測所、ニュージャージー工科大
- ⑥コロラド大気環境研究所(AER)

ヨーロッパ

- ①アイルランド、ダブリントリニティ大学
- ②英国ブラッドフォード大学
- ③ベルギー王立観測所
- ④国立アテネ観測所, アテナアカデミー
- ⑤ ESAオランダ

中国・韓国・日本

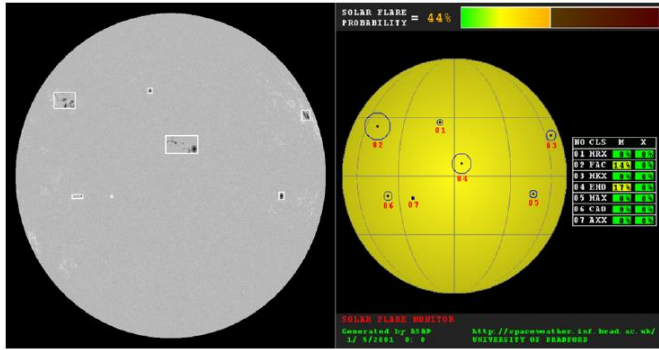
- ①ハルビン工科大学
- ②国立天文台 (NAOC)
- ③中国宇宙科学応用研究センター
- ④北京WuZi大学情報学校
- ⑤韓国宇宙天気センター(RRA/KSWC)
- ⑥宇宙環境研究所(SELab)
- ⑦キョンヒ大学
- ⑧韓国天文・宇宙科学研究所(KASI)
- ⑨京都大学、理研
- ⑩ NICT

オーストラリア

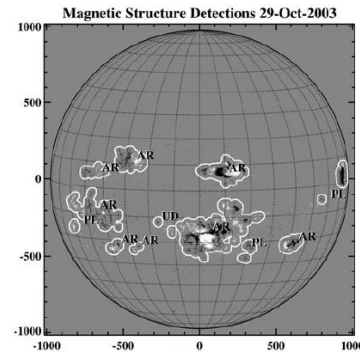
- ①オーストラリア気象局 IPS電波宇宙サービス
- ②シドニー大学

■ 世界のフレア予測ツール開発と運用

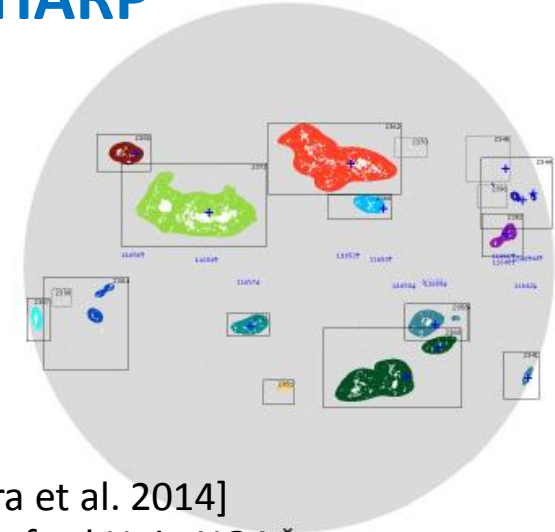
ASAP (UK, '09)



SMART (UK, '13)



SHARP



[Bobra et al. 2014]
@Stanford Uni., NOAA

MAG4 (USA, MSFC, UAH)

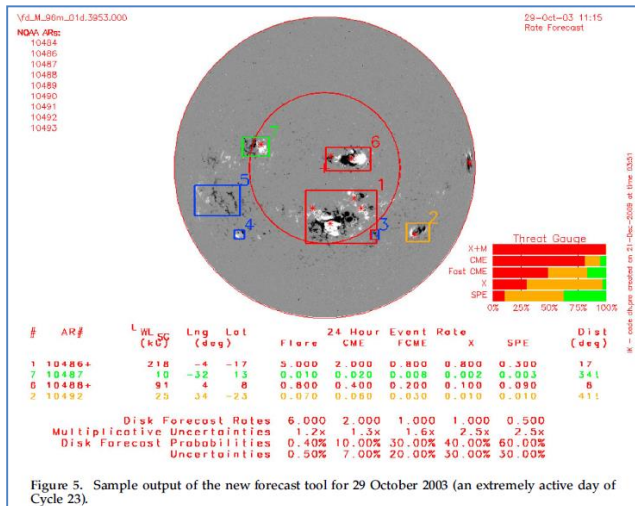
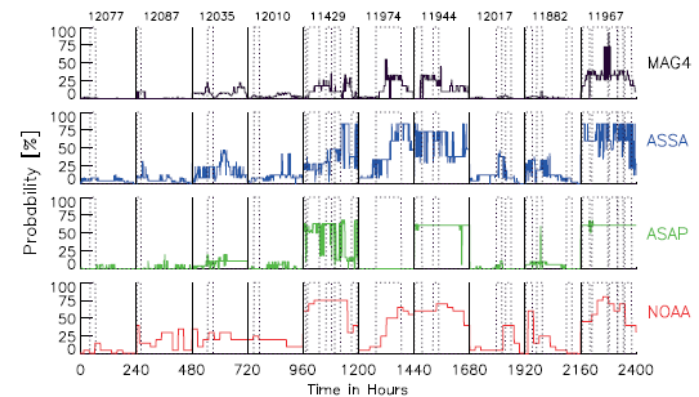



Figure 5. Sample output of the new forecast tool for 29 October 2003 (an extremely active day of Cycle 23).

Ensemble (USA, GSFC, Catholic U.)

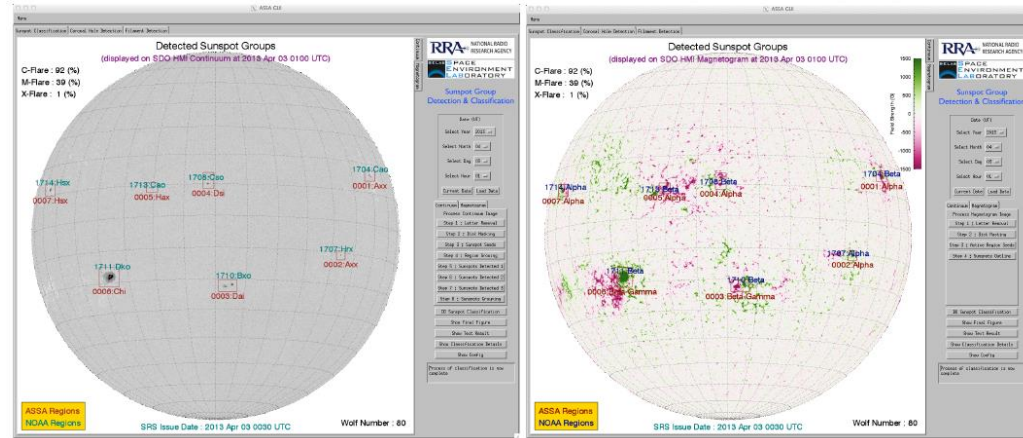


■ 世界のフレア予測ツール開発と運用

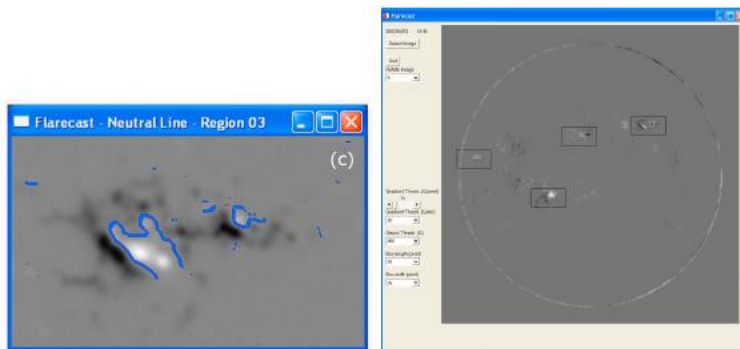
FORSEF (Greece)



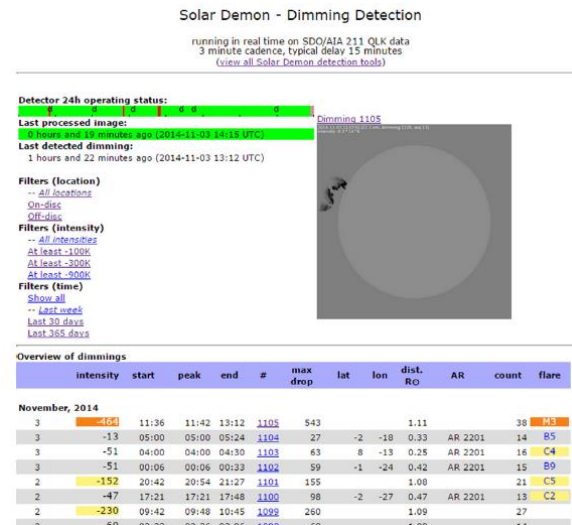
ASSA (Korea)




Flarecast (Australia)



Solar Daemon (Belgium)



■ 太陽フレア予測モデルの概要







SDO衛星
/NASA

活動領域
検出

特徴量
抽出

フレアクラス
の予測



SDO/HMI: Fe I 6173 Å 光球磁場(全面撮像)
SDO/AIA : 1600 Å UV連続光(全面撮像)
GOES : 軟X線データ

2010年~ 2015年 1時間1枚に間引いて**10万枚**画像!!
Xクラス ~40例
Mクラス ~460例
(リムイベント1割除外)

- マグネットグラム(Bz) 3TB
- **ベクトル磁場** 12TB
- **彩層発光**(UV 1600 Å) 3TB

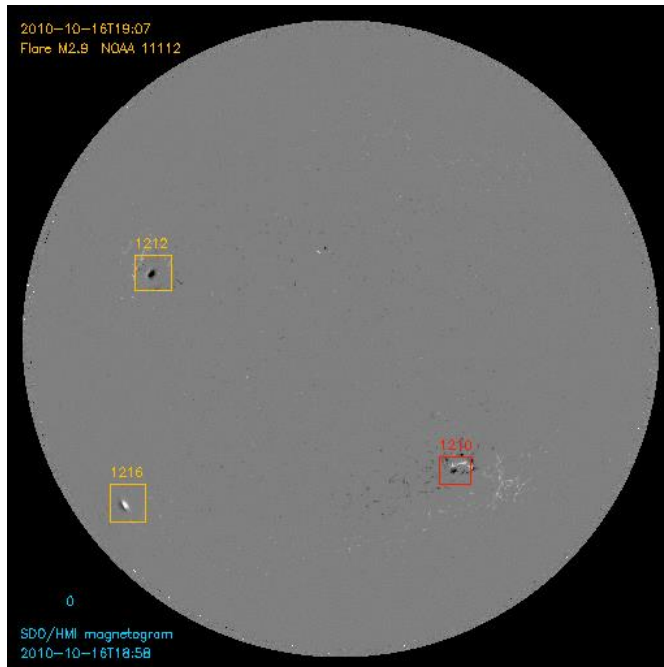
各領域毎に
フレア発生確率

X ○%
M ○%
C ○%

■ 機械的に黒点情報を抽出

SDO衛星マグネトグラムで
光球磁場 $B_{LOS} > 140G$ を検出


2010-2015年の検出結果



(活動領域ID: 01000 ~ 13000)

↑ 黄赤枠: 検出活動領域
赤色枠: フレア発生領域

各領域について特徴量抽出
(ベクトル磁場、1600Åも同領域)




例えば

- ・領域面積 ・磁束量
- ・最大/最小/平均 磁場
- ・最大/最小/平均 磁場勾配
- ・磁気中性線の長さ、本数、総合長
- ・過去の**フレア履歴**
- ・**時間発展**(1hr, 6hr, 12hr, 24hr)

■ ベクトル磁場と彩層発光の特徴量

検出領域のベクトル磁場




(射影効果はCEA変換で補正)



エネルギー蓄積/不安定性

- ・ 垂直電流 ($=J_z$)
- ・ 電流ヘリシティ ($=\Sigma B_z \cdot J_z$)
- ・ ローレンツ力 ($=\Sigma B^2$) x, y, z成分
- ・ 平均特徴ツイスト変数 $\alpha (= \Sigma B_z \cdot J_z / \Sigma B_z^2)$
- ・ 磁場自由エネルギー
- ・ 平均シア角、シア領域面積

cf) Bobra & Couvidat 2015 ApJL



SDO/AIA 1600A

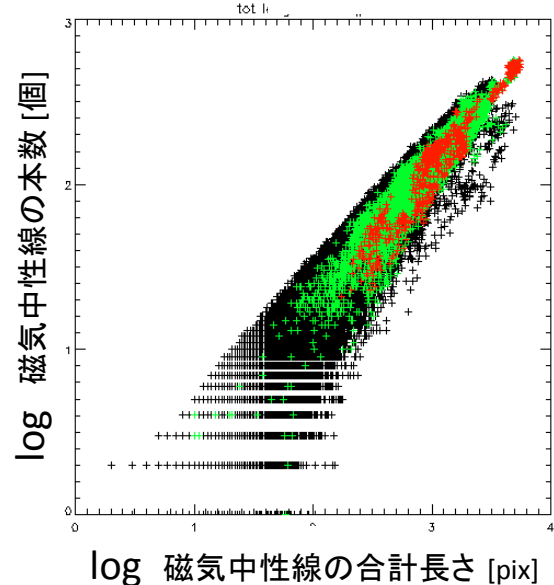
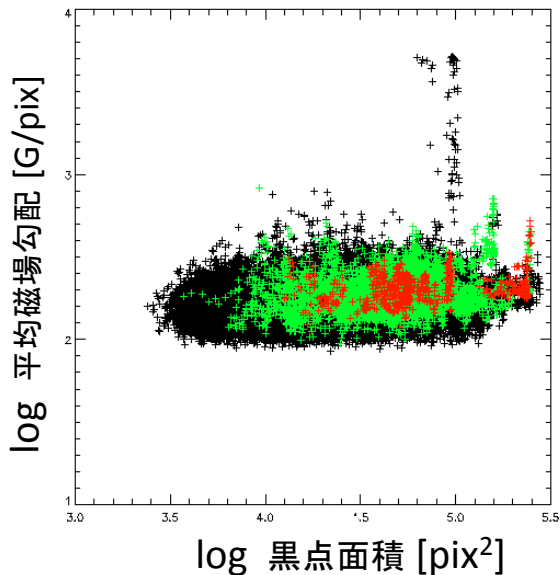
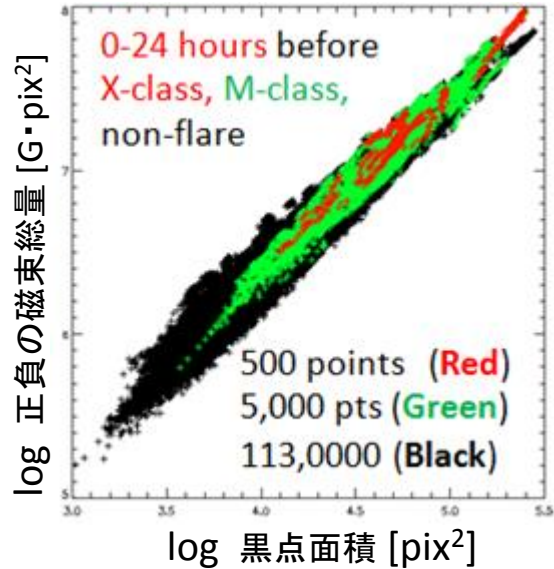



1600 Å 連続光の増光
→ 彩層底部で加熱(プレフレア発光)

- ・ 1600A 最大輝度
- ・ 1600A 明るい領域面積

cf) 齊藤等・西塚等2006年春季年会(TRACE1600)
伴場等2015年春季年会(SDO/AIA1600)

■ フレア前の特徴量空間マップ



- 全特徴量 = 約60種を抽出
- 2次元特徴量空間
 - 赤印 ■ = Xクラス1日前
 - 緑印 ■ = Mクラス1日前
- 面積、磁気中性線の本数、最大長、合計長が大きい程、フレアが大きい傾向がある。
- 磁場勾配強度はあまりフレア規模に影響していない。
- Xクラスには、統計分布に3つのクラスターが存在する。

■ CSVファイルの中身(太陽フレア)

Time	v1	v2	v3	X24	logXmax
00:00	0.54	0.45			0	2.34
01:00	0.43	0.32			0	2.55
02:00	0.30	0.16			0	2.43
03:00	0.76	0.78			1	5.43
04:00	0.56	0.54			0	2.12
⋮	⋮	⋮			⋮	⋮
⋮	⋮	⋮			⋮	⋮
⋮	⋮	⋮			⋮	⋮

分類・カテゴリー
の答え

特徴量はz値 (z-value)
を計算して標準化/規格化
する。⇒精度が上がる！

回帰の答えは標準化
・規格化しない。

■ フレア予測結果と評価

- 特徴量データベースをランダムに7:3にテスト・訓練データセットに分けて、機械学習を適用した。評価にはTSSを用いた。

		Observation	
		flare	no
Prediction	flare	TP	FP
	no	FN	TN

● True Skill Statistic

[by Hanseen & Kuipers '65]

$$TSS = \frac{TP}{TP + FN} - \frac{FP}{FP + TN}$$

TSS = 1, 100% の的中

full shuffle (1 hr)

		Observation	
		flare	no
Prediction	flare	144	15
	no	18	54439

TSS= 0.889

		Observation	
		flare	no
Prediction	flare	146	6
	no	16	54448

X flare TSS= **0.927**

		Observation	
		flare	no
Prediction	flare	130	1
	no	32	54453

TSS= 0.802

- 最大で **TSS = 0.927** を達成 → 世界トップクラスのスコア
- 今回の我々のモデルでは, **kNN** (最近傍法) が最も良い性能を示した。

■ 特徴量の重要度ランキング



順位	特徴量	重要度(重み)	
1.	Xhis	0.0519	・フレア履歴 (合計, 前日のみ) ・前日の最大X線強度
2.	Xmax1d	0.0495	
3.	Mhis	0.0365	
4.	TotNL	0.0351	・磁気中性線の総合長 ・磁気中性線の本数 ・磁束の絶対値の和 ・Bzの平均値/最大値
5.	Mhis1d	0.0342	
6.	NumNL	0.0341	
7.	Usflux	0.0332	
8.	CHArea	0.0235	彩層発光の面積
9.	Bave	0.0230	
10.	Xhis1d	0.0224	・ローレンカの和 ・磁場の垂直方向からの傾き ・極性毎の正味の電流の和
11.	TotBSQ	0.0199	
12.	VUSflux	0.0196	
13.	Bmax	0.0193	
14.	MeanGAM	0.0179	
15.	dt24SavNCPP	0.0171	

全60特徴量



* フレア履歴を除いた場合 TSS=0.89

AIによる分析で分かった

■フレア予測に有効な黒点の特徴



地震の断層面の
ように磁場の歪み
がたまる場所



発光部分


矢印の向きと
大きさから磁場
の歪みがわかる

◆黒点の特徴の重要度ランキング

1	太陽フレアの発生実績
2	磁気中性線の長さ・本数
3	磁場の強さ・磁束量
4	彩層低部の発光
5	磁場の歪み具合
6	時間変化の度合い

・黒点の約**60個の特徴**の有効性を比較した。
⇒ 地震と同じくエネルギー蓄積とトリガー現象が鍵！

★いまだに解明されていない太陽フレアの発生メカニズム
を解明する鍵が得られた。



5. 太陽フレア予測へのAI技術応用2 ～**深層学習**を用いた改良～

■ 太陽フレア予測の次の課題

• より予測精度を上げる(+信頼度もアップ)

- まだ試していない“新しい”学習アルゴリズムを試す。
『何がベストかは試さないとわからない』(定理)。分類と回帰モデル。

• 予報運用に適したモデル評価

- 現状、データベースのRandom shuffle & divideとk分割交差検証(10-fold Cross Validation)を使用。その一方で、予報運用を目的とした世界標準の評価手法はまだ確立していない。


• 予報の多様化

- 多様な予報期間(24h, 12h, 6h, 48h, ...)
- X/M/Cクラス毎のフレア発生・**確率予報** [Cクラス6000例追加]
- 他現象予測(CME, SEP, デリンジャー現象)への応用

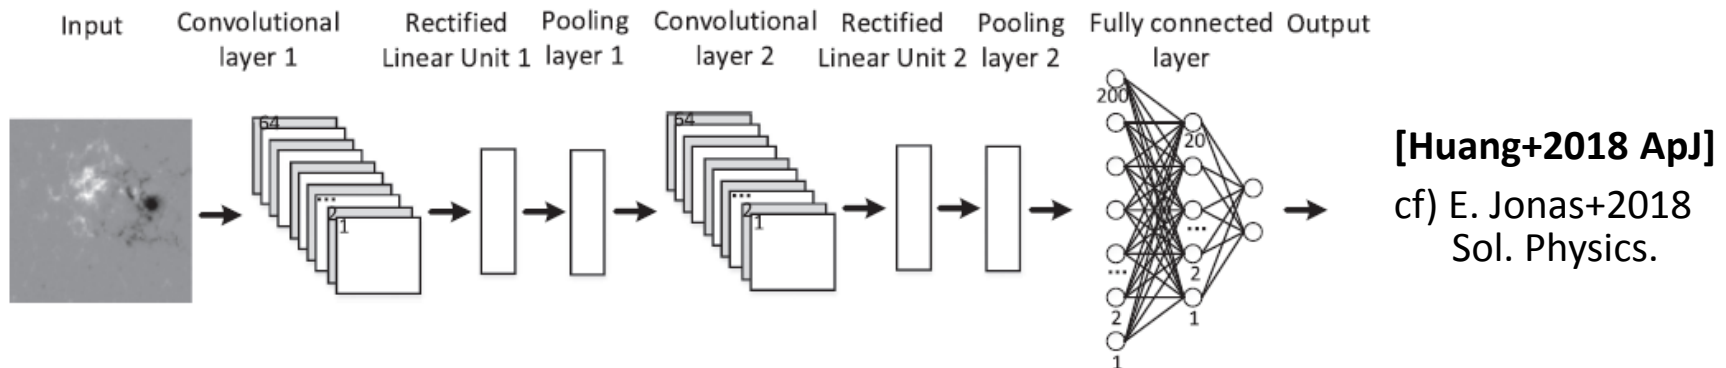
■ 機械学習モデルの課題

(1) リアルタイムデータを用いた予報:

- ・前モデルでは過去データを用いて予測していた。[Nishizuka+2017 ApJ]
- ・しかし、リアルタイムデータで評価すると、性能はまだ十分でないことがわかってきた。(TSS=0.3).



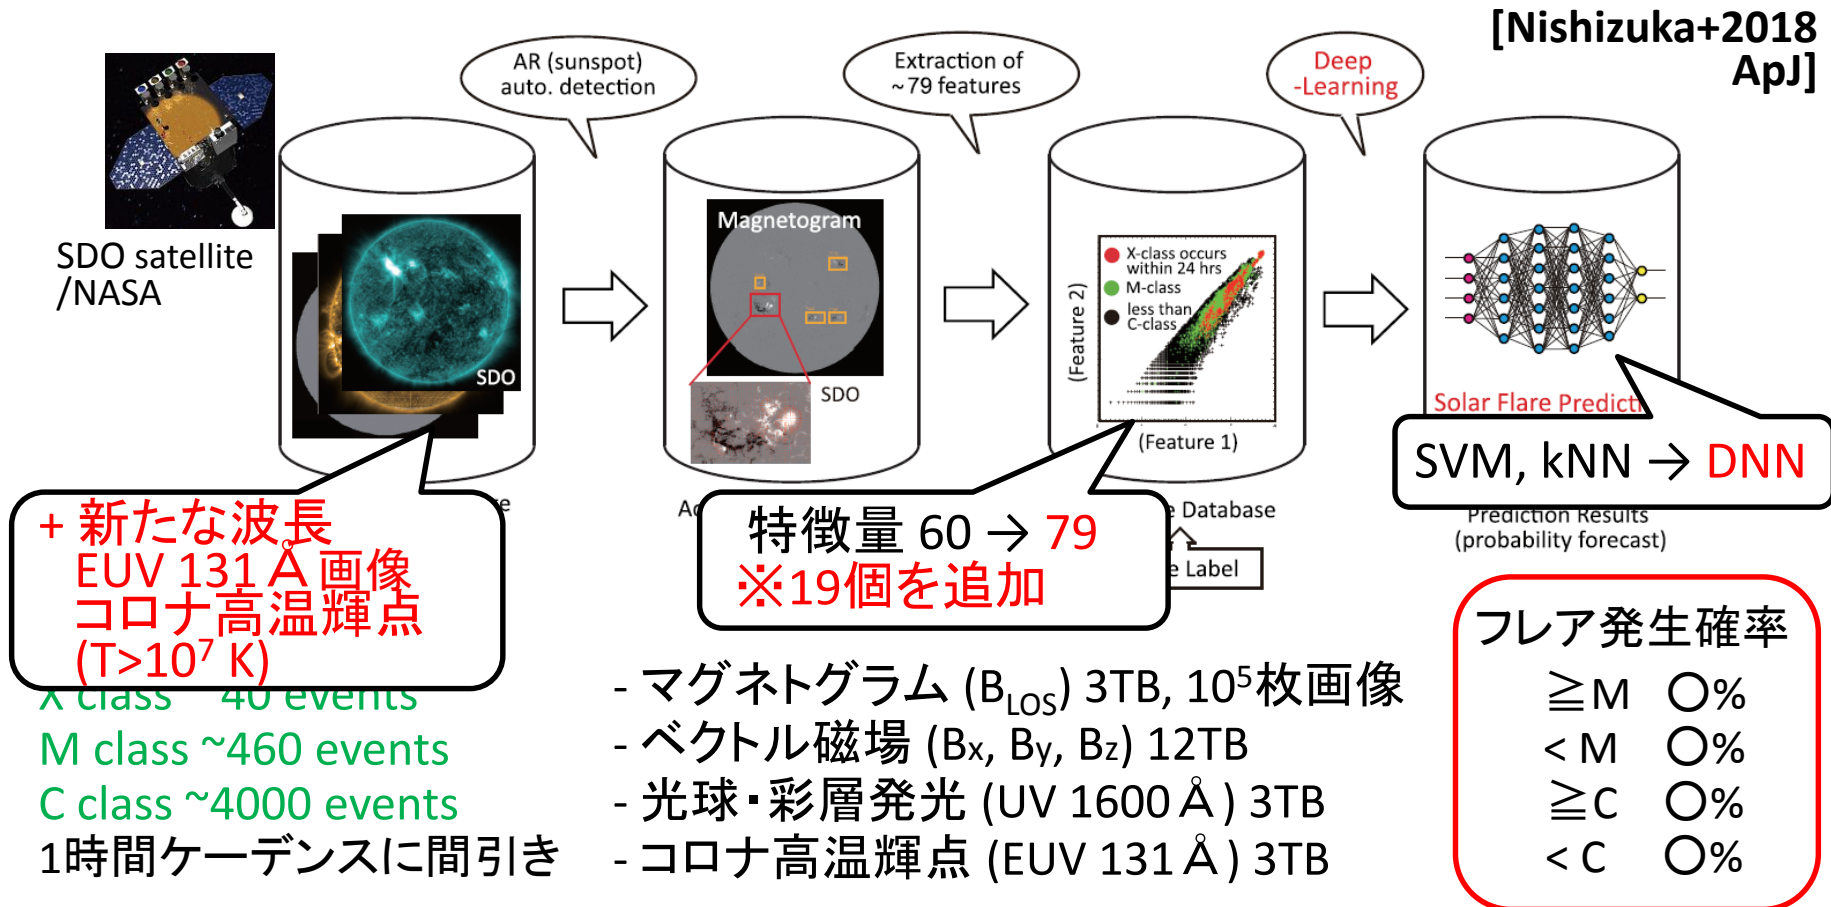
(2) 深層学習(DNN)や畳み込みニューラルネット(CNN)を用いた予測:



画像特徴量は自動的に検出されるが、中身はブラックボックス(説明不可)。

■ Deep Flare Net (DeFN) モデル

- ・深層学習を用いた太陽フレア予測モデルを開発。TSSを最大化する。
- ・予報運用形式のリアルタイムデータを用いた精度評価を行う。
- ・Deep Flare Net (DeFN) = Excellent + Nippon/NICT/...




79個の特徴量の抽出



面積 視線方向磁場 (HMI)
 磁束量絶対値の和
 正味の磁束量
 視線方向Bzの最大値/平均値
 Bz勾配の最大値/平均値
 磁気中性線の最大長
 磁気中性線の長さの和
 磁気中性線の本数

彩層発光面積 (AIA1600 Å)
 彩層発光の最大輝度
 彩層発光の輝度総量



検出黒点領域のベクトル磁場

ベクトル磁場 (HMI)
 カレント・ヘリシティ ($\sum B_z \cdot J_z$)
 ローレンツ力 ($\sum B^2$)
 垂直電流 (J_z)



時間微分 (2, 12, 24 hrs)

同一領域のフレア履歴(X, Mクラス)
 前日のフレア履歴
 軟X線の2時間/4時間平均値
 前日の軟X線最大値 (GOES)

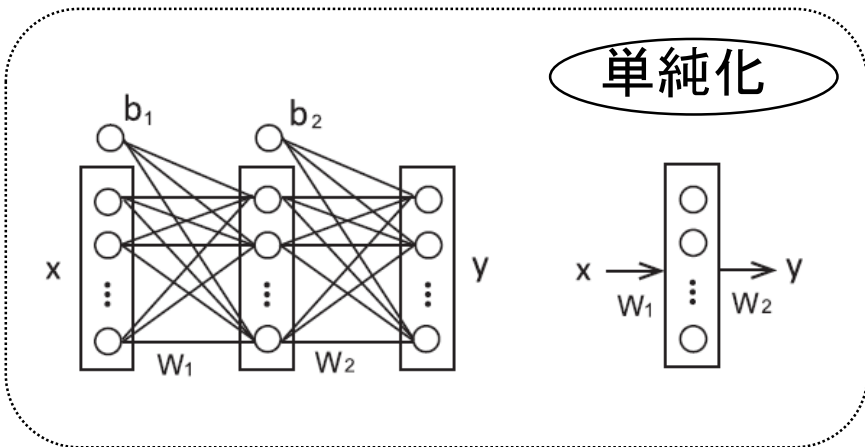

コロナ輝点面積 (AIA131 Å)
 コロナ輝点の最大輝度
 コロナ輝点の輝度総量

X線/EUV131 画像データより
 1&2時間前データ

リアルタイム予報用に
 新たな特徴量を追加!



Deep Flare Netの構造



予測スコアを向上させるため、以下を採用


- ReLU (活性化関数: 非線形関数)
- Skip connection (Residual Net)
- Batch Normalization (BN)
- **Weighted cross entropy** (損失関数)

$$J = \sum_{n=1}^N \sum_{k=1}^K w_k y_{nk}^* \log p(y_{nk}).$$

n: サンプル数

label $y_{n^*} = (1,0)$, or $(0,1)$

■ 活動領域ごとの確率予報



最後の層でsoftmax functionを計算。

$$p(y_i) = \frac{\exp(y_i)}{\sum_{j=1}^N \exp(y_j)}$$

フレア発生確率が得られる。

$P(y_1)$: Mクラス以上のフレアの発生確率

$P(y_2)$: M未満のフレアの発生確率

が2値問題で使われる。

最終的に、DeFNでは最大確率を与えるフレアのクラスを選択して予報する。

$$\hat{y} = \operatorname{argmax}_k p(y_k).$$

■ 予測結果と評価

- データベースを時系列に分割し、2010-2014年データを訓練用、2015年データをテスト用を使用した。さらに予測結果をTSSで評価。

		Observation	
		flare	no
Prediction	flare	TP	FP
	no	FN	TN

● True Skill Statistic

[by Hanseen & Kuipers '65]

$$TSS = \frac{TP}{TP + FN} - \frac{FP}{FP + TN}$$

TSS = 1 は100%的中の意味する

\geq M-class		Observation	
		flare	no
Prediction	flare	963	4382
	no	54	25937

TSS= **0.80**

\geq C-class		Observation	
		flare	no
Prediction	flare	4967	4420
	no	1171	20778

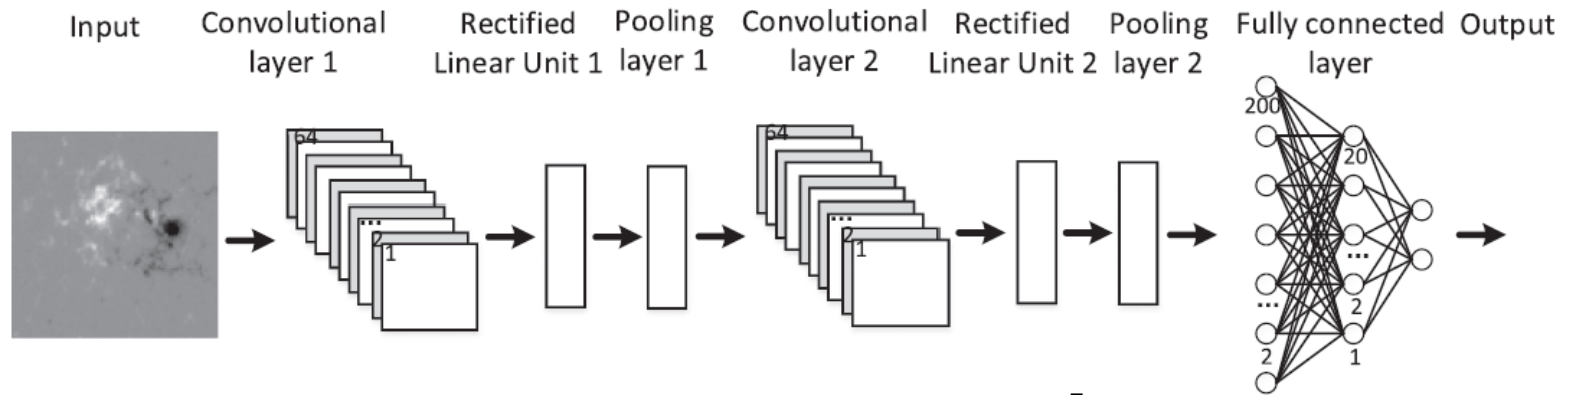
TSS= **0.63**

- スキルスコア **TSS=0.80** を達成。やや過剰見積もりぎみ (FP大きい)

cf) Huang+2018 ApJ: TSS=0.66 (\geq M), 0.49 (\geq C) DNN



Muranushi+2017 (arXiv): TSS=0.27 (\geq M), 0.30 (\geq C) DNN

Convolutional Neural Network (CNN)を用いた太陽フレア予測



[Xin Huang et al. 2018 ApJ]

1	2	3	4	5	6	7	8
9	10	11	12	13	14	15	16
17	18	19	20	21	22	23	24
25	26	27	28	29	30	31	32
33	34	35	36	37	38	39	40
41	42	43	44	45	46	47	48
49	50	51	52	53	54	55	56
57	58	59	60	61	62	63	64



- ・左図： CNN畳み込みカーネル
- ・パターンがあるところが重要な情報を保持
- ・CNNも磁場の強い領域、磁気中性線に注目（・スコアはDeFNモデルがやや良い。）

■ 恒星フレアへの応用






図6 : H α で見たスーパーフレアが起こっている星の想像図。



- ・スーパーフレアの光度曲線予測
- ・巨大黒点の再現
- ・激変星の発見
- ・観測ターゲットの特定・選定
- ・分光スペクトルの解析

[野上氏2014天文学会記者会見資料より]

まとめ

- 宇宙利用が進む今日、実用的な宇宙の研究『宇宙天気予報』の重要性は高まってきている。
- 豊富な太陽観測データをもとに、太陽フレア予測に対して機械学習の応用を試みた結果、有用である可能性が示された。
- 深層学習(DNN)を用いることで運用形式での予報精度の向上に成功した。確率予報が可能になり、現在、リアルタイム予測システムを開発中(8月末完成目標)。
- 天文観測データが豊富にとられる宇宙ビッグデータ時代になってきた。そんな中で、AI技術(機械学習)は新たな解析アプローチになりうる。(数学の解析解から数値解放への革新のような)
- まずは興味ある人はやってみるところから始めてみよう。宇宙物理×機械学習のコンビでできるとベスト。