

機械学習を用いた台風検出器の開発

金崎 拓郎¹ 筆保 弘徳² 加瀬 紘熙³

松岡 大祐⁴ 吉田 龍二⁵

1,2 横浜国立大学教育人間科学部 〒240-8501 神奈川県横浜市保土ヶ谷区 常盤台 7 9-1

1,4 海洋研究開発機構 地球情報基盤センター 〒236-0001 神奈川県横浜市金沢区昭和町 3173-25

2,3 横浜国立大学大学院教育学研究科 〒240-8501 神奈川県横浜市保土ヶ谷区 常盤台 7 9-1

4 科学技術振興機構 さきがけ 〒332-0012 埼玉県川口市本町 4-1-8

5 理化学研究所計算科学研究センター 〒650-0047 兵庫県神戸市中央区港島南町 7-1-26

E-mail: 1,kanasaki-takuro-nc@ynu.jp, 2,fude@ynu.ac.jp

3,kase-koki-kb@ynu.jp 4,daisuke@jamstec.go.jp, 5,ryoshida@riken.jp

あらまし 機械学習と気象衛星ひまわり 8 号の雲画像を用いて、台風中心位置を検出する台風検出モデルを作成し、学習設定や台風事例によってどのように検出精度が変わるかの検証を行なった。精度検証の結果、LBP 特徴量を用いて学習を行った場合のほうが、HAAR-LIKE 特徴量を用いて学習を行なった場合よりも、検出が安定して行う事ができていた。また、台風の特徴別に検出しやすい台風と検出しにくい台風がある事がわかった。

キーワード 台風、機械学習

Development of tropical-cyclone detection method using machine learning

Takuro KANASAKI¹ Hironori FUDEYASU² Koki KASE³

Daisuke MATSUOKA⁴ Ryuji YOSHIDA⁵

1,2 YOKOHAMA National University College of Education and Human Sciences 79-1 Tokiwadai,
Hodogayaku, Yokohama-shi Kanagawa, 240-0067 Japan

1,4 CEIST, Japan Agency for Marine-Earth Science and Technology (JAMSTEC) 3173-25 Showa-machi, Kanazawa-ku,

2,3 YOKOHAMA National University Graduate School of Education 79-1 Tokiwadai, Hodogayaku, Yokohama-shi
Kanagawa, 240-0067 Japan

4, PRESTO, Japan Science and Technology Agency (JST) 4-1-8 Honcho, Kawaguchi-shi, Saitama, 332-0012 Japan

5, RIKEN Center for Computational Science 7-1-6 Minatojimaminamicho, Tyuoku, Koube-shi, Hyogo, 650-0047 Japan

E-mail: 1,kanasaki-takuro-nc@ynu.jp, 2,fude@ynu.ac.jp

3,kase-koki-kb@ynu.jp 4,daisuke@jamstec.go.jp, 5,ryoshida@riken.jp

Abstract This study developed typhoon position detection models using machine learning and Himawari-8 cloud images and verified how their detection accuracy changed depending on learning setting and typhoon case. As a result of accuracy verification, the detection was able to be performed more stably when learning was performed using the LBP feature amount than when the learning was performed using the HAAR - LIKE feature amount. Also, it was found that typhoons that are easy to detect and typhoons that were difficult to detect were found by typhoon characteristics.

Keywords tropical cyclone, machine learning

1. はじめに

1.1 背景

気象庁は、台風中心位置の検出を予報官が行っている[10]。日本列島など陸地に台風が接近している時は、多くの地上観測結果も用いて台風中心位置を検出できるが、海上に台風があるときは、気象衛星雲画像のみに頼るしかない。台風の眼が発生している時は、それを台風中心と決定できるが、実際に台風の眼が現れるのは数時間ではない。多くの時間は、気象衛星雲画像で得られた雲の分布や曲率などで台風中心を決定するが、その場合は予報官の主観などが入り不確実性が高くなる現状にある。

一方、近年のコンピュータ技術の発展に伴い、機械学習を用いた研究が盛んに行われている。台風研究の分野でも、台風の強度推定や予報に適用する研究も出てきた (Liu et al.,2016;Maskey et al., 2016; Ebert-Uphoff et al.,2017; Hong et al.,2017; Kim et al.,2017a,b; Matsuoka et al., 2017; Gorricha and Costa, 2017; O'Connor et al.,2017; Seo et al.,2017; Racah et al.,2017 ;Vandal et al.,2017;)。しかし、機械学習を用いた台風位置検出に関する研究はまだ少ない。

そこで本研究では、機械学習を用いて過去の大量の衛星雲画像データとその時の気象庁ベストトラック (BT) による台風位置を学習することで、気象衛星雲画像からより客観的に台風位置検出モデルを作成する。特に、気象衛星ひまわり 8 号が 2015 年 5 月から運用され、それまでよりも高解像度・高頻度で衛星雲画像のデータを得られるようになったため (表 1)、それを学習・検証データにする。

表 1 ひまわり 7 号とひまわり 8 号の比較

	観測頻度	色	バンド	解像度 (赤外)
ひまわり7号	30分	白黒	5種類	4km
ひまわり8号	10分	カラー	16種類	2km

1.2 目的

本研究の目的は、①様々な学習設定で得られた複数の台風位置検出モデルを開発し、学習設定による検出精度の差を検証する。また、②ひまわり 7 号以前の気象衛星雲画像の学習・検証データを用いた台風位置検出モデルも作成・比較することで、ひまわり 8 号で学習するとどの程度検出精度が向上するのかを検討する。さらに、③機械学習を用いて作成した台風位置検出モデルが、どのような特徴を持つ台風の時により精度良く位置検出ができるのか、逆にどういった台風だと位置検出が難しいのか、気象学的な視点から調べることも目的とする。

2. 実験設定

2.1 検出器モデル

本研究は、ソフトウェア OpenCV (インテルが開発・公開したオープンソースのコンピュータビジョン向けライブラリ) のカスケード型 AdaBoost 識別器を基にした台風検出器 (モデル) を作成した。本研究で開発した台風位置検出モデルは、気象衛星雲画像を学習したものである。実験設定は、①の実験では台風を識別するための特徴量としては、LBP 特徴量 (輝度分布) の 1 種類とし、minNeighbors (最低近傍矩形数) は、30, 80 に設定し、Size (検出枠のピクセル数) は、70 に固定とした。②の実験では、特徴量は LBP 特徴量 (輝度分布) と HAAR-LIKE 特徴量 (明暗差) の 2 種類を用い、minNeighbors (最低近傍矩形数) は、5, 10, 20 に設定し、Size (検出枠のピクセル数) は、150, 170, 200 に設定して、それぞれの検出感度を調べた。モデルの名前を設定に対応させて、L05-S200 や H10-S150 (L や H は特徴量の頭文字の特徴量を用い、LBP 特徴量ならば L、HAAR-LIKE 特徴量ならば H、05 や 10 の数字は minNeighbors の値、200 や 150 は Size の値) とした。また、①の実験で作成したモデルには、特徴量の前に A をつける。

2.2 学習・検証データ

①学習・検証データは、ひまわり 7 号以前の 2001 年から 2015 年までの赤外画像 (IR) で実験を行なった。使用画像は、2500km 四方とした。台風画像 (positive 画像; 図 1 左) は、気象庁ベストトラック (BT) を 1 間隔に線形内挿して得た緯度経度を中心として作成した 59402 枚の中から 20000 枚を使用した。また、非台風画像 (negative 画像; 図 1 右) は、BT 以外の北西太平洋からランダムに作成した 15000 枚を使用した。

②の学習・検証データは、ひまわり 8 号 (2015 年 7 月~2017 年 12 月) の赤外画像 (IR13) を用いて実験を行った。使用画像は、3000km 四方とした。台風画像 (positive 画像; 図 2 左) は、気象庁ベストトラック (BT) を 10 分間隔に線形内挿して得た緯度経度を中心として作成した 56372 枚を使用した。また、非台風画像 (negative 画像; 図 2 右) は、BT 以外の北西太平洋からランダムに作成した約 120000 枚の中から 50000 枚を使用した。(表 2) 学習は 2015・2016 年、検証は 2017 年とした。検証には 6 時間毎の衛星画像 (図 3 の領域: 東経 100° ~180°、南緯 10° ~北緯 50°) から台風の検出を行う。検証方法は、BT の台風位置から 600km 圏内にある時を正検出、それ以外を誤検出と定義し、誤検出は台風ではない雲を検出しているもの (空振り) と台風が発生しているのにも検出をしないもの (見逃し) も検証した。

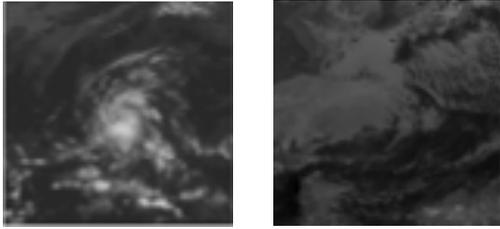


図1 ①の学習に使用した台風画像（左）と非台風画像（右）（範囲は 2500km×2500km）

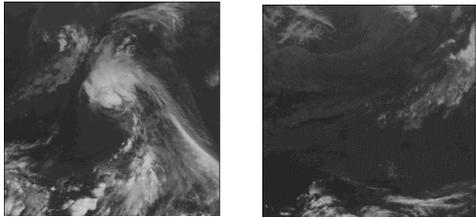


図2 ②の学習に使用した台風画像（左）と非台風画像（右）（範囲は 3000km×3000km）

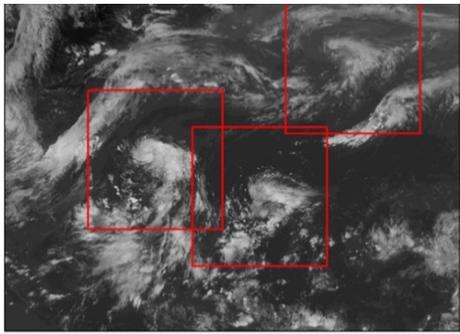


図3 検証領域と検出の様子

表2 学習データの内訳

	学習データ（年）	台風画像	非台風画像
実験①	2001-2015	20000	15000
実験②	2015-2016	56372	50000

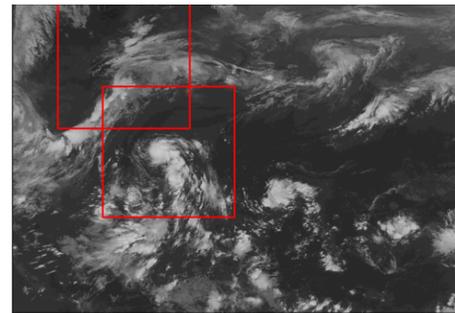
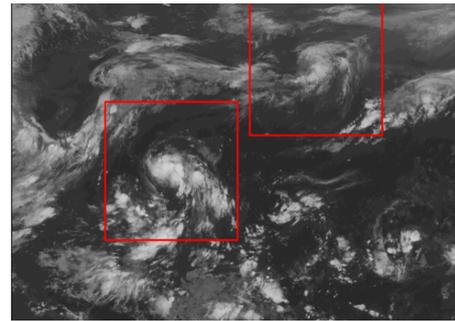


図4 L10-S200 検出器による 2017年7月1日18時から3時間ごとの検出結果

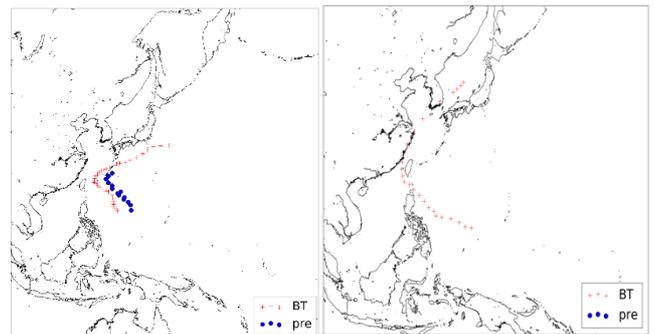


図5 AL80-S070 による精度の高い事例 T0121(左)と精度の低い事例 T0102(右)

3.結果

3.1 台風事例別の検証

図4は、L10-S200 検出器による 2017年7月2日0時から3時間ごとの検出結果である。最上の図の検出結果は2つの擾乱を検出しているが、右の擾乱の検出は、台風ではないため、空振りをしている。中央の擾乱の検出は、2017年第3号前（以後 201703）の擾乱を検出している。6時間後の台風発生まで検出することができる。この例のように、台風事例をうまく検出する場合もあれば、そうでない擾乱を検出する空振りも確認された。

図5は、AL80-S070 による(左)精度の高い事例(T0121)と(右)精度の低い事例(T0102)である。T0121では、全体的に検出が東側にずれているものの、発生から発達までをおおよそ検出することはできている。しかし、沖縄付近から北東に進路を変えて全く検出できていない事がわかる。T0102では、台風の発生から、発達まで全く検出する事ができていなかった。

図6は、L10-S200 検出器によって得られた(左)精度の高い事例(T1718)と(右)低い事例(T1705)である。T1718では、BT位置と多少の誤差はあるものの、台風発生前から発達、衰弱通してほとんど検出をすることができている。一方で、T1705は、台風発生時や北進時など所々では、検出できているものの、全体を通して見逃しが目立つ結果が得られた。他の事例も、T1705のように、検出ができる時と、検出できない時が混在する場合が多かった。

図7は、H10-S200 検出器によって得られた(左)精度の高い事例(T1718)と(右)精度の低い事例(T1705)である。LBP 検出器でも同様、HAAR-LIKE 検出器でもT1718が良い結果、T1705が悪い結果の事例として挙げられた。T1718では、LBP 検出器同様に BT位置と多少の誤差はあるものの、台風発生前から発達、衰弱通してほとんど検出をすることができている。T1705も同様に、台風発生時や北進時など所々では、検出できているものの、全体を通して見逃しが目立つ結果が得られた。

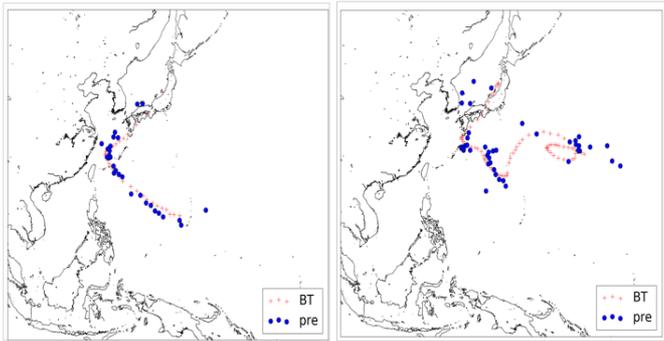


図 6 L10-S200 による精度の高い事例 T0718(左)と精度の低い事例 T1705(右)

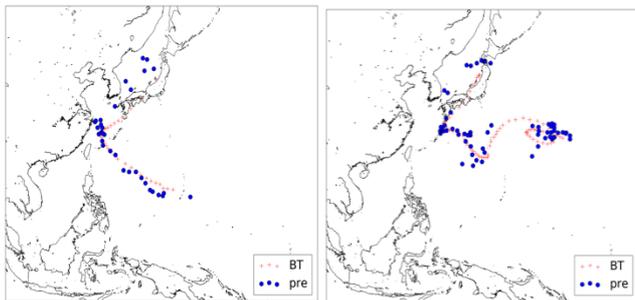


図 7 H10-S200 による精度の高い事例 T0718(左)と精度の低い事例 T1705(右)

図 6 と図 7 を比較すると T1718 では、LBP 検出器の方が全体を通して検出できており、BT との差も少ない。T1705 では、発生時や沖縄付近では、HAAR-LIKE 検出器の方が検出できていた。しかし、共通して台風が南西に進んでいるところを検出できていなかった。

図 8 は、L10-200 における 2017 年で発生した台風 27 事例の検出率である。100%検出ができていない台風もある。T1709、T1715、T1716、T1718、T1720、T1722、T1726、T1727 は検出率が 80%を超え、検出しやすい台風である。一方、T1704、T1706、T1707、T1708、T1713、T1719 は検出率が 20%以下で、ほとんど検出できていない台風事例であった。

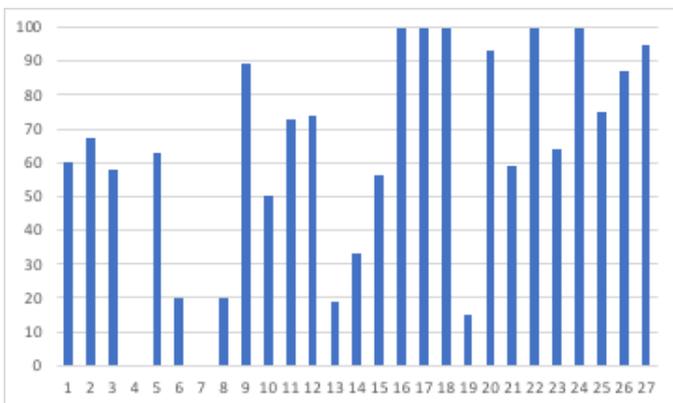


図 8 L10-200 における 2017 年の各台風の検出率

3.2 統計的な検証

表 3 は、実験①において作成した検出器ごとの 2001 年の検出数、正検出数、検出率、見逃し率、適合率、平均絶対誤差 (MAE) を表にまとめたものである。検出率は、AL30-S070 が、57%、AL80-S070 が、14%と低い値となり、適合率も 13%、17%と低い値となった。

表 4 は、実験②の LBP 特徴量を用いて作成した検出器 (以後 LBP 検出器) ごとの検出数、正検出数、検出率、見逃し率、適合率、平均絶対誤差 (MAE) を表にまとめたものである。L05-S150 が検出率 83%という結果となった。しかし、適合率を見ると L20-S200、L05-S200 の順に良い結果が出ており、全体的に見ると Size が大きい検出器ほど適合率は良くなっていて、Size が小さい検出器ほど正検出時の BT 位置との誤差が小さくなっていった。

表 5 は、実験②の HAAR-LIKE 特徴量を用いて作成した検出器 (以後 HAAR-LIKE 検出器) ごとの検出数、正検出数、検出率、見逃し率、適合率、正検出の平均誤差を表にまとめたものである。検出率は、H05-S150 で 91%、H05-S170 で 86%と高い値になっている。全体的に検出数が多くなっているのが特徴である。また、H20-S170 で、急に検出率が高くなるなど不安定な部分が見られた。

実験①と実験②で作成した検出器を比較すると、実験②で作成したひまわり 8 号の衛星データ用いた検出器の方が、圧倒的に検出率が良くなっていった。また、若干ではあるが、平均誤差も小さくなっていった。

実験②の LBP 検出器と HAAR-LIKE 検出器を比較すると、検出率は HAAR-LIKE 検出器の方が高い値が出ているが、全体的に検出数も多くなっているため、LBP 検出器の方が、適中率が高くなっている。どの検出器でも、MAE に大きな差は見られなかった。

表 3 実験①で作成した検出器から得られた結果

Model	検出数	正検出数	検出率(%)	見逃し率(%)	適合率(%)	平均誤差(km)
AL30-S070	3894	511	57	43	13	322
AL80-S070	768	124	14	86	17	301

表 4 実験②の LBP 特徴量を用いて作成した検出器から得られた結果

Model	検出数	正検出数	検出率 (%)	見逃し率 (%)	適合率 (%)	平均誤差 (km)
L05-S150	4354	571	83	17	13	278
L05-S170	3763	524	76	24	14	279
L05-S200	2606	488	71	29	19	305
L10-S150	3965	370	54	46	9	268
L10-S170	3431	357	52	48	10	277
L10-S200	2438	349	51	49	14	296
L20-S150	775	116	17	83	15	279
L20-S170	738	124	18	82	17	292
L20-S200	625	141	20	80	23	315

表 5 実験②の HAAR-LIKE 特徴量を用いて作成した検出器から得られた結果

Model	検出数	正検出数	検出率 (%)	見逃し率 (%)	適合率 (%)	平均誤差 (km)
H05-S150	7068	623	91	9	9	281
H05-S170	6204	584	85	15	9	277
H05-S200	4383	519	76	24	12	300
H10-S150	4491	468	68	32	10	277
H10-S170	3954	453	66	34	11	278
H10-S200	2861	417	61	39	15	306
H20-S150	2284	245	36	64	11	269
H20-S170	1923	496	72	28	26	276
H20-S200	1368	232	34	66	17	317

図 9 は、AL30-S070 が検出した 2001 年の台風の位置とベストトラック位置の比較である。全体としてやや東寄りに検出しているものが多いと見られていた。図 10 は、L10-S200 が検出した 2017 年の台風の位置とベストトラック位置の比較である。平均誤差が 296km であり、偏っていない事がわかった。図 11 は、H10-S200 が検出した 2017 年の台風の位置とベストトラック位置の比較である。平均誤差が 306km であり、H10-S200 では金崎;2018 とは異なり、東側よりに検出する事が少なく、西側によって検出している事が多い事がわかる。

図 9、図 10、図 11 を比較すると、図 10 の LBP 検出器のみ検出誤差に偏りがなく、平均誤差も他と比べ 5~10km 程度ではあるが、低くなっていた。

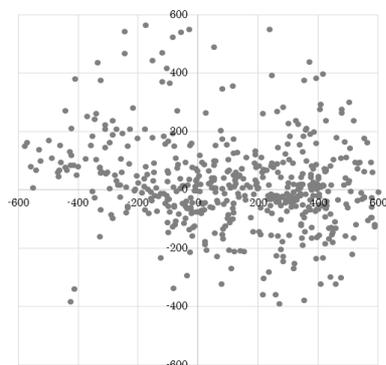


図 9 AL30-S070 が検出した 2001 年の台風の位置とベストトラック位置の比較。横軸が経度で縦軸が緯度 (km)。

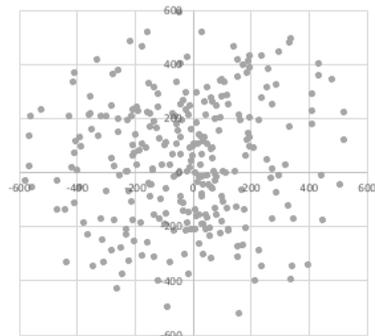


図 10 図 9 と同じで、L10-S200 が検出した 2017 年の台風の位置とベストトラック位置の比較

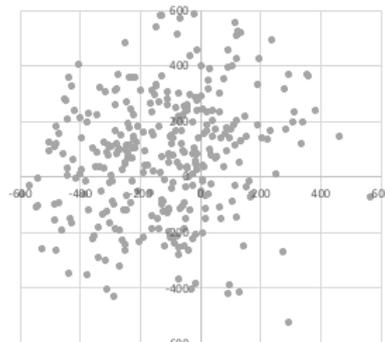


図 11 図 9 と同じで、H10-S200 が検出した 2017 年の台風の位置とベストトラック位置の比較

4. 考察

3.2 章で示した、台風事例別での検証によると、台風中心位置の検出率には高い事例と低い事例で大きな差があった。低い台風の共通点は、T1706 を除いて他全ては、南シナ海やその周辺の海域で発生して、西進して中国に上陸することである。また、T1705 の南西移動時に検出結果が悪くなった原因は、南西移動時に台風の勢力が弱まり、雲が散逸していたためと考えられる (図 12)。

さらに、図 8 において、T1704、T1706、T1707、T1708、T1713、T1719 の検出率が低かった原因としては以下の 4 つが考えられる。①T1704、T1719 は、検出範囲の東経 20° 付近に台風があったため、雲の端が画像から出てしまい検出する事ができなかった。②T1706 は、中心気圧が 1000hPa に届かず、雲の少ない台風であった。③T1707、T1708 は、お互い近くに発生したため、両者の雲域が隣接し、検出の妨げになってしまった。④T1713 は、雲が広い範囲に広がっていて、検出 Size に納まらなかった。

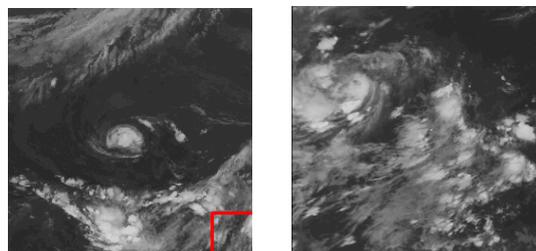


図 12 雲が散逸している (左) T1705 と雲が広い範囲に広がっている (右) T1713 の気象衛星雲画像

以上のことから、検出しにくい台風の特徴は、雲の組織化が弱く、強度が弱い台風または雲が広い範囲に広がっている台風、近くに別の台風や擾乱が存在する台風が検出しにくいと考えられる。

5.まとめ

本研究では、ひまわり 8 号を学習データとした機械学習を基にした台風検出器モデルの開発を行い、それぞれの学習設定でことなるモデルの精度比較を行った。本研究での検証結果は以下である。

- ・精度検証の結果、LBP 特徴量を用いて学習を行った場合のほうが、HAAR-LIKE 特徴量を用いて学習を行なった場合よりも、検出が安定して行う事ができていた。
- ・最小近傍矩形数が低い時に検出率が高くなり、高い時に適中率が高くなる事がわかった。
- ・Size も同様に、値が低い時に検出率が高くなり、高い時に適中率が高くなる事がわかった。
- ・台風事例ごとでみると、南シナ海やその周辺の海域で発生して、西進して中国に上陸する台風、検出率が低い傾向がある。雲の組織化が弱く、強度が弱い台風、または雲が広い範囲に広がっている台風、近くに別の台風や擾乱が存在する台風が検出しにくい事がわかった。

6.参考文献

- [1] Dvorak V. F: Tropical cyclone intensity analysis using satellite data. NOAA Tech. Rep. pp11, 45. 1984
- [2] Ebert-Uphoff I, D. R. Thompson, I. Demir, Y. R. Gel, M. C. Hill, A. Karpatne, M. Guereque, V. Kumar, E. Cabral-Cano, P. Smyth: A viasion for the development of benchmarks to bridge geoscience and data science. CI2017, pp49-52. 2017
- [3] Fudeyasu H., S. Hirose, H. Yoshioka, R. Kumazawa, and S. Yamasaki: A global view of the landfall characteristics of tropical cyclones, tropical cyclone research and review, 3, pp178-192. 2015
- [4] Fudeyasu H. and R. Yoshida: Western north Pacific tropical cyclone characteristics stratified by Genesis Environment. Mon. Wea. Rev., pp146, 435-446.2018
- [5] Fudeyasu H. K. Ito, and Y. Miyamoto: Characteristics of tropical cyclone rapid intensification over the western north Pacific. *J. Clim.*, in revision.2018
- [6] Gorricha J and A. C. Costa: A Framework for Exploratory analysis of extreme weather events using geostatistical procedures and 3D Self-Organizing Maps. International Journal on Advances in Intelligent Systems, pp16-26, 2013
- [7] Hong S, S. Kim, M. Joh, S. Song: GLOBENET: Convolutional neural networks for typhoon eye tracking from remote sensing imagery. CI2017, pp69-72.2017
- [8] Kim S. K , S. Ames, J. Lee, C. Zhang, A. C. Wilson, Dean Williams: Massive scale deep learning for detecting extreme climate events. CI2017, pp17-20.2017
- [9] Kim S, S. Hong, M. Joh, S. Song: DEEPRAIN: ConvLstm network for precipitation prediction using multichannel radar data. CI2017, pp89-92.2017
- [10]気象庁予報部: 予報作業指針: 台風予報, pp150.1990
- [11]北本朝展: 台風画像コレクションの構築および台風解析への応用: NII journal 1, pp7-22, 2000-12-20,2000
- [12] Liu Y, J. Correa, K. Kunkel, E. Racah, A. Khosrowshahi, M. Wehner, Prabhat, D. Lavers, W. Collins: Application of deep convolutional neural networks for detecting extreme weather in climate datasets,ABDA16, pp81-88, 2017
- [13]Maskey M, R. Ramachandran, R. Pradhan, J. Miller: Deep learning-powered insight from dark resources, AGU Fall Meeting,2016
- [14]Matsuoka, D., M. Nakano, D. Sugiyama, S. Uchida: Detecting precursors of tropical cyclone using deep neural networks. CI2017, pp73-76.2017
- [15]O'Connor A., R. Bell, B. Kirtman, J. Gorman: Long-range forecasting using compass machine learning. CI2017, pp57-60.2017
- [16]Pradhan R, R. S. Aygun, M. Maskey, R. Ramachandran, D. J. Cecil: Tropical Cyclone Intensity Estimation Using a Deep Convolutional Neural Network. IEEE Transactions of image Processing, pp692-702.2017
- [17]Racah E., C. Beckham, T. M. Prabhat, C. Pal: Semi-supervised detection of extreme weather events in large climate datasets,IEEE TRANSACTIONS ON IMAGE PROCESSING, pp692-702 2018
- [18]Ritchie E. A. and G. J. Holland: Large-scale patterns associated with tropical cyclogenesis in the western Pacific. Mon. Wea. Rev., pp127, 2027-2043.1999
- [19]Seo S, A Mohegh, G. B. Y. Liu: Graph convolutional autoencoder with recurrent neural networks for spatiotemporal orecasting. CI2017, pp85-88.2017
- [20]Simpson R. H.: The hurricane disaster potential scale, Weatherwise, pp27, 169-186.1974
- [21]Vandal T and A. R. Ganguly: Uncertainty quantification for statistical downscaling using bayesian deep learning. CI2017, pp29-32.2017
- [22]Yoshida R. and H. Ishikawa: Environmental factors contributing to tropical cyclone genesis over the western north Pacific. Mon. Wea. Rev., pp141, 451-467.2013