

静止気象衛星画像と深層畳み込みニューラルネットワークを用いた北西太平洋海域の台風の強度分類

大光寺 岳^{*1}・鎌倉 智之^{*2}・北 畠 尚子^{*3}

1. はじめに

台風はしばしば強風により大きな被害をもたらすため、強度の実況を高頻度で正確に把握することが、防災には非常に重要である。しかし、台風はそのライフサイクルの大部分の期間にわたって、精度の高い直接観測が少ない海上を進むため、海上を高頻度で観測できる静止衛星リモートセンシングへの依存が相対的に大きくなる。静止衛星観測を用いた台風強度推定法としては、衛星赤外面像における雲パターンを台風強度に関連付けたドボラック法 (Dvorak 1984) が長期にわたって実施されている。しかし、ドボラック法では台風に伴う雲域の主観的判断が解析結果に影響することがあるため、解析作業を自動化・客観化する開発が行われている (例えば Olander and Velden 2007; 佐々木 2015)。

一方、静止衛星観測を用いる場合でも、従来のドボラック法を前提とせず、雲パターンと台風強度を関連付けることも考えられる。二次元画像認識の手法としては、畳み込みニューラルネットワーク (convolutional neural network : CNN) を多層化した AlexNet (Krizhevsky *et al.* 2012) の提案以来、精度が著しく向上している。Pradhan *et al.* (2018) は AlexNet に類似した畳み込み層 5 層とプーリング層 3 層、及び全結合層 3 層からなるモデルを用いて、北大西洋及び北東太

平洋の熱帯低気圧 (以後、簡単のために北西太平洋以外のものも含めた熱帯低気圧を強度にかかわらず台風と称する) の衛星赤外面像を学習させ、強度分類を行い、8割を超える正解率で分類できたと報告した。ただし彼らの実験では、学習に使用したデータと検証に使用したデータをランダムに分割しており、学習と検証に同じ台風のかかなり近い観測時刻の画像を使用したことにより、結果的に高い自己相関のあるデータを使って学習を行っていたとみられる。最近、Chen *et al.* (2019) も AlexNet を参考にしたモデル (畳み込み層 4 層と全結合層 3 層、プーリング層なし) を使用して、世界中の台風の 3 時間毎の赤外面像に加えて軌道衛星マイクロ波観測データも用いて最大風速の学習と推定を行い、従来の他の推定手法よりも高い推定精度を得たとしている。これらで使用された CNN が二次元画像の判別に用いられるのに対して、加瀬ほか (2019) は画像の時間変化を学習・予測する手法である Long Short-Term Memory (LSTM : Hochreiter and Schmidhuber 1997) を用いて、前 11 時間の雲画像の変化から台風の中心気圧とその時間変化を推定した。このように様々な手法の研究開発が始まっているが、現業における解析では長時間の連続した観測値が得られない場合でも強度解析を行う必要があるため、単一の波長帯の画像を使用した手法でどの程度の精度の解析が行えるか知ることは重要である。また即時的に入手できるひまわり 8 号の 10 分ごとの観測の活用も検討する必要がある。

本研究では、静止気象衛星赤外面像と CNN を用いて北西太平洋の台風の強度分類を行い、CNN による台風強度推定の可能性を検討して課題を抽出することを目的とする。用いたモデルは、Simonyan and Zisserman (2014) が提案した VGG のうち 11 層のモデ

*1 気象大学校 (現 : 福井地方気象台)

*2 気象大学校 (現 : 気象庁総務部)

*3 (連絡責任著者) 気象大学校。

〒277-0852 千葉県柏市旭町7-4-81。

E-mail : nkitabatake@mc-jma.go.jp

—2019年6月14日受領—

—2019年11月6日受理—

ルである VGG11 を参考にしたものである。近年は ResNet (He *et al.* 2016) などのさらに複雑なモデルも提案されているが、今回の強度推定の可能性の検討には、比較的シンプルなモデルで効果を検討したほうが有効と考える。このモデルを使って第 1 表に示した 6 つの台風強度カテゴリへ分類する。VST と VT は、それぞれ、気象庁の国内向け情報における「非常に強い台風」と「猛烈な台風」に対応する強度である。

2. データと学習結果の解析方法

2.1 対象とした台風と衛星画像

本研究で対象とした台風は、赤道～60°N, 100°E～180°において気象庁ベストトラックデータに記録された 1981 年台風第 1 号 (T8101)～2017 年台風第 14 号 (T1714) の 37 年間の 934 個である。台風の中心位置や最大風速などの解析値は原則として 6 時間ごと (日本に接近した際は 3 時間ごと) に記録されている。この最大風速によって第 1 表の 6 つのカテゴリに分類した。慣例により風速はノット (kt) で表し、1 kt = 0.514 m/s である。台風が温帯低気圧に変わった後の解析値は使用しない。本研究ではこのベストトラックデータによる台風強度を「真値」と見なして学習及び評価を行う。

衛星画像としては、静止気象衛星ひまわり (GMS) からひまわり 8 号 (Himawari-8) まで、2003～2005 年の GOES-9 も含む赤外画像を用いた。使用した衛星と

その観測時間間隔は第 2 表に示すように、原則として、初期の GMS では 3 時間毎、最近の Himawari-8 では 10 分毎である。ただし、事例によっては臨時観測のデータがある場合もある。

一方で、ベストトラックデータは上述のように 6 時間毎 (一部は 3 時間毎) である。1981 年以降の気象庁ベストトラックデータにおいて、6 時間で最も気圧が低下したのは 2006 年台風第 20 号で、11 月 10 日の 0000 UTC から 0600 UTC の間に中心気圧が 40 hPa 低下し、最大風速は 35 kt 増大した。ここから、1 時間で最大風速が変化するのは最大で 6 kt 未満であると仮定し、ベストトラック解析時刻の前後 1 時間の画像は解析時刻と同一の強度カテゴリに分類した。他の事例の強度変化はこれほど大きくはないが、6 時間の間に台風強度の極大・極小が生じていることもありうると考え、ベストトラック解析時刻との差が 1 時間を超える画像は本研究では採用しないこととした。この考え方により、本研究では、一つのベストトラック解析値に対して、観測が 1 時間ごとである期間には 3 枚、観測が 30 分ごとである期間には 5 枚、観測が 10 分ごとである期間は 13 枚の赤外画像を紐づけた。この結果、用いた衛星画像の数は第 2 表のように 131343 枚となった。

2.2 訓練・検証・テストデータの選択

CNN モデルでの画像判別には、使用するデータを訓練・検証・テストデータに分割し、訓練データと検証データを使用して学習を行う。そして学習させたモデルを用いてテストデータで性能を評価する。本研究ではまず、全データ (131343 枚の画像) を Pradhan *et al.* (2018) と同様にランダムに 60% を訓練データ、20% を検証データ、20% をテストデータとして学習・テストを行った。これを「ランダム選択のデータによる実験」と呼ぶことにする。次に、全データのうち 2003 年・2008 年・2010 年の台風を検証データ、2016 年の台風をテストデータ、その他の年の台風を訓練データとした学習・テストを行った。この場合の各データ数は

第 1 表 本研究における台風強度カテゴリ。

強度カテゴリ	最大風速 (kt)
TD (tropical depression)	$V_{\max} < 34$
TS (tropical storm)	$34 \leq V_{\max} < 48$
STS (severe tropical storm)	$48 \leq V_{\max} < 64$
TY (typhoon)	$64 \leq V_{\max} < 85$
VST (very strong typhoon)	$85 \leq V_{\max} < 105$
VT (violent typhoon)	$105 \leq V_{\max}$

第 2 表 使用した衛星データ数を、観測時間間隔 (原則) 別に分けたもの。訓練データ・検証データ・テストデータは、年別選択の実験で用いたデータ数。

衛星	時間間隔	データ数	訓練データ	検証データ	テストデータ
GMS, -2, -3	3 時間	13089	13089	0	0
GMS-4, -5, GOES-9	1 時間	42989	40451	2538	0
MTSAT-1R, -2	30 分	44131	38350	5781	0
Himawari-8	10 分	31134	19830	0	11304
計		131343	111720	8319	11304

第2表に示している。これを「年別選択のデータによる実験」と呼ぶ。

年別選択のデータによる実験では、10分毎の画像について強度分類を行うため、ベストトラックの解析値1個に対して最大13個の分類結果が得られる。実際に気象庁における現業台風強度推定ではドボラック法で得られる瞬間的な解析値を3時間について平均して利用している(佐々木 2015)。そこで本研究では、この10分毎の強度分類結果を用いて、同一のベストトラック解析値に紐づけられた画像に対応するCNNモデル出力(確率)を平均することで、短時間変動を除去した強度分類結果を算出した。これを「時間平均した強度分類」と呼ぶ。

2.3 入力画像の前処理

入手した衛星画像は、輝度温度256階調のモノクロ画像で、1ピクセルあたり0.02度の解像度で経緯度座標に変換されている。この画像から、ベストトラックデータの台風中心位置を中心として、緯度・経度方向にそれぞれ640ピクセル(12.8度)の幅で切り出し、さらに、バイリニア法を用いて両辺それぞれ320ピクセルに縮小した画像を作成した。各ピクセルは0から255までの正数値を取る画素の値として表されているため、255で除算することで0~1に規格化した。さらに、これらに前処理として画像にランダムな回転などの人為的なノイズを与えた。これはdata augmentationと呼ばれ、CNNモデルで精度向上のためしばしば適用される手法である(例えばKrizhevsky *et al.* 2012; Simonyan and Zisserman 2014)。最後に256×256ピクセルの領域(経緯度10.24度四方に相当)をランダムに切り出し、これをモデル入力画像とした。

2.4 CNNモデルの構築と実験

本研究のモデルの層構造はSimonyan and Zisserman (2014)のVGG11と同様の組み合わせで、8層の畳み込み層と5層のプーリング層、及び3層の全結合層とした。畳み込み層と全結合層のパラメータ決定には、サイズ16のミニバッチ学習も取り入れた確率的勾配降下法を用い、optimizerにはAdam(Kingma and Ba 2014)を、損失関数にはクロスエントロピー誤差を採用した。さらに、各畳み込み層と全結合層の後には、バッチノーマライゼーション(Ioffe and Szegedy 2015)を実行することで学習の収束速度の向上などの効果が得られるようにした。出力層の演算では活性化関数としてSoftmax関数を用いた。本論文では以上の構成のモデルを単にVGG11と呼ぶことにする。このモ

デルに、モノクロ画像である1チャンネルで256×256のサイズのデータを入力すると、最後の出力層で第1表の6個のカテゴリそれぞれに分類される確率が得られる。

本研究では深層学習モデルの作成・実行には、Sony Neural Network Console (Sony 2017a)を使用し、Neural Network Libraries (Sony 2017b)フレームワーク上に実装した。これらは利用法が容易で、シンプルなモデルにおいては有効であると考えられる。

全訓練データに対して学習が一巡する単位を1エポックとし、1エポックごとの学習終了時には独立データである検証データを用いて損失関数の値を計算して、それが最小になったパラメータの組み合わせを「最適化された学習結果」とみなす。そして、この最適化されたパラメータを用いたモデルに、学習・評価に用いていないテストデータを適用することで、モデルの精度を評価する。

なお、本研究では畳み込み層を10層としたモデル(VGG13)を用いた実験も行ったが、使用した計算機の性能の制約に合わせてバッチサイズを縮小してVGG11と比較した実験では、層を増やしたことによる精度向上は見られなかった。このため本論文ではVGG11の結果のみを述べる。

3. 結果

第2.2節で述べたランダム選択、年別選択のデータを用いて、それぞれ実験を行った。評価の指標としては、正解率、再現率、適合率、F値を用いる。正解率は全データ中で正しく分類できた事例の割合、再現率は実際のカテゴリ中でモデル推定が正しかった割合(すなわち「見逃し」でなかった割合)、適合率はモデル推定のカテゴリ中で実際にそのカテゴリであった割合(すなわち「空振り」でなかった割合)である。F値は再現率と適合率の調和平均である。

ランダム選択のデータによる実験では、400エポックの学習を行い、これが終了した時点でのパラメータを最終的な学習結果として採用してテストを行った。その結果(混同行列は省略)、正解率は81.5%で、同様にランダム選択であったPradhan *et al.* (2018)で8割以上の正解率を出していたのと同様の結果になった。

年別選択のデータによる学習は330エポックを行ったが、110エポックの学習が終了した時点でパラメータが収束したと考えられることから、110エポックでのパラメータを最終的な学習結果として採用してテス


トを行った。その結果の混同行列を第3表に示す。正解率(表中の太字の事例数の合計の割合)は52.4%と、ランダム選択のデータによる実験よりかなり低くなった。しかしそれでも半数以上が正しく推定・分類されている。さらに1段階のズレ(表中の下線の事例数の合計の割合)を含めると91.0%に達するため、この分類による学習でも台風強度と衛星画像の対応の傾向は十分にとらえられていたと言える。カテゴリ毎に見ると、STSとVTの再現率が特に低い(見逃しが多い)。ただしVTは適合率100%で、すなわち見逃しが多いが空振りはなかった。STSは再現率・適合率とも低い。これらはランダム選択データによる実験の結果(詳細は略)と共通している。ドボラック法(Dvorak 1984)では衛星画像で眼が明瞭なものがTY以上の強度に対応付けられており、眼が不明瞭なSTS強度の台風は特徴が捉えにくくTSに分類される傾向が生じる

ことが考えられる。

ここで、第3表において、真値はVTだがCNNモデルでTSと分類され4段階のズレとなったものが11事例ある。このうち、T1626の2016年12月24日1810UTCの画像(第1図c)に着目する。ベストトラックでは1800UTCの最大風速が105 ktであることから、この時刻の真値はVTである。これと同じ時刻のベストトラックデータに紐付けされていた1700UTC~1900UTCの10分毎の衛星画像は13枚あるが、TSに分類されたのは第1図cの1枚だけで、他は第1図a, bのように一見ほとんど違いはないがTYまたはVSTに分類されていた。この期間の13枚の画像について、各カテゴリの確率値(Softmax関数出力)を第2図に示す。図中に太線で示しているのが各時刻で最大の確率となったカテゴリで、それがその時刻の強度分類となる。1810UTCを除く12枚の画像で、TY

第3表 CNNモデルによる年別選択のデータの実験の混同行列。太字は真値と推定値が同じカテゴリ、下線はカテゴリの推定のずれが1段階以内の事例数。

		推定値						再現率
		TD	TS	STS	TY	VST	VT	
真値	TD	2288	<u>745</u>	28	10	1	0	0.745
	TS	<u>870</u>	1395	290	151	0	0	0.516
	STS	342	<u>830</u>	386	<u>356</u>	12	0	0.200
	TY	43	344	<u>262</u>	903	<u>170</u>	0	0.524
	VST	15	39	0	<u>416</u>	778	<u>0</u>	0.623
	VT	0	11	0	20	<u>429</u>	170	0.270
適合率		0.643	0.415	0.400	0.487	0.560	1.000	
F値		0.690	0.460	0.270	0.505	0.590	0.425	




第1図 T1626の2016年12月24日1710UTC, 1800UTC, 1810UTCの衛星画像。画像に付記した強度カテゴリは年別選択データによるCNN強度分類結果を示す。

と VST が30%前後またはそれ以上となっている。このうち1700UTCと1710UTCは僅差でTYが卓越したために最終的にTYに分類された。その他の時刻はVSTが卓越してVSTに分類されたが、1730UTCや1740UTCはTYと僅差であるのに対して1840UTC前後はVSTが50%を超えている。これらは最終的なカテゴリ分類が同じでも信頼度に差異があることを示している。この事例は眼が比較的小さいため、各時刻の画像における眼の鮮明さの違いが、判別に影響した要素の一つとして考えられる。

第2図で1700~1900UTCの各カテゴリに対する確率を平均すると、同じ図中の「AVE」の各カテゴリの値となる。AVEで確率が最大なのはVSTの42.3%

で、これが2016年12月24日1800UTCの時間平均した強度分類となる。ここでは時間平均により短時間の変動が除去され、ベストトラックでの強度VTとは1段階のズレがある結果が得られたことになる。これと同様の時間平均の処理を、テストデータとした2016年の11304個に対して施すと、715個の時刻に関する強度分類が得られる。その結果の混同行列を第4表に示す。この場合の正解率は55.4%で、さらに1段階のズレを含めると92.7%となった。また再現率・適合率・F値ともほとんどのカテゴリにおいて時間平均を取った方が向上している。第4表で推定値が真値から2カテゴリ以上過大になった事例は、TSがTYに分類された8事例のみとなった。一方、推定値が2カテゴリ以上



第2図 T1626の2016年12月24日1700~1900UTC (横軸)の台風強度カテゴリ分類の確率値 (縦軸)。AVEは1700~1900UTCの平均。

第4表 第3表と同じ、ただし年別選択のデータによる実験結果を時間平均した強度分類の混同行列。

		推定値						再現率
		TD	TS	STS	TY	VST	VT	
真値	TD	<u>166</u>	<u>49</u>	0	0	0	0	0.772
	TS	<u>55</u>	<u>93</u>	<u>18</u>	8	0	0	0.535
	STS	20	<u>44</u>	<u>22</u>	<u>24</u>	0	0	0.200
	TY	1	20	<u>16</u>	<u>57</u>	<u>14</u>	0	0.528
	VST	0	2	0	<u>29</u>	<u>50</u>	<u>0</u>	0.617
	VT	0	0	0	1	<u>18</u>	<u>8</u>	0.296
適合率		0.686	0.447	0.393	0.479	0.610	1.000	
F値		0.727	0.487	0.265	0.502	0.614	0.457	

過小になったのは44事例ある。これは時間平均しない強度分類結果である第3表でも推定値が過小になった事例が多かったことを反映している。どの実験においても全体に推定値が過少となる傾向となったのは、元のデータに比較的弱い台風が多く、強い台風が少なかったことが影響していると考えられる。

4. まとめと考察

CNNモデルを用いて、衛星赤外面像における雲パターンによる台風の強度分類を行い、以下の結果が得られた。

- ①訓練・検証・テストデータへの分割をランダムに行った実験では、分類の正解率は80%を超えた。しかし、この実験では訓練・検証・テストデータに自己相関のあるデータが含まれており適切ではなかったと考えられる。
- ②年別にデータを分割した実験では、正解率は52%程度になった。短時間で雲パターンの変化の影響を除去するため、10分毎に得られた強度分類結果を時間平均すると、分類精度はやや向上した。
- ③いずれの実験でも、過大な強度に分類されるものよりは過小な強度カテゴリに分類されるものが多かった。特に、最も強いカテゴリのVTでは見逃しは少なくないが空振りはなかった。これはもとのデータに強い台風の事例が少なかったことが影響していると考えられるため、各カテゴリのデータ数ができるだけ均一になるように調整することで改善される可能性がある。しかしVTは事例が非常に少なく、今回の手法での推定は難しいことが考えられる。
- ④全カテゴリのうちSTSが特に再現率が低い。眼が不明瞭なSTS強度の台風は特徴が捉えにくくTSに分類される傾向が生じることが示唆される。
- ⑤本研究では、人間にはほとんど見分けのつかないような10分ごとの観測による画像でも大きく異なる分類結果が出る事例が見られた。それに対する実用上の対処法としては、時間平均して短時間変動を除去することを示したが、このような変動の起こる要因を調べることは、CNNモデルの精度向上につながると同時に台風の構造と強度に関する新たな知見を得るきっかけとなる可能性もあるだろう。

台風強度に関する議論を行う際は、本研究のように、ベストトラックデータを真値とするのが一般的である。ベストトラックデータ自体がドボラック法への依存が小さくないが、今のところ基本的に各国機関の

ベストトラックデータが最も妥当なものと思われており、それと比較しつつ強度推定誤差を小さくする努力が進められている（例えばChen *et al.* 2019）。木場ほか（1990）は、航空機観測があり衛星への依存が小さい時期のベストトラック最大風速と、ドボラック法のCI数に対応する最大風速との差を調べ、標準偏差を7～12 ktとしている。これはドボラック法の推定では20 kt前後の誤差幅に66%の事例が入ることを示唆している。このようなドボラック法に依存するベストトラックデータに不確実性が生じることを考慮すると、本研究で各強度カテゴリ（第1表に示すように最大風速14～20 ktの幅を持つ）の正解率が52%程度となったのは低すぎることはなく十分に意味があると考えられる。

ところで、最近Chen *et al.* (2019) が本研究よりさらにシンプルな7層のCNNモデルを用いた台風強度推定ではベストトラックデータとの最小二乗誤差が8 kt程度となり、従来の他の台風強度推定手法と比較すると高い精度であったとしている。彼らの手法の特徴は、世界中の台風を対象としたことや強度カテゴリ分類でなく強度推定を行った点に加え、精度向上に関係する工夫として以下の点が挙げられる。

- 静止衛星赤外面像に加え、軌道衛星マイクロ波観測の情報も使用している。
- 台風中心付近の特徴を捉えるため、狭い範囲の画像のみ使用し、また畳み込み層が4層と少なくプーリング層やドロップアウト層を使用しない非常にシンプルなモデルを採用している。
- 基本的には衛星画像を処理するCNNモデルだが、畳み込み層の後の全結合層に、画像データ以外の情報（海域や季節等）も加えている。

このような入力データや処理方法の工夫について、本研究の将来課題として検討を続ける必要がある。

謝辞

本研究で使用した衛星画像は、気象庁予報部予報課アジア気象防災センターに提供していただきました。またアジア気象防災センターの皆様、及び、気象庁技術開発推進本部 実況監視・予測技術開発部会 ガイダンスグループの皆様には、有益な助言をいただきました。さらに、気象大学校（当時）の山田雄二氏には建設的なコメントをいただきました。匿名の査読者の方には改稿に有益なコメントをいただきました。これらの方々に深く感謝します。

参 考 文 献

- Chen, B.-F., B. Chen, H.-T. Lin and R. L. Elsberry, 2019: Estimating tropical cyclone intensity by satellite imagery utilizing convolutional neural networks. *Wea. Forecast.*, **34**, 447-465.
- Dvorak, V. F., 1984: Tropical cyclone intensity analysis using satellite data. NOAA Tech. Rep. NESDIS 11, 47pp.
- He, K., X. Zhang, S. Ren and J. Sun, 2016: Deep residual learning for image recognition. *Proc. IEEE Conf. Comput. Vis. Pattern Recognit.*, 770-778.
- Hochreiter, S. and J. Schmidhuber, 1997: Long short-term memory. *Neural Comput.*, **9**, 1735-1780.
- Ioffe, S. and C. Szegedy, 2015: Batch normalization: Accelerating deep network training by reducing internal covariate shift. *Proc. 32nd Int. Conf. Machine Learn.*, **37**, 448-456.
- 加瀬紘熙, 筆保弘徳, 北本朝展, D. Chen, 吉田龍二, 竹見哲也, 2019: 深層学習を用いた台風強度推定に対する台風の特徴の影響. *天気*, **66**, 51-58.
- Kingma, D. P. and J. L. Ba, 2014: Adam: A method for stochastic optimization. *Proc. Int. Conf. Learn. Represent.*, <https://arxiv.org/abs/1412.6980> (2019.2.2閲覧).
- 木場博之, 萩原武士, 小佐野慎悟, 明石修平, 1990: 台風のCI数と中心気圧および最大風速の関係. *気象庁研究時報*, **42**, 59-67.
- Krizhevsky, A., I. Sutskever and G. E. Hinton, 2012: ImageNet classification with deep convolutional neural networks. *Proc. 25th Int. Conf. Neural Inf. Process Syst.*, 1097-1105.
- Olander, T. L. and C. Velden, 2007: The advanced Dvorak technique: Continued development of an objective scheme to estimate tropical cyclone intensity using geostationary infrared satellite imagery. *Wea. Forecast.*, **22**, 287-298.
- Pradhan, R., R. S. Aygun, M. Maskey, R. Ramachandran and D. J. Cecil, 2018: Tropical cyclone intensity estimation using a deep convolutional neural network. *IEEE Trans. Image Process.*, **27**, 692-702.
- 佐々木 勝, 2015: 客観ドボラック解析. 平成26年度予報技術研修テキスト, 107-108.
- Simonyan, K. and A. Zisserman, 2014: Very deep convolutional networks for large-scale image recognition. *Proc. Int. Conf. Learn. Represent.*, <https://arxiv.org/abs/1409.1556> (2019.5.31閲覧).
- Sony, 2017a: Sony Neural Network Console. [https://dl.sony.com/ja/\(2019.8.20閲覧\)](https://dl.sony.com/ja/(2019.8.20閲覧))
- Sony, 2017b: Neural Network Libraries. [https://nnabla.org/ja/\(2019.8.20閲覧\)](https://nnabla.org/ja/(2019.8.20閲覧))

Classification of Tropical Cyclone Intensity in the Western North Pacific Basin
by Applying a Deep Convolutional Neural Network to Geostationary Satellite Imagery

Gaku DAIKOJI^{*1}, Tomoyuki KAMAKURA^{*2} and Naoko KITABATAKE^{*3}

^{*1} *Meteorological College (Present affiliation: Fukui Meteorological Office).*

^{*2} *Meteorological College (Present affiliation: Administration Department, Japan Meteorological Agency).*

^{*3} *(Corresponding author) Meteorological College, 7-4-81, Asahi-cho, Kashiwa-shi, Chiba 277-0852, Japan.*

(Received 14 June 2019; Accepted 6 November 2019)
