

第5章 今後の展望

5.1 ガイドランスの今後¹

第1章では、2018年現在までの気象庁のガイダンスと海外気象機関のガイダンス、第3章ではガイダンスの開発と運用について、第4章では2018年現在のガイダンスについて解説した。これらを踏まえ、今後のガイダンスについて、現時点で計画していること、将来的なガイダンスの方向性を述べる。

5.1.1 ガイドランスの開発と改良

この項では本原稿執筆時点（2018年3月現在）で計画されているガイダンスの開発及び改良について述べる。なお、計画されている内の統合型ガイダンスについては、次項で別途説明する。

(1) メソアンサンブル予報を使ったガイダンス

メソモデル (MSM) の予測に対して信頼度・不確実性の情報を付加することを目的としたメソアンサンブル予報システム (MEPS) が、本原稿執筆時点で部内試験運用されている。部内試験運用は1日1回 (18 UTC 初期値) 39時間予報を11メンバーで実施しているが、次期スーパーコンピュータシステム導入 (2018年6月予定) 後約1年後までに、1日4回 (00, 06, 12, 18 UTC) と高頻度化するとともに、メンバー数が21に増強される予定である (石田 2017)。このMEPSを入力としたガイダンスを実験的に作成しており、防災情報及び航空気象予報への利用を考えて、地点形式では、気温、風、降雪量 (地点)、視程及び雲ガイダンス、格子形式では、降水量 (平均・最大)、最大降雪量、発雷確率ガイダンス、視程分布予想及び航空悪天 GPV がある (2018年3月現在)。現在の手法はMSMガイダンスと同様の予測式を各メンバーに適用している簡便なものであるが、11個の予測を平均することによって、概ねどのガイダンスもMSMガイダンスより精度が向上することを確認している。

また、より適切な予測の信頼度情報を提供するには、MEPSガイダンスの予測のばらつきから、ガイダンスの予測誤差を見積もる手法を検討する必要がある。調査からは単にMEPSガイダンスの予測のばらつきのみでは適切な予測誤差を見積もるのは難しいと思われ、第1.4節で紹介した米国気象局が運用しているEKDMOSで行っているような統計的な校正手法 (Veenhuis 2013) を検討する必要がある。

(2) 局地モデルを使ったガイダンス

局地モデル (LFM) は、2012年8月から東日本領域で1日8回 (3時間ごと) の運用が開始され、2013年5月から日本領域で1日24回 (1時間ごと) と高頻度の運用が開始された (永戸ほか 2013)。LFMガイダ

スは、精度面でのMSMガイダンス及びLFMの予測値からの優位性、高頻度かつ高分解能のLFMに適したガイダンスの作成方法を検討した後に開発を進めることとしていた。現在、これらの検討を行って降水量や風については予報作業への有効利用が見込めることが確認できつつあり、降水量と風についてLFMガイダンスの開発を進めている。

降水量については、統計的検証及び事例検証からも、大雨についてMSMの予測精度を上回ることが確認されており (原ほか 2015)、かつ平成29年7月九州北部豪雨等の線状降水帯や局地的大雨の事例について、LFMがMSMの予測を大きく改善できる例も多い。このようなことからLFM降水量ガイダンスの作成が求められたため、開発を進め、現在は実験的に運用を行っている状況である。このガイダンスは今までの降水量ガイダンスと異なり、平均降水量ガイダンスではカルマンフィルタ (KF) 等の統計手法は使わずに、LFMの予測降水量をLAF (第2.2節) を適用し、その後頻度バイアス補正のみ行う。また、最大降水量ガイダンスではニューラルネットワーク (NN) や線形重回帰 (MLR) を使わず、高分解能のLFMの降水量予測の分散を利用した手法とする予定である。なお、現時点での検証結果ではこのLFM降水量ガイダンスは、LFMの降水量予測を改善し、かつMSM降水量ガイダンスを上回る精度が確認されている。

LFMはその高い解像度により、局地風の予測精度が高く、防災情報に有効に利用できることがわかってきた。平成28年12月の糸魚川の大規模火災は山越えの南風の強風の影響があったが、LFMはこの強風を概ね予測できていた。LFMの予測特性を最大限に活用することで、有効な風ガイダンスとなるよう開発を進める予定である。

(3) ガイドランスの改良

現在、最大降水量ガイダンスは24時間積算が最大である。近年の特徴として、防災対策のためにより長い時間幅の予測が求められるようになったため、予報現場からは48, 72時間の最大降水量ガイダンスの要望がある。このニーズに対応するために、新たに48, 72時間最大降水量ガイダンスの開発を行う予定である。この際には、現在提供している1, 3, 24時間最大降水量ガイダンスの改良も含めて開発を行う予定である。また、近年、モデルの高解像度化、精緻化等の高度化が進んでいるものの、平均降水量ガイダンスや降水確率ガイダンスの説明変数は、海老原 (1999) から20年近く変更が行われていない。このため、高度化したモデルに適合した説明変数の調査を行ってゆく必要がある。

その他のガイダンスについても随時改良を行う予定であるが、利用者からの問題点の指摘や要望 (ニーズ)

¹ 高田 伸一

開発者の問題意識に基づく改良や乱気流指数や視程分布予想のような新たなガイダンスの提案（シーズ）の両面から開発を進めてゆく予定である。

5.1.2 統合型ガイダンス

前項では、2018年現在 MEPS ガイダンス及び LFM ガイダンスを開発していることを述べた。GSM（全球モデル）ガイダンス及び MSM ガイダンスにこれらのガイダンスを加えると、特性の異なる多くの予測資料が溢れ、予報作業が煩雑になる可能性がある。第 1.4 節で紹介したように、ドイツ気象局の ModelMIX、英国気象局の Optimal blended forecasts、米国気象局の NBM など、他国では複数のガイダンス等を結合し、精度の高い統合型ガイダンスを運用している。今後は、気象庁でも統合型ガイダンスを開発を進める予定である。

統合型ガイダンスには、多くのガイダンスをまとめて予報作業を適切に支援する目的以外に、各ガイダンスの予測を平均化することによって、ガイダンスのランダム誤差を軽減し、精度を向上させる目的もある。ここでは簡単な例を用いて、ガイダンスの平均化によって誤差が軽減されることを示す。ある予測事例 n ($n = 1 \sim N$) の 2 つの異なるガイダンスの予測値を f_{1n}, f_{2n} 、誤差を $\epsilon_{1n}, \epsilon_{2n}$ 、平均二乗誤差を E_1, E_2 、実況を y_n とすると、平均したガイダンスの平均二乗誤差 E は以下のようになる。

$$\begin{aligned} E &= \frac{1}{N} \sum_{n=1}^N \left[\frac{1}{2} (f_{1n} + f_{2n}) - y_n \right]^2 \\ &= \frac{1}{4} \frac{1}{N} \sum_{n=1}^N [(f_{1n} - y_n)^2 + (f_{2n} - y_n)^2 \\ &\quad + 2(f_{1n} - y_n)(f_{2n} - y_n)] \\ &= \frac{1}{4} (E_1 + E_2) + \frac{1}{2} \frac{1}{N} \sum_{n=1}^N \epsilon_{1n} \epsilon_{2n} \end{aligned} \quad (5.1.1)$$

ここで、2 つのガイダンスの平均誤差がゼロであると仮定し（通常ガイダンスの平均誤差はゼロに近い）、その誤差の標本相関係数を ρ とすると、

$$\rho = \frac{1}{N} \sum_{n=1}^N \frac{\epsilon_{1n} \epsilon_{2n}}{\sqrt{E_1 E_2}} \quad (5.1.2)$$

よって、 E は以下のように書ける。

$$E = \frac{1}{4} (E_1 + E_2) + \frac{\rho}{2} \sqrt{E_1 E_2} \quad (5.1.3)$$

仮に 2 つのガイダンス間の平均二乗誤差がほぼ同じで ($E_1 = E_2$)、誤差の相関がない ($\rho = 0$) という理想的な状況では、 $E = E_1/2$ となり、平均化することで誤差が半分になることがわかる。誤差相関が 1 の場合、すなわち、2 つのガイダンスの予測が完全に一致している場合には $E = E_1 = E_2$ となる。このことから、各

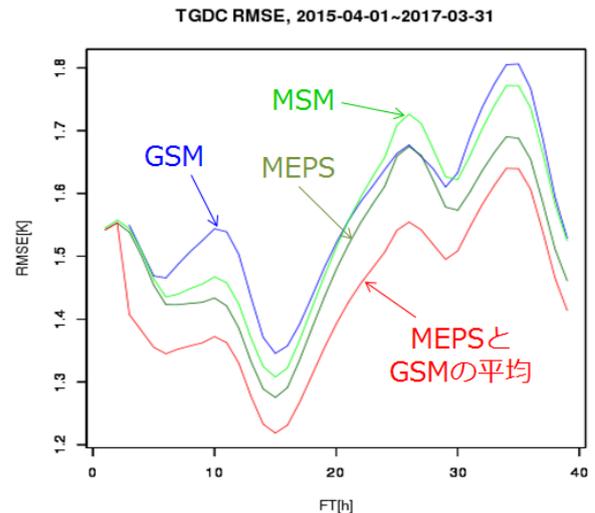


図 5.1.1 MSM, MEPS, GSM の時系列気温ガイダンスの予報時間 (FT) ごとの二乗平均平方根誤差 (RMSE)。MSM, MEPS, GSM 共に 18UTC 初期値で、統計検証期間は 2015 年 4 月 ~2017 年 3 月。緑線は MSM、深緑線は MEPS、青線は GSM、赤線は MEPS と GSM を平均した予測。

ガイダンスの誤差相関がより小さい場合には、平均化することで誤差を軽減できることがわかる²。

通常は誤差相関が 0 になることはないが、なるべく誤差相関の低い予測を平均化することで誤差を減じることができる。具体的にはアンサンブル予報では、各メンバーの予測の誤差相関が高いと考えられ、平均化による誤差軽減の効果は小さいが、異なったモデルでは、誤差相関が低く、誤差軽減の効果大きい。このことを気温ガイダンスを例に図 5.1.1 に示す。現在実験的に運用している MEPS の気温ガイダンスは、アンサンブル平均を用いることで、コントロールである MSM の気温ガイダンスの精度を上回っているが、MEPS 気温ガイダンスと GSM の気温ガイダンスを平均することによって、さらに誤差を大きく軽減できている。図 5.1.2 に MSM 気温ガイダンスと MEPS の各メンバーの気温ガイダンス及び GSM 気温ガイダンス間の誤差の標本相関係数を示した。図からわかるように、MSM と MEPS 気温ガイダンスの誤差相関より、MSM と GSM の誤差相関の方が低いことがわかる。MSM と GSM が別のモデルであるのに対し、MSM と MEPS は基本的には同じモデルのためである。この例のように、ガイダンスの誤差を減らすという観点では、アンサンブル予報だけでなく、異なったモデルを平均化することも効果的である。

(5.1.3) からわかるように、ガイダンスの予測を平均化するには、なるべく両ガイダンスの平均二乗誤差に違いがないものを使い、精度が低いガイダンスを使

² 逆相関 ($\rho < 0$) だと更に誤差 E が小さくなるが、通常、ガイダンス間の誤差相関は負になることはないため、ここでは正で考えている。

われない方がよい。図 5.1.1 には MSM と GSM の気温ガイダンスの RMSE を示したが、その差は 0.1°C 未満であり、そのために平均によって精度が大きく向上したと考えられる。よって、統合型ガイダンスの精度を上げるためには、各ガイダンスの誤差及びガイダンス間の誤差相関を調べてから結合する必要がある。

統合型ガイダンスは予報作業の負担を軽減できること、誤差を減じることができること他に、以下のメリットも考えられる。

- 顕著現象の捕捉率の精度向上
現在までの調査の結果、MEPS のガイダンスは、予測誤差に比べてスプレッド（MEPS のメンバー間の予測値のばらつき）が不足し、顕著現象を捕捉できない場合がある。他のモデルのガイダンスを加えることによって、顕著現象が起こる可能性をより捕捉できる可能性がある。
- モデル更新の悪影響の軽減
多くのガイダンスを結合することによって、モデル更新によるガイダンスの精度低下を軽減できる。これについては、次項で再度説明する。

一方、デメリットとして、全てのガイダンスを結合することによって、1つのモデルとそのガイダンスを一体として行っている予報作業が難しくなる可能性がある。2018年現在の予報作業では GSM、MSM（一部 LFM）のうち1つのモデルをベースにし、気象状況の推移についてのシナリオを組み立てることによって、そのモデルで予測する気象擾乱の位置ずれ、時間ずれ、強度の違いを検討し、それを基にしたガイダンスを修正して予報が作成されているが、この修正作業が行いづらくなる。また、予報官はシナリオに基づく気象解説を行いづらくなるというデメリットもある。これらのデメリットを軽減するには、統合型ガイダンスに最も近いモデルの選択を自動的に行う等、シナリオの組み立てを補助するようなツールを検討する必要がある。

5.1.3 モデル更新への対応と逐次学習・固定型ガイダンスの今後について

ガイダンスがモデル出力を使った統計処理 (MOS) を継続する限り、モデル更新に対応する根本的な解決はモデル更新前にできるだけ多くの再予報³を行い、ガイダンスの予測式を更新することである。実際、季節予報ガイダンスでは大きなモデル更新時には再予報を作成してガイダンスの予測式を更新している。しかし、短期予報用の数値予報モデルにおいては、再予報にはデータ同化を含める必要があることから実施コストが高く、再予報のみで対処することは難しい。他国でも、モデル更新の際にガイダンスのための長期間に再予報を実施しているといった報告はない。このため、第 3.3

³ 現業運用（予定含む）と同一の数値予報モデルを用いて過去の多数事例を対象に実施する予測実験であり、ハインドキャストとも呼ばれる。

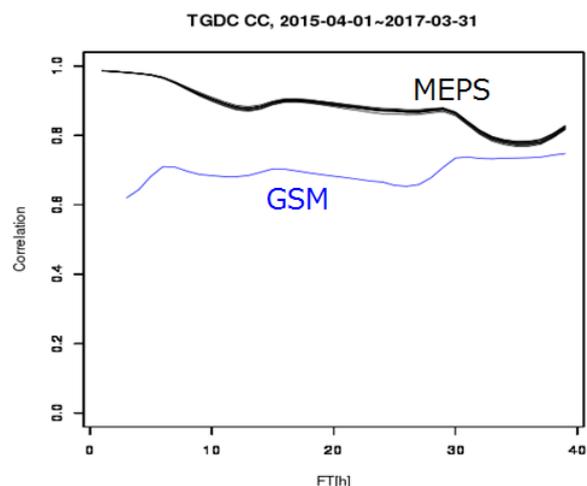


図 5.1.2 MSM 気温ガイダンスと MEPS 気温ガイダンス（各メンバー）、GSM 気温ガイダンスとの予報時間ごとの誤差の標本相関係数。青線は GSM と MSM、黒線は MEPS（各メンバー）と MSM との誤差相関。MEPS の各メンバーと MSM の誤差相関はほぼ同じのため、重なっている。初期時刻、検証期間は図 5.1.1 に同じ。

節で述べたように、モデル更新への対応は各国ともガイダンスの重要な課題であり、逐次学習型のガイダンスの導入、カナダ気象局の UMOS の導入、ガイダンスのバイアスの逐次補正、モデルの業務化試験⁴データの利用などが行われている。気象庁では逐次学習型ガイダンスである KF と NN をほとんどのガイダンスに導入することでモデル更新への対応を行ってきた。ただし、逐次学習型ガイダンスもすぐにモデル更新に対応できるわけではないことは第 3.3 節で述べた通りである。また、KF の開発・運用コストは大きいことも第 3.3 節で述べた。実際に KF、NN、ロジスティック回帰 (LR)、線形重回帰 (MLR) の各種手法を使ったガイダンスを運用してきた経験からも、LR や MLR に比べて KF と NN の開発・運用コストはかなり高い。今後、統合型ガイダンスの開発やガイダンスの開発・改良を効率よく進めてゆく場合には、この高いコストが障害となる。ドイツ気象局や米国気象局のように多くのモデルのガイダンス、多くの要素のガイダンスを運用し、かつ統合型ガイダンスを作成している気象局では、KF を導入せず、全て MLR か LR のみを利用していることも押さえておくべき重要なポイントである。また、警報・注意報向けのガイダンスの精度向上を行ってゆくには、頻度の少ない現象を対象とするため、第 1.2 節で述べたように逐次的な統計処理では後追的な予測となってしまう。これらを考えると、気象庁でも降水量、視程などについて、逐次学習型から一括学習型に戻すことを検討する時期に来ていると考えられる。

⁴ モデルの更新や新規モデルの運用開始において、業務化を行うかどうかを判断するために過去期間において実施する試験。

この一括学習型に戻す際に同時に検討すべきポイントは、前項で述べた統合型ガイダンスである。統合型ガイダンスでは、1つのモデルに頼らないため、モデル更新で精度が落ちるガイダンスがあっても、そのガイダンスの結合の重みを下げることによって、精度の低下を最小限にすることができる。現実化前に実施した業務化実験等のデータを合わせて、モデル更新後1~2年程度経過すればガイダンスの予測式が更新できるので、いったん劣化した新モデルのガイダンスの精度が向上し、結合の重みを上げれば統合型ガイダンスの精度の向上が可能である。つまり、モデル更新による悪影響を最小限に抑えつつ、タイムラグを持ってモデルの改善を統合型ガイダンスの改善に反映させる方法である。実際の運用を行う場合には、結合の重みの上げ下げ、次のモデル更新のタイミング等を検討する必要があるが、今後のモデル更新に対応できる有効な手法の一つとなると思われる。

なお、第3.4節で述べたように、逐次学習型ガイダンスは、観測所の移設・新設時の対応が比較的スムーズにできるメリットがある。頻繁にあるアメダスの移設・新設において、KFを使った気温ガイダンスは約2週間、風ガイダンスは数か月で自動的に移設・新設場の特性に馴染んでゆく。この点を考えると、アメダスの観測を目的変数としている気温及び風ガイダンスではKFが有効に働いており、KFの手法の継続が必要と思われる。英国気象局でも気温、湿度及び風ガイダンスにはKFを利用している。

5.1.4 新たなガイダンス技術の取り入れ

現在、深層学習と呼ばれるディープニューラルネットワーク(DNN)の技術が発展し、画像認識や音声認識で今までの機械学習技術を大きく超える高い能力が示されている。次節で紹介するように、DNNを気象予測に利用した調査・開発も行われている。ここでは、今後のガイダンスへの新たな技術の利用可能性について簡単に述べる。

まず、今まで説明変数は1点の数値予報格子点値(GPV)または周辺のGPVを内挿または平均処理などを行って利用していたが、DNNでは広範囲のGPVをそのまま説明変数とし、GPVの平面的・立体的な気圧や暖湿流等のパターンから、数値予報のバイアスを補正できる可能性がある。例えば、気温ガイダンスでは、放射冷却が起きて大外れしそうな気圧パターンや鉛直プロファイルのパターン、降水で大外れしそうな降水予測の広がりパターンから最適な補正ができる可能性がある。つまり、今まで行うことができなかったパターン認識による層別化を導入できる可能性がある。

前述した統合型ガイダンスにおいても、多くのガイダンス・モデルの予測を入力とし、適切な組み合わせを自動的に高精度に行うことができる可能性がある。特にどのモデルがどのパターンが得意かを判定しなが

ら結合できれば、大きく精度向上できる可能性もある。しかしながら、深層学習のガイダンスへの有効性については未知な部分も多く、めったに発生しない顕著現象に対してどの程度の予測精度が可能か、モデル更新に対して安定した予測が出せるか等、DNNを導入するコストに見合った有効性があるかを十分検討しておく必要がある。

また、深層学習といった最新の機械学習だけではなく、長年にわたって他の分野で使われてきた手法も検討する必要がある。第2.10節では、ランダムフォレスト、ブースティングなどの各種の機械学習技術を紹介した。今後の統合型ガイダンスやガイダンスの改良を進めるにあたって、最新の技術だけに偏らず、長年にわたって有効性が確認されている手法も検討する必要がある。

参考文献

- 海老原智, 1999: 降水ガイダンスの改良と検証. 平成11年度数値予報研修テキスト, 気象庁予報部, 23-33.
- 永戸久喜, 原旅人, 倉橋永, 2013: 日本域拡張・高頻度化された局地モデルの特性. 平成25年度数値予報研修テキスト, 気象庁予報部, 18-41.
- 原旅人, 伊藤享洋, 松林健吾, 2015: asucaが導入された局地数値予報システムの特性. 平成27年度数値予報研修テキスト, 気象庁予報部, 9-23.
- 石田純一, 2017: 数値予報. 平成29年度数値予報研修テキスト, 気象庁予報部, 114-117.
- Veenhuis, B. A., 2013: Spread Calibration of Ensemble MOS Forecasts. *Mon. Wea. Rev.*, **141**, 2467-2482.

5.2 ディープニューラルネットワーク¹

5.2.1 はじめに

ディープニューラルネットワーク (DNN²) とは、多層のニューラルネットワークによる機械学習手法である。第 2.6.1 項でも述べたように、DNN は、2012 年に大規模画像認識のコンペティションである ILSVRC で Hinton からカナダのトロント大学のグループが、後に AlexNet (Krizhevsky et al. 2012) と呼ばれる DNN を用いて圧勝したことをきっかけに大きな注目を集め、2018 年現在もそのブーム³が続いている。この間、DNN の更なる多層化や新しい手法の開発などが進み、VGG (Simonyan and Zisserman 2014) や GoogLeNet (Szegedy et al. 2015), ResNet (He et al. 2016) と呼ばれるネットワークが次々に発表され、それまでの認識性能の記録を塗り替えてきている。

DNN は、画像認識の分野をはじめとして、音声認識、自然言語処理の分野で大きな成果をあげているが、近年では気象予測の分野でもその適用例が報告されている。そこで本節では、まず第 5.2.2 項で気象庁のガイダンスで用いているニューラルネットワークと DNN の違いを簡単に説明する。次に第 5.2.3 項と第 5.2.4 項で、気象予測の分野に DNN を適用した例を紹介する。最後に、第 5.2.5 項で、これら適用例の気象庁ガイダンスへの応用の可能性を検討し本項のまとめとする。なお、前提となるニューラルネットワークについては、第 2.6 節を参照されたい。

5.2.2 気象庁のガイダンスに用いるニューラルネットワークと DNN の違い

現在の気象庁のガイダンスに用いるニューラルネットワークと DNN の違いは、その中間層の数の違い、また、その中間層を多くしたニューラルネットワークを適切に学習するために必要な技術の有無の違いと言える。第 2.6.1 項でも述べたように、現在の気象庁のガイダンスに用いているニューラルネットワークは、長いニューラルネットワークの歴史の中で第 2 世代に当たる技術を用いた 3 層の順伝播型ネットワーク (第 2.6.4 項参照) である。第 2 世代ニューラルネットワークは、誤差逆伝播法の再発見を機にブームが起き、気象庁のガイダンスでも数値予報モデルの更新に伴う予測特性の変化に追従することが可能になる手法として、カルマンフィルタと並んで多くのガイダンスに導入された。しかし、当時の技術で中間層を多層にしたネットワークの学習を行う場合、その学習時に勾配消失問題 (第

2.6.6 項 (2) 参照) が発生してしまうために学習が適切に行えず、画像を対象とする畳み込みニューラルネットワーク⁴(CNN⁵) といった一部の例外を除いて、ネットワークを多層にすることが困難であった⁶。ここにブレイクスルーをもたらしたのが、先に述べた Hinton の研究である制約ボルツマンマシン (Hinton et al. 2006) と呼ばれる単層のネットワークや、Bengio らが示した自己符号化器⁷(AE⁸, Bengio et al. (2006)) と呼ばれる手法である。これらを用いることで、多層のネットワークを入力層に近い側から順番に学習する事前学習⁹を行い、この事前学習によって得た重みを初期値に使うことで、DNN であっても適切に学習できることが明らかになった。その後、前述した画像認識のコンペティションで Hinton らのグループが圧勝したのをきっかけに、DNN の有効性が広く知られるようになり、現在までネットワークの多層化、手法の多様化が進んでいる。しかし、この大きなブレイクスルーをもたらした Hinton や Bengio らが提案した事前学習の手法ですら、DNN を学習するために欠かせない技術では無くなりつつある。それは、次々と提案される新たな学習手法やネットワークに与えるパラメータの初期設定値の与え方によっては、より簡単に勾配消失問題に対応できることが分かってきたためであり、DNN の技術は日々新しくなっているとと言える。

このように、現在の気象庁ガイダンスに用いられるニューラルネットワークと DNN は、どちらもニューラルネットワークという機械学習手法に括られるものの、そのネットワークの構造や学習手法などの技術的な面での多くの違いがある。

5.2.3 CNN と LSTM を組み合わせた降水量予測

Shi et al. (2015) は、CNN と LSTM¹⁰ (第 2.6.4 項参照) を組み合わせた畳み込み LSTM (ConvLSTM) を用いた降水量のナウキャスト手法を提案し、既存の予測手法を上回る予測精度が得られることを示した。

Shi らは、香港天文台が開発した最新の降水ナウキャストである ROVER¹¹ (Woo and Wong 2014) の問題

¹ 白山 洋平

² Deep Neural Network

³ Hinton らの研究によって勾配消失問題に対応できるようになったことのほかに、GPU などによって計算機性能が飛躍的に向上したこと、学習に用いる大量の画像や映像データをインターネット上などから集めることが可能になってきたこともブームの要因である。

⁴ 畳み込み層とプーリング層と呼ばれる 2 種類の層を有する順伝搬型ニューラルネットワークで画像認識に用いられる。

⁵ Convolutional Neural Network

⁶ 画像を対象とした CNN については、80 年代後半に 5 層のネットワークによる予測が成功されている (LeCun et al. 1989)

⁷ 3 層ニューラルネットワークにおいて、入力層と出力層に同じデータを用いた学習を行う手法。

⁸ autoencoder

⁹ まず入力層、中間層の 1 層目、仮の出力層の 3 層で出力層と入力層が一致するように学習を行う。次に、この仮の出力層を取り除き、元のネットワークの 2 層目の中間層を積み上げ、前回の学習した時の中間層を入力層と見なした 3 層でもう 1 度学習する、といった学習を元のネットワークの分だけ繰り返して DNN を学習する手法。

¹⁰ Long Short-Term Memory

¹¹ Real-time Optical flow by Variational methods for

点として、大気場の流れの推定処理とレーダーエコーの外挿処理が分離しており、そのことが良い予測精度を得るためのモデルパラメータの決定を困難にしていることを挙げ、この問題は機械学習の観点から解決できる可能性があるとして述べている。彼らは、降水のノウキャストは過去のレーダー画像の時系列データを入力として、ある固定された期間の将来のレーダー画像の時系列（予測する時刻数は通常は1より大きい）を予測する時空間系列データの予測問題であると考え、近年のDNNの発展、特に時系列データを適切に扱えるリカレントニューラルネットワーク（RNN¹²、第2.6.4項参照）や通常のRNNよりも長い記憶を扱えるLSTMがこの問題に対処するために有用であると考えた。DNNによるアプローチでは、適切なモデルと学習用の十分な量のデータが必要であるが、降水ノウキャストであればデータの要件は満たすため、必要なのは適切なモデルとなる。Shiらは、モデルとして3つの先行研究を例に挙げている。1つはSutskever et al. (2014)による入出力データがともに時系列データである問題に対する学習のための一般的なフレームワーク、後の2つはDNNモデルで映像データの先のフレームを予測する研究（Ranzato et al. 2014; Srivastava et al. 2015）である。ただしShiらは、Ranzato et al. (2014)は予測する時刻数が1時刻であったり、CNNの畳み込み計算の範囲が制限されていて空間方向の相関の考慮が不十分なことを、Srivastava et al. (2015)はLSTMを用いた複数時刻の予測をするものの、その計算が畳み込み計算でないため空間方向の相関を考慮していないことを指摘している。Shiらは、これらの先行研究を念頭に、未来の複数時刻を予測し、かつLSTMの計算に畳み込み計算を導入して空間方向の相関も考慮できるようにしたConvLSTMを提案した。

図 5.2.1 及び図 5.2.2 は、Shiらが提案したConvLSTMによる降水量予測の検証結果と実際の予測例を、HKOのノウキャスト手法であるROVERやSrivastava et al. (2015)が提案した手法と比較した結果である。このConvLSTMによる実験では、モデルとしてConvLSTMユニットを2層を持つDNNを用いている。また学習用のデータには、2011年から2013年の3年間のレーダーエコーデータから上位97日の降水日を抽出して用いている¹³このデータは、前処理として、グレースケールへの変換、領域の切り出し、6分毎の240枚/日のデータセットへと整理などを行い、訓練・評価・テストの3セットに分割して実験に用いられる。図 5.2.1 は、左上から各予測と観測の相関係数、0.5 mm/hのスレットスコア、誤検出率、捕捉率である。いずれも赤線で示されたConvLSTMが

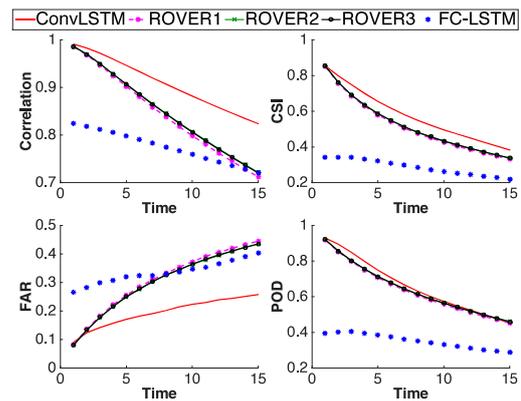


図 5.2.1 Shi et al. (2015) の Figure 7。左上から各予測と観測との相関係数、0.5 mm/3hのスレットスコア（図中はCSI）、誤検出率（図中はFAR）、捕捉率（図中はPOD）。赤線はConvLSTMによる予測、青線はSrivastava et al. (2015)が提案したLSTMを用いた手法による予測、残りは既存手法であるROVERによる予測で、1~3はROVERの設定を変更した3通りの実験結果を表している。

最も高精度であることを示している。Shiらは、このConvLSTMの改善について、ConvLSTMは領域の境界付近をうまく予測できていること、またConvLSTMではデータセット内の複雑な時空間パターンを学習できることを理由に挙げている。図 5.2.2 は、実際の予測例で上段から順に、ConvLSTMやROVERに与える入力のレーダー画像、入力のレーダー画像に続くレーダー画像（つまり、予測に対する真値）、ConvLSTMによる予測結果、ROVERによる予測結果である。この予測結果から、ConvLSTMでは外挿によって予測を行うROVERでは予測し得ない領域の外側から流れてくるエコーを予測していることが分かる。一方で、ROVERは時間が進んでもシャープな予測をしているが、ConvLSTMはぼやけた予測になっている。Shiらは、このROVERのシャープな予測は多くの空振りを引き起こし、ConvLSTMより精度が低くなる原因になっていること、またConvLSTMのぼやけた予測は、予測の後半で領域全体をシャープに、また精度良く予測することはほとんど不可能であるという、降水のノウキャスト固有の不確実性による誤差を緩和することができていると述べている。このようにShiらは、これまでは機械学習の恩恵を受けていなかった降水のノウキャストにDNNを上手く適用し、既存の予測手法を上回る予測精度を達成した。

林ほか(2016)は、Shiらの手法は過去の降水量のみを入力とした将来の降水量予測であるが、実際の降水は雲の厚さや地形、風向きといった複数の要因に依存して変化することを指摘し、過去の降水量に加えてこれら複数の要因を入力とした予測手法を提案している。林らは、この提案手法の評価のために、降水量データとしてShiらと同じ気象レーダーによる観測データを、降水量以外の要因として気象衛星ひまわり7号の雲観測データをそれぞれ120×120のピクセルのグレース

Echoes of Radar

¹² Recurrent Neural Network

¹³ Shiらは、ノウキャストのターゲットは降水量予測であるため、無降水の日の実験には用いていない。

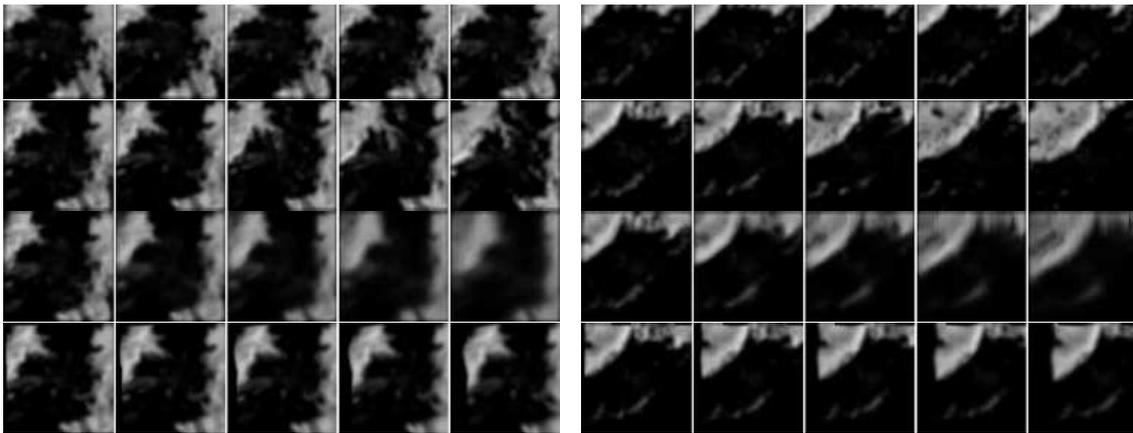


図 5.2.2 Shi et al. (2015) の Figure 8。実際の降水のナウキャスト例（左右で 2 事例分）。2 事例とも上段から順に、ConvLSTM や ROVER に与える入力のリダー画像、入力のリダー画像に続くリダー画像（つまり、予測に対する真値）、ConvLSTM による予測結果、ROVER による予測結果で、それぞれ左から右に時間が進んでいる。

ケールのデータに変換、これらデータを RGB 画像のような多チャンネルのデータとして扱った ConvLSTM を構築し、Shi らの提案した過去の降水量データのみを入力データに用いた予測手法よりも精度が向上することを示している。

5.2.4 気象観測データを用いた翌日の降水量予測

Hernández et al. (2016) は、AE と多層パーセプトロン¹⁴(MLP¹⁵) を組み合わせた DNN と前日までの気象観測データを用いて翌日の日降水量予測を行い、AE を用いない MLP のみによる予測やいくつかの先行研究が提案しているニューラルネットワークによる予測精度を上回ることを示した。

彼らが構築したネットワークでは、まず用意した前日までの降水量、気温、気圧などの気象観測データを AE を用いてよりコンパクトな表現に変換する。AE は、入力層、中間層（入力層よりユニット数を少なくする）、出力層（入力層とユニット数を同じにする）の 3 層で構成され、ネットワークの出力値が入力値に近づくように学習することで、真ん中の中間層に入力値から非線形変換されたより次元の小さいコンパクトな特徴量を抽出する手法である。この隠れ層からの出力値を MLP の入力値とすることで、MLP が過学習しにくくなり、かつ精度が改善されると Hernandez らは述べている。なお、これら AE や MLP の学習回数や学習率、それぞれの隠れ層のユニット数などのパラメータは、いくつかの候補値の組み合わせを総当たりすることで最適な設定を決定している。また、Hernandez らはこの構築したネットワークの実際の予測例を示し、大雨の日は非常に良い精度で予測できている一方で、日降水量が 20 mm 未満の日は予測が正確ではなく、これら雨量

の少ない日の予測精度の改善が今後の課題であると述べている。

5.2.5 まとめ

本項では、はじめに気象庁のガイダンスに用いているニューラルネットワークと DNN の違いについて説明し、さらに DNN の気象予測の分野への応用例をいくつか紹介した。

第 5.2.3 項で初めに紹介した、Shi らの過去の降水量のみを入力とした ConvLSTM は、そのままでは降水のナウキャスト手法であるため本報告が対象とするガイダンス手法ではない。また、ナウキャスト手法としても、予測時間の後半ではばやけた降水予測となっており、このままでは大雨の予測といった防災目的への利用は難しいと考えられる。林らが提案した ConvLSTM に複数の要因を取り込む手法はガイダンスへの応用が期待できる。例えば、入力が多チャンネルデータに数値予報モデルの降水量や高度場のデータを、教師データに降水量ガイダンスの目的変数を与えたネットワークを学習することで、LSTM によって対象時刻までの入力データを、CNN によって周囲の格子の気象要素を考慮した統計的な補正を行うニューラルネットワークの作成が行えると考えられ、従来にはない新しいアプローチのガイダンス作成手法となりうるだろう。また、第 5.2.4 項で紹介した、気象観測データのみを用いた翌日の降水量予測は、一般的には数値予報を用いた場合に比べて予測精度は劣るものと想像されるが、多様な入力データからデータの特徴を良く表す量（特徴量）を効率的に抽出しており、この手法はニューラルネットワークを用いたガイダンスに限らず、多くの既存のガイダンスにも応用可能な技術であると考えられる。このように、DNN はガイダンス開発に新たなアプローチを与えるとともに、第 2.6.9 項でも述べたように、現在気象庁が運用しているガイダンスに、DNN に用いられる新しい技術を取り込んでいくことで、気象

¹⁴ 順伝播型ニューラルネットワークと同じだが、本節では Hernández et al. (2016) にあわせて多層パーセプトロンと記す。

¹⁵ multilayer perceptron

庁ガイダンスの予測精度の向上にも資すると言えるだろう。

第 5.2.1 項や第 5.2.2 項で述べた通り、DNN の技術は日進月歩であり、新しい技術が次々に発表されている。引き続き最新の DNN の情報収集に努め、既存のガイダンスの精度向上に繋がる技術開発に結びつけていきたい。

参考文献

- Bengio, Y., P. Lamblin, D. Popovici, and H. Larochelle, 2006: Greedy Layer-Wise Training of Deep Networks. *Proceedings of the 19th International Conference on Neural Informatin Processing Systems*, 153–160.
- 林政行, R. Hadfi, 伊藤孝行, 2016: 深層学習を用いたマルチモーダル学習による降水量予測. *情報処理学会第 78 回全国大会論文集*, 2016(1), 369–370.
- He, K., X. Zhang, S. Ren, and J. Sun, 2016: Deep Residual Learning for Image Recognition. *The IEEE Conference on Computer Vision and Pattern Recognition*, 770–778.
- Hernández, E., V. Sanchez-Anguix, V. Julian, J. Palanca, and N. Duque, 2016: Rainfall prediction: A Deep Learning approach. *Proceedings of the 11th International Conference on Hybrid Artificial Intelligent Systems*, 151–162.
- Hinton, G.E., S. Osindero, and Y.W. Teh, 2006: A fast learning algorithm for deep belief nets. *Neural Computation*, **18**, 1527–1554.
- Krizhevsky, A., I. Sutskever, and G.H. Hinton, 2012: ImageNet Classification with Deep Convolutional Neural Networks. *Proceedings of the 25th International Conference on Neural Informatin Processing Systems*, 1097–1105.
- LeCun, Y., B. Boser, J.S. Denker, D. Henderson, R.E. Howard, W. Hubbard, and L.D. Jackel, 1989: Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Computation*, **1**, 541–551.
- Ranzato, M., A. Szlam, J. Bruna, M. Mathieu, R. Collobert, and S. Chopra, 2014: VIDEO(LANGUAGE) MODELING: A BASELINE FOR GENERATIVE MODELS OF NATURAL VIDEOS. *arXiv preprint arXiv:1412.6604*.
- Shi, X., Z. Chen, H. Wang, D. Yeung, W. Wong, and W. Woo, 2015: Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting. *arXiv preprint arXiv:1506.04214*.
- Simonyan, K. and A. Zisserman, 2014: VERY DEEP CONVOLUTIONAL NETWORKS FOR LARGE-SCALE IMAGE RECOGNITION. *arXiv preprint arXiv:1409.1556*.
- Srivastava, N., E. Mansimov, and R. Salakhudinov, 2015: Unsupervised Learning of Video Representations using LSTMs. *Proceedings of the 32nd International Conference on Machine Learning*, **37**, 843–852.
- Sutskever, I., O. Vinyals, and Q. V. Le, 2014: Sequence to Sequence Learning with Neural Networks. *Proceedings of the 27th International Conference on Neural Informatin Processing Systems*, **2**, 3104–3112.
- Szegedy, C., W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, 2015: Going deeper with convolutions. *The IEEE Conference on Computer Vision and Pattern Recognition*, 1–9.
- Woo, W.C. and W.K. Wong, 2014: Application of Optical Flow Techniques to Rainfall Nowcasting. *the 27th Conference on Severe Local Storms*.

5.3 ガイダンスグループ¹

2018年現在、気象庁内のさまざまな課室や施設等機関で統計や機械学習を利用したプロダクトの開発や調査が行われている。また、ディープニューラルネットワークなどの新しい技術の登場により、気象庁でも新たな手法を利用したガイダンスの開発が求められている。そこで、各課室が持つツールやノウハウを共有することによってプロダクトの開発と改良を促進するとともに、新しい技術を互いに習得することによって新しいプロダクトの開発を進めることを目的として、平成29年度より気象庁技術開発推進本部の実況監視・予測技術開発部会の下にガイダンスグループが立ち上げられた。過去にも、予報部内に平成9～16年にガイダンスワーキンググループが立ち上げられ、ガイダンスの改良・開発の促進に寄与したが、ガイダンスグループは庁内を横断したグループである点が異なる。

平成29年度の主な参加メンバーは、表5.3.1となっている。ガイダンスグループへの付託事項は、

- ガイダンス等統計的プロダクトの作成手法とノウハウを共有し各課プロダクトの高度化を推進すること
- 機械学習や人工知能などの最新技術の動向を調査し業務への利用可能性を検討すること

となっており、前者に関しては、

1. 各メンバーの担当プロダクトで使っている統計・機械学習技術の共有
2. 統計・機械学習技術の基礎知識の習得
3. 関連ツールの紹介
4. 外国の論文やプロダクトの紹介
5. 担当プロダクトの改良調査の報告

などを行っている。特にメソアンサンブルや全球アンサンブルのアンサンブル予報を使った応用技術の高度

化に力点を置いている。

後者に関しては、ディープニューラルネットワークを使った調査結果の共有及びツールの共有を行っており、実際に業務への利用調査も実施している。また、若手を中心に基礎的な理論と技術の習得を目的とした活動も行っている。今後は、部外の機械学習の専門家との共同研究などの連携を行ってゆくことを検討している。

表 5.3.1 ガイダンスグループ構成メンバー（平成29年度）。以下のメンバーの他に情報通信課及び気象大学校からも参加。

参加メンバー	関連担当業務
数値予報課・アプリケーション班	天気予報ガイダンス、航空気象予報ガイダンス、航空悪天 GPV、週間予報ガイダンス
予報課・週間予報係	週間予報ガイダンス
気候情報課・季節予報係	季節予報ガイダンス
予報課・アジア太平洋気象防災センター	台風予報ガイダンス
予報課・開発班	雷ナウキャスト
航空予報室	航空気象予報プロダクト
観測システム運用室	推計気象分布
海洋気象情報室	海氷解析
気象衛星センター	積乱雲情報プロダクト

¹ 高田 伸一