機械学習による局地気象予報の試み Innovative approach for prediction of local weather using machine learning

吉兼 隆生^{*1} Takao Yoshikane 芳村 圭^{*1} Kei Yoshimura

*1 東京大学生産技術研究所 Institute of Industrial Science, The University of Tokyo

Local weather forecasting is technically very difficult because the mechanisms are still unknown and there are a lot of errors with numerical model. In this study, we found some close relations between the observed precipitation and the simulated precipitation distribution patterns in a local area, and then we have applied the relations to predict the local precipitation using machine learning (A regression model of support vector machine). As the result, the model biases were drastically reduced by the innovative approach. It is expected that this approach is useful to improve the performance of the local weather forecast.

1. はじめに

1.1 局地気象予測の難しさ

気象観測や数値シミュレーションを行う以前は,各地域において経験的に知られていた天気の変化パターンにより天気を予測してきた[1].「観天望気」とも呼ばれており,現在も船舶の出航の判断などに利用されている[2][3][4].

現在は、気象衛星を含む気象観測データが充実し、スパコン を用いた数値予報の精度も向上している.しかし、いつ、どこで、 どのくらいの降水があるのかなど、地域詳細な気象予報につい ては十分な精度が得られていない.理由の1つとして、短時間 で大きく変化するメソスケール現象(数百キロ以下の規模を持つ 気象システム)の予測が難しいことが挙げられる.降水は個々の 積雲対流によりもたらされるが、それらの発生発達は地形や風 の影響を受けて複雑に変化し、さらには複数の積雲対流による メソ対流システムを構成することもある[5].このような個々の積雲 対流の形成プロセスや細かい地形の影響を含めて予測を行う には、数値モデルの高解像度化が不可欠だが、様々な技術的 要因から現状では実現が難しい.さらに初期値依存性(カオス 現象)の影響も考慮する必要がある.また、メソスケール現象の 形成メカニズムについては未解明な点も多く、現象の複雑さが 予測を一層困難にしている.

船乗りにとっては、急激な天気の変化がいつ起こるのか把握 することは安全面で極めて重要である[2]. 観天望気は、現在の 科学的知見や技術では対応できない局地の天気を予測するた めに必要とされている.

1.2 局地気象予測における機械学習の可能性

観天望気を重要視しているのは、前兆現象として限定された 地域内で何らかのパターン(規則性)が存在しているためと考え られる.そのパターンがどのようなものなのか認識できれば、局 地気象予測に活用出来るだろう.近年、機械学習を用いて現在 の大気の状態から数時間先を予測する手法が開発されてきた [6][7][8].観測された降水分布から数時間先の降水を予測する ものや上空の気温状況など降水に関係する複数の要素を取り 入れて学習させて降水予測を行うものなど様々だが、いずれも 時間の経過とともに精度が大きく低下する.メソスケール現象は

連絡先: 吉兼隆生, 東京大学生産技術研究所, 277-8574 千 葉県柏市柏の葉 5-1-5, E-mail takao-y@iis.utokyo.ac.jp 時空間スケールが小さく,時間の経過とともに大きく変化するため,同じような大気の状態であっても結果が大きく異なる.メソスケール気象の特性が,機械学習でのパターン認識を困難にしていると推測される.

数値予報は、上述の手法やレーダ降雨域の移動などから降 水予測を行うナウキャストと比較して長時間の精度の高い予測 が期待される[8][9][10]. 数値モデルはメソスケール現象の発 生・発達・衰退などの過程を扱える他, データ同化手法により観 測値からの誤差を改善できる.一方で,モデルの不完全さ(各 過程や解像度など)による誤差を避けることは難しい. 図1に気 象庁の数値予測情報の1つであるメソスケール客観解析値[11] とレーダーアメダス[12]による 2015 年1月の月平均降水量分布 である.レーダーアメダスでは日本海沿岸地域の比較的標高の 低い平野部で大きな降水が見られるが,数値モデルでは平野 部で少なく山岳地域で多い傾向が見られる.冬季の北西季節 風が山岳風上側で強制されて上昇流となり、日本海沿岸地域 に沿って断続的に降水が形成される. 大まかな降水特性は数 値モデルでも再現されているが,顕著な降水分布の誤差(モデ ルバイアス)が確認できる.バイアス原因として,解像度が粗い (格子間隔 5km)こと,降水過程などの物理プロセスが適切でな いことが推測される[13][14]. それ以外にもモデル座標系による 計算誤差[15]も想定されるため、単に数値モデルを高解像度化 しただけでバイアスが改善するとは考え難い.



図1 2015 年1月の月平均降水量分布. レーダーアメダス(a)と 気象庁メソスケール客観解析値(MSMGPV) (b).

一方で、ある程度広い範囲の領域平均降水量の時間変化を 見るとモデルと観測で大きな違いはなく、モデルは実際の降水 特性を良く再現していると判断できる(図2).モデルバイアスに より降水分布は実際と大きく異なるものの、冬季季節風に対応し た降水特性(パターン)を再現しているのかもしれない.



図2 Region 1(図1)での観測とモデル(MSMGPV)の領域平均 降水量の時間変化(a)と時間降水量の関係(b).

仮にモデルと観測の降水分布パターン特性が対応している ならば、パターン認識により局所的な降水予測が可能になると 想定される.本研究では、モデルで再現された降水パターンを 利用して機械学習による局所降水予測について調査した.

2. 方法

機械学習にはサポートベクターマシンの回帰モデル(SVR)を 用いた. SVR は統計解析ソフト R のパッケージソフトウェアであ る e1071 を利用した[16].

入力にはレーダーアメダスの3時間ごとの観測降水(0.06 度 四方に補正したもの)と気象庁メソスケール客観解析値 (MSMGPV)のモデル降水を用いた.学習期間は,テスト期間 (2015 年 1 月)を除く2014 年~2017 年までの冬季(12 月~2 月)とした.0.06 度四方(約 5km 四方)の格子に対して,その格 子での観測降水と格子を中心とした40x30 格子の領域でのモ デル降水分布の関係性をSVMにより学習させた.(図3)



図3 SVM 入力データの設定.

3. 予測結果

SVM(SVR)による 2015 年 1 月の月平均降水量分布を図 4b に示す.降水分布特性は観測(図 4a)とよく似ており,定量的に

もよく再現している. 図 5 は Point A(図1)における降水量(3時 間ごと)の時系列を示す.降水の起こるタイミングはよく一致して おり(相関係数:0.75),観測降水との関係性が高いことを示して いる.これらの結果から,モデル降水の分布パターンと実際の 降水(観測値)との間に強い関係性があることが分かる.

地形に対応した降水は風速場に強く影響している. 実際に日 本海側山岳域で起こる降水は、冬季季節風が主要因である. モデルの分布パターンが風速場によるならば、モデルの降水分 布パターンの代わりに風速場を特徴ベクトルとして採用しても同 様に再現すると想定される.風速場の特徴ベクトルとして、 40x30grid の風速分布(東西,南北成分)をそのまま与えた場合 (Case 1)と,領域平均した風速場を与えた場合(Case 2)で,再 現性を調査した(図 4d,e). Case 1 では, 降水分布パターンを与 えた場合とほぼ同じ分布となったが(図 4d), Case 2 では全体で 過小評価であり,再現性は良くなかった(図 4e).領域平均した 風速場でも季節風の強弱が反映されているのだが、局所的な 降水特性は大規模場との関係よりも地域詳細な風速分布パタ ーンとの関係の方が強いことを示している.また、Casel では降 水量の時間変化(図 5b)が,特徴ベクトルにモデル降水分布を 与えた場合(図 5a)と同様に再現されているが、Case 2 では、時 間変動パターンの再現性が低く、変化のめりはりがあまり見られ ない(図 5c).





図4 2015 年1月の月平均降水量分布. 観測(レーダーアメダス)(a), モデル降水分布を特徴ベクトルとした SVR による予測 値(b), モデル(MSMGPV)(c), 地上風を特徴ベクトルとした予 測(d), 領域平均地上風を特徴ベクトルとした予測(e).



図5 Point A(図1)での降水量の時間変化.特徴ベクトルは、降水分布(a),地上風分布(b),領域平均地上風(c).

4. 考察

4.1 観測とモデルの関係

SVR による予測結果は,観測された降水は,領域内部の分 布の違い(パターン)により大きな影響を受けることを示している. つまり,局地気象予測,特に局地降水予測の場合は,季節風 や高低気圧などの大規模スケールの気象現象との関係だけで なく,Region 1(図1)内部で形成される中小規模スケールの気 象現象との関係性も無視できないことを意味する.複雑な地形 の影響を強く受ける地域であれば,それに対応した気象現象と の関係性を注意深く観測する必要があるだろう.従って,数値 モデルバイアスの補正が可能であるのは,中小規模擾乱の再 現が可能である高解像度のモデルで,降水分布や地上風分布 の特性が十分に再現されている場合に限定されるだろう.図4と 図5に示された SVR 予測値の高いパフォーマンスは,数値モ デル(MSMGPV)による局地気象特性の再現精度が極めて優 れていることを示している.

モデルで再現された気象要素と観測値との関係性を用いて バイアスを補正する手法として、「統計ダウンスケーリング」が一 般に用いられる[17].この手法は、解像度の粗い(格子間隔 50km 以上)の温暖化予測モデルの結果を実用的な地域スケー ルの温暖化予測情報に補正するためによく使われる.しかし、 基本的には大規模スケールの気象現象との関係のみで補正さ れているため、メソスケール気象現象と深い関係にある局地降 水予測では大きな誤差が生じることも懸念されている[17].本研 究で用いた手法を適用することにより、従来のダウンスケーリン グ手法の問題点を改善し、高い精度での局地降水予測が可能 になると期待される.

4.2 機械学習を用いた手法の問題点

第2章で示したように、局地気象予測において数値モデルと 機械学習の組み合わせが有効である.しかし、機械学習では学 習できない事象に対しては予測できない.また、出現頻度の低 い極端降水現象に対して適用するのも難しい.稀な現象を予測 する場合は、学習期間を長くするなどの必要があるかもしれな い.対象とする地域や季節によって学習条件を含む特徴ベクト ルの設定を変更する必要がある.

基本的には、観測結果と関係あると想定される要素を特徴ベクトルの候補として採用するが、そもそもどのような要素が深く関係しているのかさえ分からない場合も多い。局地気象の成因が複雑であり、メカニズムをほとんど解明できていないことが特徴ベクトルの選択を難しくしている。いずれにせよ、機械学習による局地気象予測のパフォーマンスを向上させるためには、特徴ベクトルの設定が極めて重要になるだろう。一つの方法として、特徴ベクトルを自動的に摘出可能なニューラルネットワーク、深層学習を適用することにより、人には複雑すぎて認識できないパターンを捉えて精度の高い予測が可能になるかもしれない[18].

4.3 機械学習への期待

局地気象については、防災面からも予測精度を改善すること が求められている.また、農業など様々な産業や、太陽光、風 力、小水力発電など再生可能エネルギーにも大きく影響するた め、経済的な側面からも地域詳細かつ高精度での予測が必要 とされている.現在、気象庁ではメソスケールモデル (MSMGPV)による 39 時間予報を実施しており,ほぼリアルタイムで予報値データが配信されている.機械学習を用いて数値 予報値のバイアス補正を行うことにより局地降水予報の精度向上にも応用できる.既存の数値モデルの潜在能力を引き出して 機械学習の手法をさらに発展させることにより,コストを大幅に 抑制し,観天望気に加えてさらに精度の高い局地気象予報が可能になると期待される.

気象学を含む自然科学分野が扱うのは複雑系であり、起こった結果が偶然か必然かの判断ができないケースも多々ある.しかし、人には判断できなくても、機械学習により複雑な現象から規則性が見出されるかもしれない.規則性を見出すことができれば、それにより予測が可能になるだろう.従来の方法では検出できなかったパターンについても、様々な機械学習の手法を用いることにより発見できるかもしれない.さらに、未知のメカニズムを解明し自然現象への理解を深めるための糸口を提供してくれるかもしれない.現時点において、気象分野では機械学習、人工知能が一般に広く取り入れられているわけではないが、今後さらに理解が進めば有効な研究手法の1つになるだろう.気象分野と人工知能研究分野の多くの方に関心を持っていただき、自然災害や地球温暖化など気象に関わる様々な環境問題を解決するきっかけとなることを期待したい.

5. まとめ

- 冬季の日本海側降水特性について、観測降水とモデル 降水にサポートベクターマシンの回帰モデルを適用することにより、モデル降水のバイアスを大きく低減できた。
- 地域詳細の降水分布や風向風速分布パターンを認識することにより、局地降水を高い精度で予測できる。
- 機械学習は、複雑な現象から規則性(パターン)を認識して予測を行うことが可能であり、数値モデルと組み合わせることにより、局地気象予報の精度向上に有効である。

参考文献

- Kimura R, Numerical weather prediction. Journal of Wind Engineering and Industrial Aerodynamics. 90.12-15, 1403-1414, 2002.
- [2] 山田力:小型船舶安全運航のための観天望気を入れた気 象海象の話,関東小型船安全協会,2007, http://www.shoankyo.or.jp/kisyou/pdf/khn2.pdf.
- [3] Acharya, S., Presage biology Lessons from nature in weather forecasting. Indian Journal of Traditional Knowledge, 10, 114-124. 2011.
- [4] Met Office: Red sky at night and other weather lore, 2017, https://www.metoffice.gov.uk/learning/learn-about-theweather/how-weather-works/red-sky-at-night.
- [5] 小倉義光: メン気象の基礎理論, 東京大学出版会, 1997.
- [6] French, Mark N., Witold F. Krajewski, and Robert R. Cuykendall: Rainfall forecasting in space and time using a neural network. Journal of hydrology 137.1-4, 1-31, 1992.

- [7] Kuligowski, Robert J., and Ana P. Barros: Experiments in short-term precipitation forecasting using artificial neural networks. Monthly weather review 126.2, 470-482, 1998.
- [8] 帰納的機械学習手法の天気予報への応用,気象研究所技術報告,第39号2000. http://www.mrijma.go.jp/Publish/Technical/DATA/VOL_39/39_005.pdf
- [9] WMO: Nowcasting. 2018. http://www.wmo.int/pages/prog/amp/pwsp/Nowcasting.htm.
- [10] 気象庁: 解析雨量・降水短時間予報・降水ナウキャストの 改善. 2018.
- http://www.jma.go.jp/jma/kishou/books/yohkens/18/chapter3.pdf.
- [11] 気象庁: メソモデル・局地モデル. 2018. http://www.jma.go.jp/jma/kishou/know/whitep/1-3-6.html.
- [12] 気象庁: 解析雨量. 2018. http://www.jma.go.jp/jma/kishou/know/kurashi/kaiseki.html.
- [13] Giorgi, Filippo, and Maria Rosaria Marinucci.: A investigation of the sensitivity of simulated precipitation to model resolution and its implications for climate studies. Monthly Weather Review 124.1: 148-166. 1996.
- [14] Barros, Ana Paula, and Dennis P. Lettenmaier: Dynamic modeling of orographically induced precipitation. Reviews of geophysics 32.3. 265-284. 1994.
- [15] Haney, Robert L.: On the pressure gradient force over steep topography in sigma coordinate ocean models. Journal of physical Oceanography 21.4: 610-619. 1991.
- [16] David Meyer et al.: Misc Functions of the Department of Statistics, Probability Theory Group (Formerly: E1071), TU Wien, 2017. https://cran.r-project.org/web/packages/e1071/e1071.pdf
- [17] Wilby, Robert L., et al.: Guidelines for use of climate scenarios developed from statistical downscaling methods. Supporting material of the Intergovernmental Panel on Climate Change, available from the DDC of IPCC TGCIA 27, 2004.
- [18] LeCun, Yann, Yoshua Bengio, and Geoffrey Hinton: Deep learning. nature 521.7553, 436. 2015.