

アンサンブルスプレッドを活かした ガイダンスの精度向上

相河 卓哉・稲津 将 (北大院理)

1. はじめに

現業の予報作業においては数値予報モデルの出力値そのままではなく、地形の効果や数値予報モデル自体がもつ系統誤差を統計的に補正した数値予報ガイダンスと呼ばれるデータが用いられている。

ガイダンスでは、数値予報データと予測対象地点の観測データから、統計的手法によって系統誤差の予測式を作成する。気象庁では、気温、風、降水などの主要なガイダンスにおいて、観測があるたびに予測式の係数を更新しながら予報する逐次学習型を採用している。

逐次学習型のガイダンスには、季節による予測式の変化やモデル自体の変更などに柔軟に対応できるという利点があり、カルマンフィルタ理論 (Kalman 1960) に基づいて線形重回帰式の係数を更新する手法 (Persson 1991; Simonsen 1991) が主に用いられる。

カルマンフィルタには、観測誤差分散という新しく入ってきたデータにどの程度の重みを置いて学習するかを決定するパラメータがあり、これが大きいほど予測式の係数の変動が小さくなる。この値が適切でないと、前線や低気圧などの擾乱の発生・発達を外れることなどによる系統的でない誤差を含むデータを過剰に学習してしまう。そのため予測式が不適切に変化し、その後のガイダンスの精度が悪化する。

したがって、系統的でない誤差がどの程度含まれるかによって、観測誤差分散を変化させる必要がある。しかし、学習時に系統的でない誤差の大きさを見積も

るのは難しいため、実際には観測誤差分散が定数であるとするのが多く、過剰な学習がたびたび発生する。気象庁では、予報が一定値以上外れた場合に観測誤差分散を大きくすることで過剰な学習を抑制し、ガイダンスの精度が向上させた事例がある (後藤 2014; 白山 2017)。

本研究ではアンサンブルスプレッドに着目した。これには初期値による予報の困難さの情報が含まれていることが期待されるため、系統的でない誤差の見積もりに使用することができると考えられる。先行研究として、Pelosi et al. (2017) では、観測誤差分散を陽に推定することを避けるための手法としてアンサンブルスプレッドを用いる方法が提案されている。しかし、これにより過剰な学習が抑制されるかどうかには明らかではない。

本研究では、アンサンブルスプレッドを利用して観測誤差分散を推定することが、カルマンフィルタにおける過剰な学習の抑制に効果的であることを明らかにする。この際、本手法の効果を解析しやすくするため、Lorenz (1996) のモデルを用いた理想状態での双子実験を行う。

2. 実験方法

本研究で用いる Lorenz (1996) のモデルは以下の式で表される。

$$\frac{dx_j}{dt} = (x_{j+1} - x_{j-2})x_{j-1} - x_j + F$$

$$(j = 1, \dots, N)$$

右辺第 1 項が移流を模した非線形項であり、第 2 項が減衰項、第 3 項が外力項である。ここでは $N = 40, F = 8.0$ とした。

上の式を用いて次の 3 種類のデータを

作成する。

1. 適当な初期値から計算したデータ
2. 1にガウシアンノイズを加えたもの
3. 予報初期時刻毎にアンサンブル変換カルマンフィルタ (Bishop et al. 2001) によって2を観測として解析を行う 32メンバーのアンサンブルデータ

ガイダンスを作成する際には、系統誤差として3のデータに時間変化する値を加えたものをモデル予報値とし、1のデータが観測値であるとする。したがって、3のデータに加えた値をガイダンス予測式が再現できれば制度のよいガイダンスということになる。

観測誤差分散の推定方法は次の3つを比較する。

- a. 固定値とする (Constant)
- b. ガイダンスが一定以上外れた場合に大きくする (Threshold)
- c. スプレッドに応じて変化させる (Spread)

いずれの手法もパラメータの設定が必要になるが、いくつかの場合を実験し各手法で結果の良かった場合を比較する。

3. 実験結果

図1に各手法のガイダンスが予測した




図1：ガイダンスが予測した誤差の時間変化。灰：与えた系統誤差、黒破線：Constant、黒点線：Threshold、黒実線：Spreadである。

誤差と与えた系統誤差の時間変化を示す。時刻115と145付近を見ると、ConstantとThresholdでは、予報が大きく外れたことによって予測した誤差が大きく変動しているが、Spreadではその変動が小さく抑えられている。これはこの時刻におけるアンサンブルスプレッドが大きくなっていることが要因であり、期待していた効果が見られる。

図2に実験期間全体におけるガイダンスが予測した誤差と与えた系統誤差の散布図を示す。対角線上にあるほどガイダンスの精度が良いということであり、Spreadではガイダンスが大きく予測を外す場合が減っている。

4. まとめ

アンサンブルスプレッドに応じてカルマンフィルタの観測誤差分散を変化させることで、過剰な学習が軽減されることがわかった。

今回の実験は理想実験であるため、現実のデータに即座に適用できるわけではないが、今後活用する機会がさらに増えるアンサンブル予報データを用いたガイダンスの精度向上手法の一つとなることが期待される。




図2：ガイダンスが予測した誤差（横軸）と与えた系統誤差（縦軸）の散布図。正方形：Constant、菱形：Threshold、円：Spreadである。