



Title	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
Author(s)	相河, 卓哉; Aikawa, Takuya; 稲津, 將 他
Citation	北海道大学地球物理学研究報告, 85, 1-10
Issue Date	2022-03-26
DOI	https://doi.org/10.14943/gbhu.85.1
Doc URL	https://hdl.handle.net/2115/84678
Rights(URL)	https://creativecommons.org/licenses/by-nc/4.0/
Type	departmental bulletin paper
File Information	GBHU_85_p1-10.pdf



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¹・稲津 将²

¹ 気象庁情報基盤部

² 北海道大学大学院理学研究院

(2021年6月30日受理)

The improvement of post-processing with the ensemble spread

Takuya AIKAWA¹, Masaru INATSU²

¹Information Infrastructure Department, Japan Meteorological Agency

²Faculty of Science, Hokkaido University.

(Received June 30, 2021)

Post-processing is an inevitable procedure to statistically correct systematic errors in a numerical model product. Karman filtering, a post-processing technique, often ameliorated the prediction skill by overlearning due to large random errors. This study conducted an experiment to determine the observation error variance from the ensemble spread, based on an idealised numerical model of Lorenz 96. The results suggested that the overlearning was mitigated in spite of synchronisation of systematic errors and the prediction skill was higher than in previous method.

I. はじめに

天気予報の精度向上は気象学にとって最大の課題のひとつである。数値予報モデルでは大気を有限の格子に分割し、その格子に合わせて地形などの境界条件を与えるため、格子間隔以下の地形による効果は再現されない。そのため現業の予報作業においては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。この予測式を作成する手法としては、予報変数の線形結合でかけるとする線形重回帰やカルマンフィルタが古くから用いられており、発雷確率などの2値現象にはロジスティック回帰が主に用いられている。ほかにも、近年はニューラルネットワークも使用されている。



ガイダンスの学習方法は大きく2種類に分けることができる。1つは過去数年分のデータから予測式の係数を求め、予報ではその係数を常に利用する一括学習型の手法であり、もう1つは観測があるたびに係数を更新しながら予報する逐次学習型の手法である。

気象庁では、降水、気温、風などのガイダンスにおいて逐次学習が用いられている（後藤 2018）。これは、一括学習の場合は季節ごとに係数を切り替えたり、数値予報モデルの更新のたびに予報データを用意して学習し直したりする必要があるのに対し、逐次学習は日々の学習の中で系統誤差の変化に追随することができるという利点があるためである。逐次学習型のガイダンスを作成する際には、カルマンフィルタ理論（Kalman 1960）に基づいて係数を更新する手法（Persson 1991; Simonsen 1991）がよく用いられる。本研究では、このカルマンフィルタによる逐次学習型ガイダンスの精度を向上させるための新手法を実験する。

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、これが大きいほど係数の変動が小さくなる。カルマンフィルタによるガイダンスの精度は、このパラメータに非常に敏感であり、大きすぎると系統誤差の時間変化に追随できなくなり逐次学習の利点を失う。一方、小さすぎると系統的ではない予報誤差を過剰に学習し、係数が不適切に変動する。例えば、数値予報モデルで前線や低気圧などの擾乱の発生・発達を外れることによる誤差は、さまざまな誤差を生じさせるためガイダンスにとっては系統的とはいえない。そのため、このような誤差を含むデータを過剰に学習してしまうと係数が不適切に変化し、その後のガイダンスの精度が悪化する。

したがって、予報誤差に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を定数として扱うことが多く、過剰な学習が行われる場合がある。気象庁のガイダンスではこれを改善するため、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処理も導入されている（後藤 2014; 白山 2017）。

アンサンブル予報のスプレッドには、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、観測誤差分散の見積もりに使用できる可能性がある（工藤 2018）。スプレッドを用いた観測誤差分散の推定手法として、Pelosi et al. (2017) は新しいデータの重みであるカルマンゲインの分母にあたる部分を、アンサンブルスプレッドと実況値の分散の推定値の和に置き換える、という方法を提案した。この手法は、既存の手法と比較して同等以上の精度であることが示されているが、彼らはアンサンブルデータに対するカルマンフィルタの適用手法の一部として、観測誤差分散を陽に推定することを避けるためにこの手法を導入しており、過剰な学習が抑制されるかどうかには着目していない。

本研究では、アンサンブルスプレッドから推定した観測誤差分散を用いることで、カルマンフィルタにおける過剰な学習を抑制できることを示す。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（以下 Lorenz 96 モデルと呼ぶ）を用いた双子実験を行う。また、Pelosi et al. (2017) とは異なり観測誤差分散のみアンサンブルスプレッドを用いて推定するこ

ととする。これらの手法の詳細は次節で説明する。

II. ガイダンス作成法

この節では、線形重回帰式を予測式としそれをカルマンフィルタによって更新するガイダンス手法と、Pelosi et al. (2017) 及び本研究での観測誤差分散の推定手法について説明する。

ガイダンスにおけるカルマンフィルタでは、時刻 t における目的変数（ここでは予測対象とする物理量の系統誤差） y_t が次の式で書けるとする。

$$y_t = \mathbf{x}_t^T \mathbf{w}_t + v_t = w_{0,t} + x_{1,t} w_{1,t} + \dots + x_{n,t} w_{n,t} + v_t \quad (1)$$

この式を観測モデル式という。ここで $n+1$ 次ベクトル $\mathbf{x}_t = [1, x_{1,t}, x_{2,t}, \dots, x_{n,t}]^T$ は説明変数（適切に選択した数値予報モデルの予報値）、 $n+1$ 次ベクトル $\mathbf{w}_t = [w_{0,t}, w_{1,t}, w_{2,t}, \dots, w_{n,t}]^T$ は係数、 $v_t \sim N(0, D_t)$ であり、 D_t は観測誤差分散である。また、係数 \mathbf{w}_t は次のような時間変化をとする。

$$\mathbf{w}_t = \mathbf{w}_{t-1} + \mathbf{u}_t \quad (2)$$

この式をシステムモデル式という。 $n+1$ 次ベクトル \mathbf{u}_t はシステムノイズと呼ばれ、平均 $\mathbf{0}$ 、分散共分散行列 \mathbf{U}_t の $n+1$ 次正規分布 $N_{n+1}(\mathbf{0}, \mathbf{U}_t)$ に従う。

式 (1),(2) の仮定の下で、カルマンフィルタにより係数 \mathbf{w}_t 、すなわちバイアス $w_{0,t}$ と各説明変数が目的変数に与える影響の大きさ $w_{1,t}, w_{2,t}, \dots, w_{n,t}$ を更新する。この際、時刻 $t-1$ での観測の情報をもとにした時刻 t の係数の推定値 $\mathbf{w}_{t|t-1}$ およびその分散共分散行列 $\mathbf{Q}_{t|t-1}$ の推定値は次の式で表される。

$$\mathbf{w}_{t|t-1} = \mathbf{w}_{t-1|t-1} \quad (3)$$

$$\mathbf{Q}_{t|t-1} = \mathbf{Q}_{t-1|t-1} + \mathbf{U}_t \quad (4)$$

そして時刻 t での観測がわかったとき、次のようにこれらの値を更新する。

$$\mathbf{w}_{t|t} = \mathbf{w}_{t|t-1} + \mathbf{K}_t (y_t - \mathbf{x}_t^T \mathbf{w}_{t|t-1}) \quad (5)$$

$$\mathbf{Q}_{t|t} = \mathbf{Q}_{t|t-1} - \mathbf{K}_t \mathbf{x}_t^T \mathbf{Q}_{t|t-1} \quad (6)$$

$$\mathbf{K}_t = \mathbf{Q}_{t|t-1} \mathbf{x}_t (\mathbf{x}_t^T \mathbf{Q}_{t|t-1} \mathbf{x}_t + D_t)^{-1} \quad (7)$$

ここで y_t はモデル予報値－観測値として求める。 $n+1$ 次ベクトル \mathbf{K}_t はカルマンゲインと呼ばれ、係数をどの程度更新するかを表す。

式 (5),(6),(7) で表されるカルマンフィルタによる更新では、更新前の係数 $\mathbf{w}_{t|t-1}$ と新しい系統誤差の情報 y_t の線形結合のうち、それぞれの分散共分散行列 $\mathbf{Q}_{t|t-1}, D_t$ を考慮して更新後の係数 $\mathbf{w}_{t|t}$ の分散共分散行列 $\mathbf{Q}_{t|t}$ の対角和が最小となるように更新がなされる。つまり、適切な観測誤差分散 D_t が与えられている限り、係数はその分散を小さくしながら適切な値に収束してゆく。しかし、実際には係数は時間変化すると考えられ、一定以上過去の情報を“忘れる”必要がある。それに対応するものがシステムノイズであり、毎時刻 \mathbf{u}_t だけ分散共分散行列 $\mathbf{Q}_{t|t-1}$ を大きくすることで係数が一つの値に収束することがないようになっている。

この更新を元にガイダンス値を作成するときは、次の時刻の係数の推定値 $\mathbf{w}_{t+1|t}$ は式 (3) より $\mathbf{w}_{t|t}$ となるので、 $\mathbf{x}_{t+1}^T \mathbf{w}_{t|t}$ が系統誤差の推定量となり、モデル予報値からこれを引いたものがガイダンス値となる、

以上がカルマンフィルタによるガイダンスの作成方法である。ここでパラメータとして与えなければならないのは、係数とその分散共分散行列の初期値 $\mathbf{w}_{0|0}, \mathbf{Q}_{0|0}$ 、及びシステムノイズと観測ノイズの分散共分散行列 \mathbf{U}_t, D_t である。前者は更新を繰り返していれば適切な値に近づいていくために適当な値を与えてよい。しかし、後者は何からの方法で適切な値を推定する必要がある。本研究では Pelosi et al. (2017) と同様にシステムノイズの分散共分散行列は次の式で定義される対角行列とした。

$$\mathbf{U}_t = c^2 \mathbf{I} \quad (8)$$

ここで \mathbf{I} は $n+1$ 次単位行列、 c は定数である。システムノイズを単純な形としたのは、システムノイズは前の時刻の係数の重みをどの程度減らすかに関わっており、これを大きくすることは観測誤差分散を小さくすることと同じ作用となるためである。

次に観測誤差分散の推定方法を示す。Pelosi et al. (2017) では、 D_t を陽に決めることを避けるため式 (7) のカルマンゲイン \mathbf{K}_t の分母である $\mathbf{x}_t^T \mathbf{Q}_{t|t-1} \mathbf{x}_t + D_t$ を次の式 (9) に置き換える方法が用いられている。ここでの上付き添え字はアンサンブルの各メンバーを表す。

$$\frac{1}{N-1} \sum_{i=1}^N (z_t^{(i)} - \bar{z}_t)^2 + (d\zeta_t)^2 \quad (9)$$

$$z_t^{(i)} = y_t^{(i)} - \mathbf{x}_t^{(i)T} \mathbf{w}_{t|t-1} \quad (10)$$

$$\bar{z}_t = \frac{1}{N} \sum_{i=1}^N z_t^{(i)} \quad (11)$$

ここで、 N はメンバー数、 ζ_t は観測値であり、 d はパラメータである。 $y_t^{(i)}$ はモデル予報値－観測値として求めるため各メンバーによって異なる値となる。式 (9) の第 1 項はアンサンブルスプレッドではないが、式 (1) で $n=0$ とした場合、すなわち系統誤差がバイアス $w_{0,t}$ のみであるとした場合はアンサンブルスプレッドと一致する。このようにして、カルマンゲインの分母を求めたのち、アンサンブル平均に対してガイダンスを作成する。

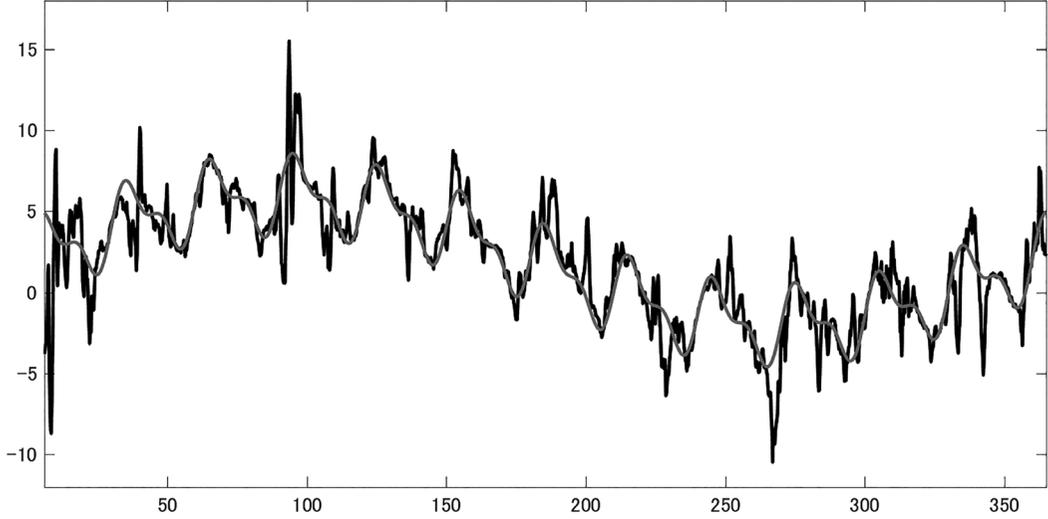


Fig. 1. The model prediction error from the true value (black), and the systematic error in Eq. (14) (grey). The horizontal axis shows the time (unit is day).

彼らの手法は、 K_t の分母を置き換えるため K_t が 1 を超え計算が破綻する可能性があり、観測値 ζ_t をそのまま用いるためそのスケールに依存する。これらの点を避け、またアンサンブルスプレッドによる効果をより明確にするため本研究では次の式を提案する。

$$D_t = \begin{cases} b & , s_t^2 < s_0^2 \\ a(s_t^2 - s_0^2) + b & , s_t^2 \geq s_0^2 \end{cases} \quad (12)$$

ここで s_t^2 はアンサンブルスプレッド（系統誤差を求める物理量の予報値の不偏分散）、 a 、 b 、 s_0^2 はそれぞれパラメータである。すなわち、 s_t^2 が s_0^2 未満の場合は固定値 b とし、それ以上の場合は a を係数として線形に増加させる、というものである。単純な線形としないのは、観測値自体にも誤差が含まれることを考慮するためである。

III. 実験方法

本研究で用いるモデルとデータについて説明する。

本研究で用いる Lorenz 96 モデルは以下の式で表される。

$$\frac{dX_j}{dt} = (X_{j+1} - X_{j-2})X_{j-1} - X_j + F \quad (j = 1, \dots, K) \quad (13)$$

ここでの添え字は空間方向である。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。本研究では $K=40$ 、 $F=8.0$ とする。また Lorenz (1996) と同様に、

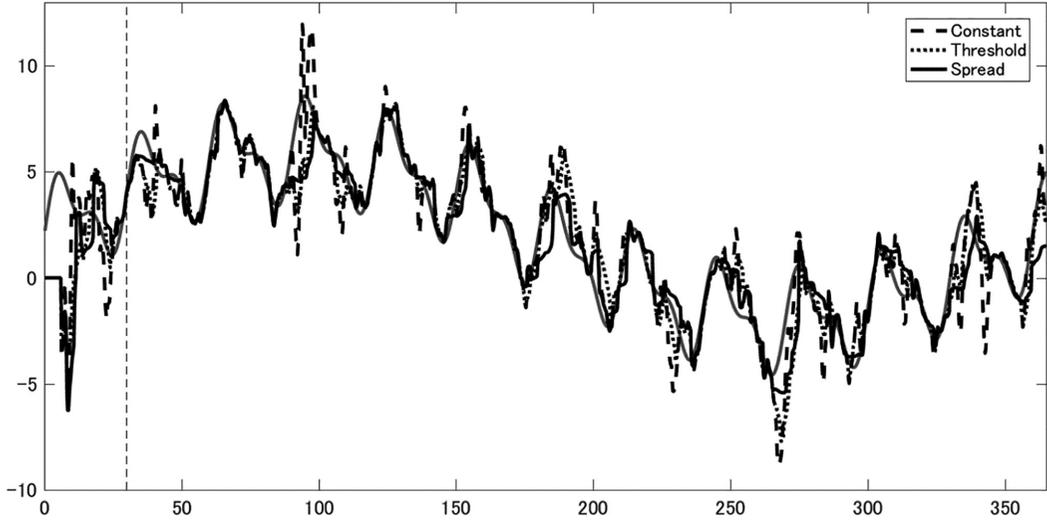


Fig. 2. The error of post-processing outputs of (dashed line) constant method, (dotted line) threshold method, and (solid line) spread method and systematic error (grey). The horizontal axis shows the time (unit is day).

誤差の平均発達率が大气と同程度になるよう 0.2 タイムステップを 1 日と定義する。なお、時間積分には 4 次の Runge-Kutta 法を使用した。

上記のモデルを使用して次の 4 種類のデータを 1 年間分作成する。

- ① 適当な初期値から計算を始めたデータ
- ② ①に $N_K(\mathbf{0}, \mathbf{I})$ のガウシアンノイズを加えたデータ
- ③ 6 時間毎に②を観測としてアンサンブル変換カルマンフィルタ (Bishop et al. 2001) によって解析を行った 32 メンバーのアンサンブルデータ
- ④ ③を初期値とするリードタイム 144 時間 (6 日) の 32 メンバーのアンサンブル予測に、系統誤差を加えたデータ

①が真値, ②が観測値, ③が解析値, ④がモデル予測値にそれぞれ対応する。

ガイダンスは X_j のうち 1 次元のみを対象として作成する。作成する際には, 上記の①を観測値, ②のアンサンブル平均をモデル予測値として扱う。また, 系統誤差は次の式とする。

$$2 + 2 \sin(2\pi t/15 \text{ day}) + 2 \sin(2\pi t/30 \text{ day}) + 4 \sin(2\pi t/360 \text{ day}) \quad (14)$$

式 (14) はモデル予測値に依存しないため, 観測モデル式は式 (1) で $n = 0$, すなわち系統誤差がバイアス w_t^0 のみであるとした。

観測誤差分散の推定方法は次の 3 種類を比較する。

$$\cdot D_t = 0.005 \text{ で一定とする (Constant)}$$

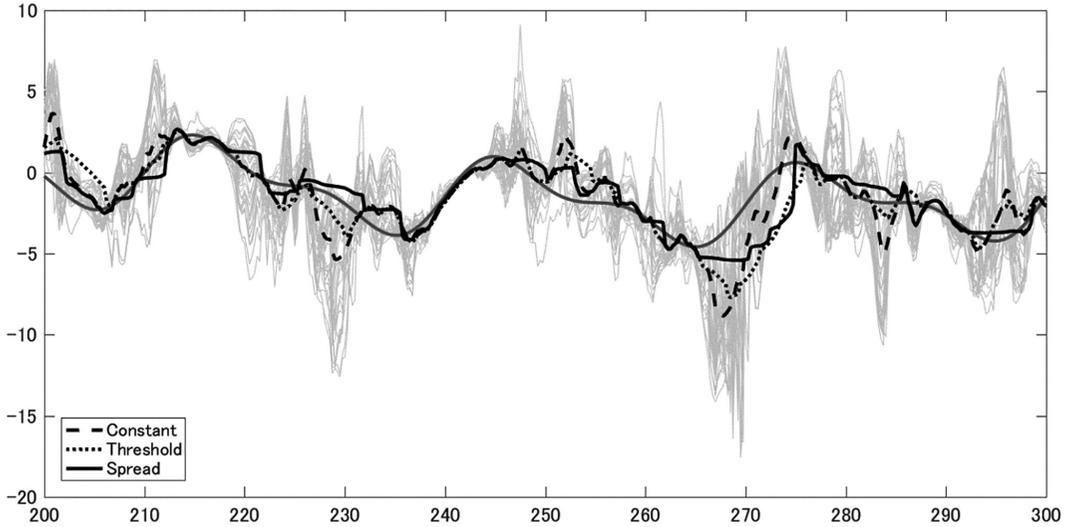


Fig. 3. An enlarged figure focusing on the period from 200 to 300 days. Grey thin lines denote the error of each member of the model forecast from the true value.

- $D_t = 0.005$ とするが、式 (5) の $y_t - \mathbf{x}_t^T \mathbf{w}_{t|t-1}$ が 1.5 以上の場合は D_t を 20 倍にする (Threshold)

- 式 (12) において $a = 0.25, b = 0.0025, s_o^2 = 1.0$ とする (Spread)

Threshold は後藤 (2014) の、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という手法を模したものである。なお、式 (8) の c は 0.03 とした。

IV. 結果

第 1 図にモデル予報値の真値からの誤差、及び式 (14) で表される系統誤差の時系列を示す。長期的には系統誤差に従った変動をしつつ、ランダムな誤差によって誤差が大きく変化する傾向が見られ、現実の予報値を再現できていることがわかる。以下では、各ガイダンスの手法が、ランダムな誤差に影響されずに系統誤差をどの程度予想できたかを検証する。

第 2 図に前節で示した各手法によるガイダンスの予測と系統誤差の時系列を示す。いずれの手法も基本的に系統誤差の時間変化を再現しているが、ランダムな誤差の影響で大きく変動することがある。また、実験開始直後は十分な学習ができていないため推定精度が悪い。よって、以降は 30 日 (細破線) より後のみを対象として解析を行う。

第 3 図に第 2 図の 200 日から 300 日の部分を拡大した図を示す。230 日と 270 日付近にはガイダンスの予測と系統誤差に大きな差が見られる。これは、予報がランダム誤差によって大きく外れた影響をガイダンスが過剰に学習したためである。特に Constant 実験でこの影響が大きいが、

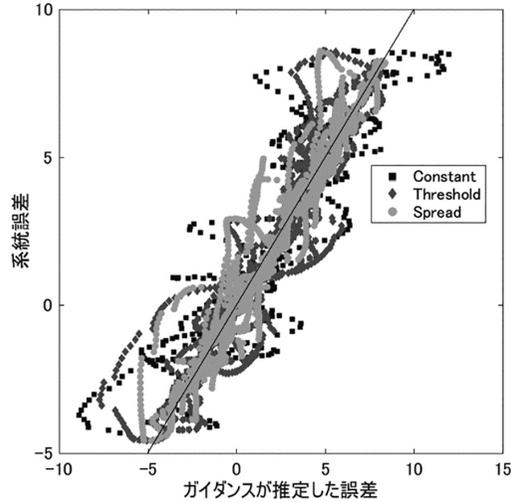


Fig. 4. The scatter plot between estimated error by post-processing and systematic error. Square, diamond, and circle respectively show the constant, threshold, and spread methods. The plot is limited to the period after 30 days from the initial time.

Threshold 実験や Spread 実験ではこの変動が抑制されている。各メンバーの予報のばらつきを見ると、この部分の予報のスプレッドが大きくなっており、これによって Spread 実験では変動が抑制されたことがわかる。

第 4 図に各手法のガイドナスの予測と系統誤差の散布図を示す。第 3 図と同様に Constant 実験に顕著にみられる過大・過小な予測が Spread 実験では抑制されていることがわかる。各手法の二乗平均誤差は Constant 実験では 1.31, Threshold 実験では 1.23, Spread 実験では 1.10 であった。

第 5 図にモデル予報値のランダムな誤差とアンサンブルスプレッドの平方根の散布図を示す。ここでのランダムな誤差とはモデル予報値から系統誤差を引いたものである。図の左上には点が存在せず、アンサンブルスプレッドが大きい場合にはランダムな誤差も大きくなる傾向が確認できる。これはアンサンブルスプレッドによって過剰な学習を効果的に抑制することを示唆する。また、図の右下に存在する点は、アンサンブルスプレッドが大きくとアンサンブル平均が真値に近い場合である。この場合は、必要以上に観測誤差分散を大きく見積もってしまっていることとなり、本来取り込むべき情報が取り込めていないことになる。

ここまでの実験では、系統誤差は式 (14) に示すような連続関数とした。これは系統誤差の季節変動を模したものである。しかし、実際の数値モデルに対してガイドナスを作成する際には、モデル自体の変更による系統誤差の変化を考慮する必要がある。そこで、モデル自体の変更を模すために、式 (14) の定数項 2 を 50 日ごとに 0 としたり 2 としたりを繰り返す実験を行った。その結果を第 6 図に示す。Threshold 実験では、250 日および 300 日付近の不連続な変化をランダムな誤差と区別することができず、変化に対応するのが遅れている。一方、Spread 実験では特に

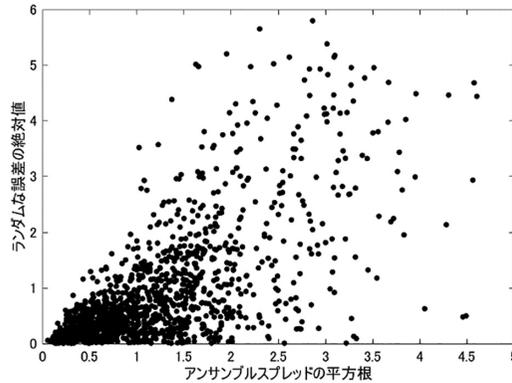


Fig. 5. The scatter plot between the square root of ensemble spread and the absolute value of random error in model forecast.

アンサンブルスプレッドが小さい 300 日で即座に変化に対応することができた。この実験での二乗平均誤差は Constant 実験では 1.31, Threshold 実験では 1.29, Spread 実験では 1.09 であった。

V. ま と め

本研究では、カルマンフィルタを用いたガイダンスにおいて課題となっている、過剰な学習を抑制する手法を提案し、理想モデルで実験を行った。その結果、アンサンブルスプレッドの 1 次関数として観測誤差分散を推定することで過剰な学習を抑制できることがわかった。また、気象庁で現在用いられている手法の一つに近い、閾値を決めて観測誤差分散を大きくする手法と比較しても、モデルの変更による不連続な系統誤差の変化に対して本研究の手法が有効であることがわかった。

本研究は、理想モデルでの実験でありガイダンスの“答え”である系統誤差が分かっている状態での実験である。実際の数値モデルでガイダンスを作成する際にはモデルの誤差のうちどこまでを系統誤差とするかという問題がある。ガイダンスの精度は観測誤差分散を決定するためのパラメータによって大きく左右される。本研究で実験した各手法ともいくつかのパラメータを設定する必要があり、本研究では“答え”がわかっている状態でチューニングすることができたが、実際には“答え”がわからない状態でチューニングをする必要がある。また、実際の数値モデルのアンサンブルスプレッドにどの程度ランダムな誤差の情報が含まれるかは、モデルのスプレッドスキルなどに左右されることが考えられ、明らかではない。ほかにも本研究では、ガイダンス作成対象の変数のスプレッドを用いたが、実際のガイダンスでは観測モデルに用いた変数のうちどの変数のスプレッドを利用するかについて検討する必要がある。したがって、本研究の手法が即座に現業のガイダンスに適用可能ではない。しかし、今後さらに高解像度化が進むアンサンブ

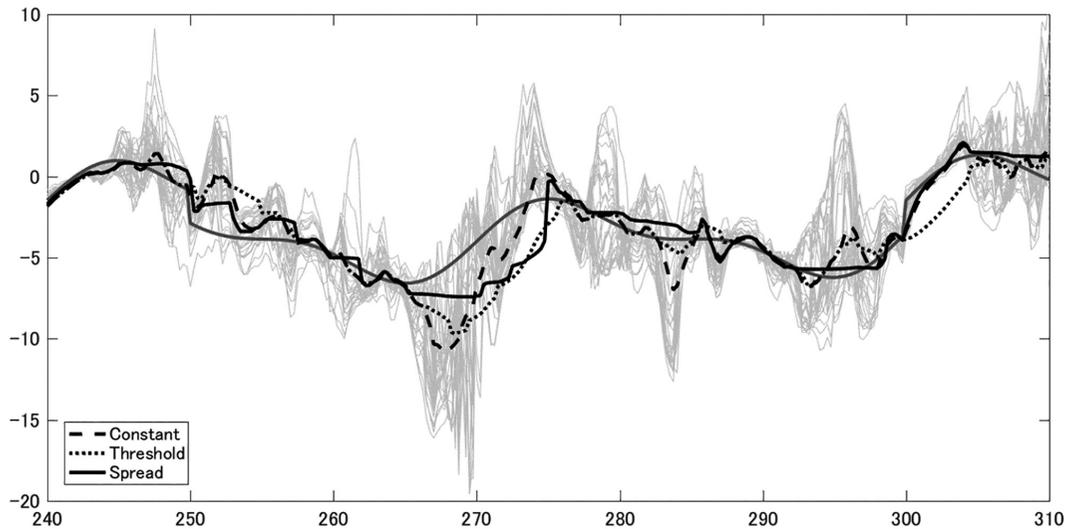


Fig. 6. Same as Fig. 3, but the result of an experiment with the systematic error discontinuously changing at 250 day and at 300 day.

ル予報に対して、アンサンブルの情報を活かすガイダンス作成手法の一つとなることが期待される。

謝辞 第二著者は科学研究費補助金 基礎研究 (A)18H03819 及び基礎研究 (C)18K03734 ならびに文部科学省気候変動適応社会実装プログラムの支援を受けた。本研究を進めるにあたり現業でのガイダンス運用の詳細についてご教授いただいた気象庁の白山洋平様、また気象庁でのガイダンスの詳細を解説資料として公開していただいている気象庁予報部の方々に深く感謝申し上げます。

文 献

- Bishop, C. H., B. Etherton, and S. J. Majumdar, 2001. Adaptive sampling with the ensemble transform Kalman filter. Part I: Theoretical aspects. *Mon. Wea. Rev.*, **129**, 420-436.
- 後藤尚親, 2014. 気温ガイダンスの改良. 平成 26 年度数値予報研修テキスト, 気象庁予報部, 72-79.
- 後藤尚親, 2018. ガイダンス一覧. ガイダンスの解説, 気象庁予報部, 94.
- Kalman, R. E., 1950. A new approach to linear filtering and prediction problems. *J. Basic Eng.*, **82**, 35-45.
- 工藤淳, 2018. カルマンフィルタ. ガイダンスの解説, 気象庁予報部, 62-70.
- Lorenz, E. H., 1996. Predictability - A problem partly solved. *Proceedings of the ECMWF seminar on predictability*. Reading, UK.
- Pelosi, A., H. Medina, J. Van den Bergh, S. Vannitsem, and G. B. Chirico, 2017. Adaptive Kalman filtering for postprocessing ensemble numerical weather predictions. *Mon. Wea. Rev.*, **145**, 4837-4854.
- Persson, A.O., 1991. Kalman filtering - A new approach to adaptive statistical interpretation off numerical meteorological forecasts. *WMO Technical Document*, **421**, 27-32.
- 白山洋平, 2017. 降水ガイダンスの改良. 平成 29 年度数値予報研修テキスト, 気象庁予報部, 86-93.
- Simonsen, C., 1991. Self adaptive model output statistics based on Kalman filtering. *WMO Technical Document*, **421**, 33-37.