条件非线性最优扰动和繁殖向量相结合的一种集合预报方法

周仕政¹, 郑琴^{1*}, 沙建新²

1. 解放军理工大学理学院, 南京 211101;

2. 解放军 94906 部队, 苏州 215157

* 联系人, E-mail: qinzheng@mail.iap.ac.cn

2017-02-22 收稿, 2017-05-08 修回, 2017-05-08 接受, 2017-06-22 网络版发表

国家自然科学基金(41331174, 41430426)资助

摘要 集合初始扰动的好坏对集合预报效果有着至关重要的影响. 为了产生能够捕捉到初始场不确定性的初始扰动, 在不考虑模式误差的情况下, 用Lorenz-96模式探讨了条件非线性最优扰动(conditional nonlinear optimal perturbation, CNOP)在集合预报中的应用, 并与传统的增长繁殖模方法(breeding of growing mode, BGM)进行了比较. 发现用CNOPs代替 L_2 范数较大的繁殖向量(breeding vectors, BVs)的集合预报技巧明显高于BGM方法. 在分析误差是快速增长型扰动的条件下, 新方法对预报结果的改善幅度随预报时间的延长而增大, 特别是在中期预报范围(6~14 d)内, 改善效果更加明显. 按照通常距平相关系数(ACC)不小于0.6则视为有效预报的标准, 新方法和BGM方法得到的集合预报相对于参照预报而言, 都能够将有效预报时间延长4 d左右.

关键词 集合预报, 条件非线性最优扰动, 繁殖向量, 预报技巧

数值天气预报经过几十年的发展, 成为了当代天气预报的重要组成部分. 但由于真实的大气状态无法准确获取, 代入数值模式的初始场只能是真实状态的一个近似, 不可避免地存在一定的误差. 在大气系统非线性特征的影响下, 细微的误差可能导致最终的预报结果相去甚远^[1], 这使得单一的确定性预报难以克服初始场不确定性和大气系统不稳定性所带来的不良影响.

为了估计预报的不确定性, Epstein^[2]提出了集合预报的思想, 随后, Leith^[3]在集合预报中引入了蒙特卡罗法(Monte-Carlo forecast, MCF), 即在分析场上叠加随机的初始扰动来生成多个初始场进行预报, 从而估计一个大气状态发展可能的概率分布. 1983年, Hoffman和Kalnay^[4]在集合预报中采用了滞后平

均法(lagging average forecasting, LAF)生成初始扰动, 该方法利用初始时刻之前的实际预报误差来产生扰动, 因而受环境大背景环流演变的影响, 考虑了与动力模式的协调. 但大的LAF集合预报需要大量的以前预报, 对集合成员的增加造成了困难, 且集合平均存在被以前预报所污染的可能. 随着扰动技术的发展, 不同的初始扰动生成方法相继出现, 其中奇异向量法(singular vectors, SVs)^[5,6]和增长模繁殖法(breeding of growing mode, BGM)^[7,8]作为最具代表性的两种方法, 1992年分别在欧洲中期天气预报中心(ECMWF)和美国国家环境预报中心(NCEP)投入业务使用. SVs方法能够确定最快的扰动发展方向, 并具有很好的发散度, 但存在计算量较大和扰动结构与模式大气层结构不一致的缺陷. 相比SVs方法, BGM

引用格式: 周仕政, 郑琴, 沙建新. 条件非线性最优扰动和繁殖向量相结合的一种集合预报方法. 科学通报, 2017, 62: 2392–2398

Zhou S Z, Zheng Q, Sha J X. An ensemble forecast method combining CNOPs with BVs (in Chinese). Chin Sci Bull, 2017, 62: 2392–2398, doi: 10.1360/N972016-01155

方法模拟资料分析的过程,由模式的反复循环产生扰动,操作简单,计算经济,且产生的初始扰动结构与大气模式结构协调性较好,因此本文采用BGM方法与新方法进行集合预报试验对比。

考虑到SVs在非线性领域的局限性,2003年Mu等人^[9]提出了条件非线性最优扰动(conditional nonlinear optimal perturbation, CNOP)的概念。自CNOP提出以来,已被成功地应用到了可预报性、目标观测、集合预报等多个大气和海洋科学领域中。2007年,穆穆和姜智娜^[10]用正压准地转模式探讨了CNOP在集合预报中的可能应用,发现用CNOP代替第一奇异向量的集合预报技巧在中期预报范围(6~14 d)内明显高于奇异向量法。CNOP包括全局CNOP和局部CNOP,在CNOP方法与SVs方法结合的应用中,所使用的仅仅是一个全局CNOP,局部CNOP未被应用到集合预报当中。穆穆和姜智娜^[10]表明在集合扰动的建立过程中,局部CNOP可能起着比全局CNOP更为重要的作用。所以本文将基态所对应的所有全局CNOP和局部CNOP一起应用到集合预报当中,结合繁殖向量(breeding vectors, BVs)来产生初始集合扰动,进一步探讨了CNOPs在集合预报中的应用前景。

1 初始扰动的生成

合理扰动场应该与实际分析资料可能的误差分布一致,以保证每个扰动场都能代表大气可能的实际状态。此外,集合成员在模式中的演变方向应该尽可能大地发散,以保证预报集合最大可能地包含实际大气可能状况。

1.1 增长繁殖模法(BGM)

BGM方法最早由Toth和Kalnay^[7,8]提出,其原理是在已有的预报模式的基础上,通过模式的反复繁殖循环获取最快增长模向量,使得快速增长型扰动比重不断增大,从而保留了扰动快速增长的动力结构。具体步骤:(1)在分析场上叠加一个初始扰动;(2)用相同的非线性模式积分被扰动分析场和未被扰动分析场;(3)在固定的时间间隔(本文取6 h),用被扰动预报减去未被扰动预报得到一个新的扰动;(4)将新的扰动进行尺度化处理,使其在均方根意义上与初始扰动具有相同量级;(5)将得到的新扰动添加到过程(1)中进行下一个6 h繁殖循环。依时间多次重复上述过程,3 d的繁殖循环结束后得到快速增长

的BV,作为集合预报的初始扰动。繁殖循环的初始扰动取Lorenz-96模式24 h预报的均方根误差乘上一个随机数,该随机数服从 $[-1, 1]$ 之间的均匀分布^[11]。

1.2 条件非线性最优扰动(CNOP)

CNOP是满足一定的约束条件 $\|\Delta x_0\| \leq \delta$,且在预报时刻非线性发展最快的一类扰动。即在初值 x_0 上叠加一个扰动 Δx_0 ,条件非线性最优扰动 Δx_0^* 就是满足下列形式的一种扰动:

$$J_{(\Delta x_0^*)} = \max_{\|\Delta x_0\| \leq \delta} J_{(\Delta x_0)}, \quad (1)$$

其中,目标函数 $J_{(\Delta x_0)}$:

$$J_{(\Delta x_0)} = \|M_T(x_0 + \Delta x_0) - M_T(x_0)\|, \quad (2)$$

式中, $\|\cdot\|$ 为选取的适当范数, M_T 表示非线性传播算子积分到 T 时刻。

CNOP的求解属于带约束的最优化问题,采用SPG2(Spectral Projected Gradient 2)优化算法来计算,为确保能找到参照预报场所对应的全局CNOP和所有局部CNOPs,每次试验计算20次CNOP,将所有CNOPs按相似度高于90%的标准划分为一类模态,所有不同模态的CNOPs都将用来替换 L_2 范数较大的BVs。相似度的计算公式为

$$S = \frac{\langle X \cdot Y \rangle}{\|X\| \cdot \|Y\|}, \quad (3)$$

式中, S 表示向量 X 与 Y 之间的相似度, $\langle \cdot \rangle$ 是欧式内积, $\|\cdot\|$ 是二范数模。

2 试验设计

2.1 Lorenz-96模式

Lorenz-96模式是Lorenz^[12]在1996年从动力模式中推导简化出来的新的动力模式,被广泛应用在集合预报问题当中^[13,14]。该模式是一个可变尺度的低阶动力学系统,模式中包含 m 个状态变量 $x_1, x_2, \dots, x_m$,均匀分布在同一纬圈上。模式对初值敏感,且非线性作用强烈,控制方程如下:

$$\frac{dx_i}{dt} = (x_{i+1} - x_{i-2})x_{i-1} - x_i + F, \quad (4)$$

式中, $i=1, 2, \dots, m$ 是与循环边界条件相关的格点标号, F 为外部强迫项,通过控制变量维数 m 和强迫项 F 的大小可以控制模式系统的解的性态。Lorenz和Emanuel^[15]表明,当 $m=40$, $F=8.0$ 时,模式系统呈现混沌状态,此时模式的1个无量纲时间步相当于实际5 d

的时间尺度, 本文中的所有试验都在此参数设定下进行. 此外, 按照Lorenz和Emanuel的做法, 试验采用四阶Runge-Kutta方案进行模式差分, 其中时间步长取为0.05个无量纲单位, 差分后的1个无量纲时间步相当于实际6 h的时间尺度.

2.2 试验方案

所有试验在不考虑模式误差的假设下进行. 试验初始态的选取时, 令状态变量 $x_1=1.001 \times F$, $x_i=F$ ($i=2, 3, \dots, m$), 将其代入模式中进行spin-up过程(积分差分后模式4000步), 确保模式变量之间的相互协调, 然后再将得到的状态变量积分1年(积分差分后模式1460步), 选择1年中任意时刻的状态 x_i ($i=1, 2, \dots, m$)作为初始态 X_0 . 用模式积分初始态 X_0 , 模拟一个两周的大气“真实态”, 集合预报场和参照预报场都将与这个“真实态”作比较. 采用集合变换卡尔曼滤波(ensemble transform Kalman filter, ETKF)方法^[16]来产生初始分析场, 通过在“真实态”上叠加随机观测误差来产生观测资料, 其中观测误差为状态 x_i 振幅的1%乘上一个服从 $[-1, 1]$ 之间的均匀分布的随机数. CNOPs以参照预报场为基态得到, 约束半径 δ 大小取初始分析场 L_2 范数的2%, 优化时段2 d. 在初始分析场上叠加初始扰动产生初始集合场, 初始集合场和初始分析场组成一个集合样本. 集合样本1(记为S1)的初始集合扰动全部由BVs组成. 用CNOPs替换S1中 L_2 范数较大的几个BVs, 保持其他扰动不变, 组成集合样本2(记为S2). S1和S2的集合成员数均为17个, 其中包括一个参照预报场.

集合平均代表集合预报结果, 采用均方根误差(RMSE)和距平相关系数(ACC)^[17]来评估预报效果. RMSE用来评估预报与“真实态”之间差别, RMSE越小, 表明对“真实态”的预报越准确, 其计算公式为

$$\text{RMSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (x_i - t_i)^2}, \quad (5)$$

式中, m 为空间格点数量, x_i 和 t_i 分别表示第 i 个格点所对应的预报和“真实态”.

ACC用来评估预报与“真实态”的相关性, ACC越大, 表示预报技巧越高, 其计算公式为

$$\text{ACC} = \frac{\sum_{i=1}^m (x_i - \bar{x}) \cdot (t_i - \bar{t})}{\sqrt{\sum_{i=1}^m (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^m (t_i - \bar{t})^2}}, \quad (6)$$

式中, m 为空间格点数量, x_i 和 t_i 分别表示第 i 个格点所对应的预报和“真实态”, c_i 表示气候态, 用模式10年(积分差分后模式14600步)的平均态作为气候态 c_i , $\bar{x}$ 和 $\bar{t}$ 分别是预报和“真实态”的空间平均. 通常把ACC不小于0.6的预报视为有效预报.

3 结果与分析

3.1 试验结果

本文采用Lorenz-96模式进行了100次基于不同基态的集合预报试验, 预报技巧通过比较ACC和RMSE来评估. 由于ACC评估结果和RMSE所得结果相近, 所以下面表格只展示了RMSE评估结果. 对比参照预报场以及S1和S2对应集合预报场的RMSE, 表1给出了在不同预报时刻S1和S2对应的集合预报技巧高于参照预报技巧的试验次数, 及S2对应的集合预报技巧高于S1的试验次数.

从表1可以发现, 随着预报时间的增长, S1和S2的集合预报技巧高于参照预报技巧的试验次数越来越多, 特别是在中期预报范围(6~14 d)内, S1和S2在一半以上的个例中提供了预报效果优于参照预报的集合预报. 在绝大多数个例中S2的集合预报技巧高于S1的集合预报技巧, 这意味着用CNOPs代替 L_2 范数较大的BVs的初始扰动生成方法, 在集合预报中比传统的BGM方法有更高的预报技巧. 表2给出了100次试验中, 集合预报和参照预报的平均RMSE, 以及集合预报相对于参照预报的RMSE改进率.

RMSE直接反映了预报与“真实态”之间的差异, RMSE越小意味着预报越精准, 预报技巧越高. 从表2可以看出, 在两周的预报中, S2的集合预报技巧始终高于S1, 并且S2对参照预报结果的改善能力更强, 这说明用CNOPs和BVs组合出的初始集合扰动, 比单纯的用BVs作初始扰动更加能够抓住初始场不确定性的特征, 生成的集合预报效果更好. 此外还能看出, 随着预报时间的延长, S1, S2对应的集合预报对预报的改进幅度随之增大. 相同的结论可以从图1得到.

值得注意的是, 在图1(b)中可以发现参照预报的ACC在第10天时低于0.6, 而S2的集合预报在第14天时才出现这种情况, 按照通常ACC不小于0.6则视为有效预报的标准, 新方法和BGM方法对应的集合预报比参照预报的有效预报时效延长了4 d左右.

表 1 100 次试验中, S2 的预报技巧高于参照预报和 S1 预报技巧的试验次数及 S1 的预报技巧高于参照预报技巧的试验次数

Table 1 The experiment number of forecast skill of S2 is higher than S1 and control forecast, and forecast skill of S1 is higher than control forecast in 100 experiments

预报时刻 (d)	S1预报技巧高于 参照预报的 试验次数(次)	S2预报技巧高于 参照预报的 试验次数(次)	S2预报技巧高于 S1的 试验次数(次)
1	18	35	84
2	18	23	94
3	23	31	92
4	38	50	88
5	48	55	87
6	51	64	87
7	61	73	85
8	69	80	81
9	82	89	69
10	90	96	66
11	94	95	66
12	95	96	60
13	95	96	61
14	96	97	60

3.2 结果分析

从表1得知, 100次基于不同基态的集合预报试验

中, 不是每一次集合预报结果都比参照预报好, 图2展示了个例1和2两种完全不同的情况.

为了解释图2两种不同试验结果发生的原因, 从 L_2 范数角度比较了分析误差、全局CNOP和第一BV(对应 L_2 范数最大的BV)的非线性发展. 图3分别是个例1、个例2对应的分析误差、全局CNOP、第一BV在 L_2 范数下随预报时间的非线性发展.

容易发现, 图3的主要差异在于分析误差的发展情形, 个例1对应的分析误差在预报前期便迅速发展, 可认为是快速增长型扰动, 相反个例2对应的分析误差属于缓慢增长型扰动. 再将个例1和2的预报结果与分析误差的类型一一对应作比较, 当分析误差属于快速增长型扰动时, 集合预报技巧都要高于参照预报技巧; 当分析误差属于缓慢增长型扰动时, 集合预报效果不如参照预报, 得到的预报效果较差. 100次试验的分析结果均符合这一结论.

在不考虑模式误差的假定下, 集合预报的效果主要依赖于初始扰动成员能否较好地表征初始的分析误差. 而BGM方法和CNOP方法产生的初始扰动都是快速增长型扰动, 当分析误差属于缓慢增长型扰动时, 快速增长型扰动就不能很好地捕捉到分析误差的特征, 快速增长型扰动产生的集合预报就导致了预报结果较差的情况.

表 2 100 次试验中集合预报和参照预报的平均RMSE及集合预报相对于参照预报的RMSE改进率

Table 2 The average RMSE of ensemble forecasts and control forecast in 100 experiments, and the RMSE improvement of ensemble forecasts relative to control forecast

预报时刻(d)	平均RMSE			RMSE改进率(%)	
	S1	S2	参照预报	S1相对于参照预报	S2相对于参照预报
1	0.8867	0.8418	0.8104	-9.42	-3.88
2	1.4299	1.2714	1.1290	-26.25	-12.61
3	1.9152	1.6938	1.5312	-25.08	-10.61
4	2.2338	1.9961	1.9791	-12.87	-0.86
5	2.5206	2.2903	2.3594	-6.84	2.93
6	2.7608	2.5372	2.7301	-1.12	7.06
7	2.9398	2.7271	3.1184	5.73	12.55
8	3.0788	2.9074	3.4084	9.67	14.70
9	3.2013	3.0839	3.7658	14.99	18.11
10	3.2785	3.1949	4.0607	19.26	21.32
11	3.3293	3.2579	4.1543	19.86	21.58
12	3.3841	3.3329	4.2830	20.99	22.18
13	3.4305	3.4046	4.4273	22.52	23.10
14	3.4790	3.4630	4.5283	23.17	23.53

图1 S1和S2所得集合预报和参照预报的平均RMSE(a)和平均ACC(b)随预报时间的演变

Figure 1 The average RMSE (a) and the average ACC (b) vary with forecast time for ensemble forecasts generated by S1, S2 and the control forecast

图2 个例1(a)和个例2(b)中, S1和S2所得集合预报和参照预报的RMSE随预报时间的演变

Figure 2 The RMSE vary with forecast time for ensemble forecasts generated by S1, S2 and the control forecast in case 1 (a) and case 2 (b)

图3 个例1(a)和个例2(b)中, 分析误差、全局CNOP、第一BV在 L_2 范数下随时间的非线性发展

Figure 3 For case 1 (a) and case 2 (b), the nonlinear evolution of analysis error, global CNOP and the first BV under the L_2 norm

4 总结与讨论

在不考虑模式误差的假定下, 本文将 L_2 范数较大的几个BVs替换成CNOPs, 组合出一组新的初始扰动进行集合预报, 为检验方法的有效性, 在Lorenz-96模式上进行100次基于不同基态的两周集合预报试验, 预报结果与传统的BGM法进行了对比. RMSE和ACC评估结果统计显示, 当分析误差是快速增长型扰动时, 新方法和BGM方法的集合预报效果都优于

参照预报, 对参照预报的改进幅度随预报时间的延长而增大. 相对于BGM方法, 新方法对应的集合预报技巧更高, 对参照预报技巧的提升作用更大. 按通常ACC不小于0.6则视为有效预报的标准, 新方法和BGM方法对应的集合预报相对于参照预报, 都能够延长有效预报时效4 d左右. 当分析误差属于缓慢增长型扰动时, BGM方法和新方法产生的集合预报都会导致预报效果变差, 但对于极端事件而言, 初始分析误差的发展大部分是快速增长的, 所以我们的方

法在极端事件的预报当中应该是有效的。

由于是在“完美模式”假定下进行的试验, 所以如何在模式误差存在的情况下推广我们的方法还需要进一步研究。另外, 在CNOPs的求解过程中, SPG2算法需要复杂的伴随模式, 且不能在一次计算中迅速地找到全局CNOP和所有的局部CNOPs, 这给新方

法在更大模式上的展开造成了一定计算成本上的困难。下一步还需结合智能优化算法^[18-20], 在寻找能够更快速、准确地求解CNOPs的算法上努力。为了更好地检验CNOPs在集合预报中的应用, 还需在更复杂的模式上做更多的数值试验, 采用更多的评价指标来探讨其应用价值, 以期获得更满意的成果。

参考文献

- 1 Lorenz E N. Deterministic non-periodic flow. *J Atmos Sci*, 1963, 20: 130-141
- 2 Epstein E S. Stochastic dynamic prediction. *Tellus*, 1969, 21: 739-759
- 3 Leith C E. Theoretical skill of Monte Carlo forecasts. *Mon Weather Rev*, 1974, 102: 409-418
- 4 Hoffmann R N, Kalnay E. Lagged average forecasting, an alternative to Monte Carlo forecasting. *Tellus*, 1983, 35A: 100-118
- 5 Molteni F, Buizza R, Palmer T N, et al. The new ECMWF ensemble prediction system: Methodology and validation. *Q J R Meteorol Soc*, 1996, 122: 73-119
- 6 Mureau R, Molteni F, Palmer T N. Ensemble prediction using dynamically conditional perturbations. *Q J R Meteorol Soc*, 1993, 119: 299-323
- 7 Toth Z, Kalnay E. Ensemble forecasting at NMC: The generation of perturbation. *Bull Amer Meteorol Soc*, 1993, 74: 2317-2330
- 8 Toth Z, Kalnay E. Ensemble forecasting at NCEP and the breeding method. *Mon Weather Rev*, 1997, 125: 3297-3319
- 9 Mu M, Duan W S, Wang B. Conditional nonlinear optimal perturbation and its applications. *Nonlinear Process Geophys*, 2003, 10: 493-501
- 10 Mu M, Jiang Z N. A new approach to the generation of initial perturbations for ensemble prediction: Conditional nonlinear optimal perturbation. *Chin Sci Bull*, 2008, 53: 2062-2068 [穆穆, 姜智娜. 集合预报初始扰动产生的一个新方法: 条件非线性最优扰动. *科学通报*, 2007, 52: 1457-1451]
- 11 Guan J P, Huang H, Zhang L F. Methods of producing initial perturbations in ensemble forecast (in Chinese). *J PLA Univ Sci Tech*, 2003, 4: 87-90 [关吉平, 黄泓, 张立凤. 集合预报中初始扰动生成方法的探讨. *解放军理工大学学报*, 2003, 4: 87-90]
- 12 Lorenz E N. Predictability: A problem partly solved. In: *Seminar on Predictability*. Shinfield Park: ECMWF, 1996. 1-18
- 13 Duan W S, Huo Z H. An approach to generating mutually independent initial perturbations for ensemble forecasts: Orthogonal conditional nonlinear optimal perturbations. *J Atmos Sci*, 2016, 73: 997-1014
- 14 Roulston M S, Smith L A. Combining dynamical and statistical ensembles. *Tellus*, 2003, 55A: 16-30
- 15 Lorenz E N, Emanuel K A. Optimal sites for supplementary weather observations: Simulation with a Small Model. *J Atmos Sci*, 1998, 55: 399-414
- 16 Bishop C H, Etherton B J, Majumdar S J. Adaptive sampling with the ensemble transform Kalman Filter, Part I: Theoretical aspects. *Mon Weather Rev*, 2001, 129: 420-436
- 17 Murphy A H, Epstein E S. Skill scores and correlation coefficients in model verification. *Mon Weather Rev*, 1989, 117: 572-581
- 18 Ye F H, Zhang L, Gong X W, et al. Improved particle swarm optimization algorithms for conditional nonlinear optimal perturbation (in Chinese). *J Jiangnan Univ*, 2011, 10: 468-472 [叶飞辉, 张露, 巩向武, 等. 改进的粒子群算法在求解条件非线性最优扰动的应用. *江南大学学报*, 2011, 10: 468-472]
- 19 Zheng Q, Ye F H, Sha J X, et al. Effective application of particle-swarm optimization algorithm in variational data assimilation with discontinuous “on-off” switch (in Chinese). *Meteorol Sci Tech*, 2013, 41: 286-293 [郑琴, 叶飞辉, 沙建新, 等. 动态权重粒子群算法在含“开关”过程四维变分资料同化中的有效应用. *气象科技*, 2013, 41: 286-293]
- 20 Shu H, Li Q, Zheng Q. Variational data assimilation based on parallel particle swarm optimization (in Chinese). *J PLA Univ Sci Tech*, 2014, 15: 584-590 [舒航, 李强, 郑琴. 基于并行粒子群优化算法的变分资料同化. *解放军理工大学学报*, 2014, 15: 584-590]

Summary for “条件非线性最优扰动和繁殖向量相结合的一种集合预报方法”

An ensemble forecast method combining CNOPs with BVs

ZHOU ShiZheng¹, ZHENG Qin^{1*} & SHA JianXin²

¹*Institute of Science, PLA University of Science and Technology, Nanjing 211101, China;*

²*Troop 94906, People's Liberation Army, Suzhou 215157, China*

* Corresponding author, E-mail: qinzheng@mail.iap.ac.cn

Numerical forecasting can estimate the future state of the atmosphere or oceans. Because the atmosphere and oceans are complex and nonlinear systems, very small errors in the initial field can be amplified nonlinearly during integration of the numerical model, which may ultimately result in large errors. The true initial field cannot be obtained, and it is not possible to construct a perfect model that simulates the development of the atmospheric or oceanic state. Therefore, initial uncertainties and system instabilities result in large forecast errors. However, ensemble forecasting can be used to estimate the forecasting uncertainty. The ensemble initial perturbation has a crucial impact on the ensemble forecasting result. To obtain the initial perturbation that can capture initial field uncertainties and system instabilities, conditional nonlinear optimal perturbation (CNOP) is applied to generate initial perturbations for ensemble forecasting.

CNOP is the initial perturbation that satisfies certain physical constraints and causes the largest forecast error at forecast time. More specifically, it is a generalization of the singular vector (SV) in nonlinear field. Using the Lorenz-96 model, we generate initial perturbations by combining CNOPs and breeding vectors (BVs), and then compare it with the traditional breeding growing modes (BGM) method. The spectral projected gradient 2 (SPG2) optimal algorithm is used to compute CNOPs based on basic states, and we sort the BVs according to the corresponding L_2 norm magnitude. We design two ensemble samples for the forecast experiments: sample 1 (S1) and sample 2 (S2). Ensemble initial perturbations all consist of BVs in S1. CNOPs and BVs are combined to form ensemble initial perturbations in S2; we use CNOPs to replace the several larger BVs in S1 according to the BVs' L_2 norm magnitude order, and keep the remaining BVs unchanged. Both S1 and S2 are consist of 17 ensemble members, including one control forecast. Under the perfect model assumption, many ensemble forecasting numerical experiments are run on the Lorenz-96 model. The root mean square error (RMSE) and anomaly correlation coefficient (ACC) are used to evaluate the forecast results. We find that the forecast skill of S2 is higher than that of S1 in most experiments. This result suggests that initial perturbations generated using the new method better overcome the adverse impact from initial field uncertainty and system instability, and provide higher ensemble forecasting skill than the BGM method. When the initial analysis errors are fast-growing, ensemble forecasts generated by the new method can improve the control forecasts results. Furthermore, the rate of improvement increases with increasing forecast time, and is more obvious in the medium range (6–14 d). Ensemble forecasts generated using the new method can extend the effective forecast time about four days relative to the control forecasts based on the standard that the effective ACC forecast is not <0.6 . Nevertheless, for slowly-growing initial analysis errors, ensemble forecasts generated using the new and BGM method may be worse than the control forecasts. The initial analysis errors that show much faster growth behavior are easily influenced by nonlinearity, and extreme events due to strong nonlinear instability may be more likely to cause fast growth of initial analysis errors. Therefore, ensemble forecasts generated by combining CNOPs and BVs will have higher forecasting skill than the BGM method, and can improve the forecast effect of control forecast.

ensemble forecasting, conditional nonlinear optimal perturbations (CNOPs), breeding vectors (BVs), forecast skill

doi: 10.1360/N972016-01155