

辗转坐标筛选*

贡九鼎 李慧武

(浙江省气象科学研究所)

提 要

在只有一个主要因子的前提下, 给出一个不涉及到因子权重而输出唯一相似样品的算法。算法里体现了因子间的相互作用。

关键词: 稠密集; 有限集; 辗转坐标筛选。

一、简单的数学框架

1. 最近距离在有限集里的多值性

预报中要求在已知样品曲线 $f_1, f_2, \dots, f_m$ 中找出一条样品曲线 f_e , 使 f_e 与待报样品 f_o 最接近。该问题即是在函数空间里求点列 $\{f_i\}$ 以 f_o 为极限的收敛点 f_e 。

距离空间 R^n 的点列 $\{f_i\} = \{(x_{i1}, x_{i2}, \dots, x_{in})\}$ 收敛于点 $f_o = (x_{o1}, x_{o2}, \dots, x_{on})$ 的充要条件是 f_i 的每个坐标都收敛于 f_o 的每个相应坐标^[1]。即在欧氏距离 $d(f_i, f_o) = \left(\sum_{k=1}^n |x_{ik} - x_{ok}|^2 \right)^{1/2}$ 中, 当 $f_i \rightarrow f_o$ 时有 $|x_{ik} - x_{ok}| < \varepsilon$ 对一切 $k=1, 2, \dots, n$ 都成立。从而也有 $d(f_i, f_o) < \varepsilon$, ε 为无穷小量。

在有限集里, 除非 f_o 本身或者恰有 $f_e = f_o$, 对任何 $\{f_i\}$ 中的元素 f_i , 对任何坐标 k , 不等式 $|x_{ik} - x_{ok}| < \varepsilon_{kl}$ 中的 ε_{kl} 是一个有限正数, ε_{kl} 是等差递减序列 $\{\varepsilon_{kl}\}$ 的一般项 (详见本文第三节第三段)。距离 $d(f_i, f_o) \leq \left(\sum_{k=1}^n \varepsilon_{kl}^2 \right)^{1/2} = L$ 也是一个有限正数。因为同样的 L 可由无穷多组不尽相同的 ε_{kl} 生成。即以点 f_o 为圆心, 以 L 为半径的开球内的所有点都满足 $d(f_i, f_o) \leq L$ 。这是一个多值问题, 也是产生“值相似”而“形不相似”的原因^[2]。

样品曲线 $f_i(x_{i1}, x_{i2}, \dots, x_{in})$ 可表为阶梯函数, x_{ik} 表示第 i 个样品的第 k 个坐标值。

$$f_i = \sum_{k=1}^n C_k \chi_{(x_k, x_{k+1})}(x),$$

当 $x_k \in [x_k, x_{k+1})$ 时, $C_k = x_{ik}$, χ 为集合的特征函数。

图 1a 为稠密集中 f_o 与 f_e 的比较, 图中只列出三个坐标。图 1b 是 $f_e - f_o$ 的图像, 表现了一致收敛的情形。图 2 是有限集的情形。我们就是要在 $\varepsilon_1 \neq \varepsilon_2 \neq \dots$ 的有限集里求

1987年5月3日收到, 12月10日收到再改稿。

* 本文为国家气象局台风基金资助课题。

唯一的 f_e , 或者说在该集里建立全序关系. 本文中的样品和点, 因子和坐标是指同一件事.




图1 稠密集中 f_o 与 f_e 的比较 (a) 及 $f_e - f_o$ 的图像 (b)
实线为 f_o , 虚线为 f_e .




图2 在有限集的情形
实线为 f_o , 虚线为 f_e

2. 引进筛选算子 DE

点 f_i 与 f_o 在坐标 x_k 上的距离是


$$d_{io}^k(f_i, f_o) = |x_{ik} - x_{ok}|,$$

上述线性运算在一维空间里不产生多值情形. 如果 d_{io}^k 为 f_i 的像, 那么原像 (反函数) 存在. 今以 $f_i = (d_{io}^k)^{-1}$ 记之. 在一维空间 x_k 里, 集合 $\{d_{10}^k, d_{20}^k, \dots, d_{m0}^k\}$ 的上确界 $\sup_k \{d\}$ 的原像 $(\sup_k \{d\})^{-1}$ 代表了在坐标 x_k 里与 f_o 有最大距离的点. 下确界 $\inf_k \{d\}$ 的原像 $(\inf_k \{d\})^{-1}$ 代表了与 f_o 有最小距离的点. 如果集合稠密, n 个坐标上的 n 个原像: $(\inf_1 \{d\})^{-1}, (\inf_2 \{d\})^{-1}, \dots, (\inf_n \{d\})^{-1}$ 是同一个点. 即有 $(\inf_1 \{d\})^{-1} = (\inf_2 \{d\})^{-1} = \dots = (\inf_n \{d\})^{-1}$. 该点就是 f_o 的收敛点 f_e .

有限集里情形远为复杂. 在某个一维空间里与 f_o 有最近距离的点, 在另一个一维空间里不一定是与 f_o 有最近距离的点. 即当坐标 $i \neq j$ 时, 一般有 $(\inf_i \{d\})^{-1} \neq (\inf_j \{d\})^{-1}$.

设有 m 个点, n 个坐标, 可断言点 $(\sup_k \{d\})^{-1}$ 在 n 维空间里一定不是与 f_o 有最近距离的点. 不妨考察极端情形, 即点 $(\sup_k \{d\})^{-1}$ 在其余 $n-1$ 个坐标里和 f_o 距离最近, 那么该点就是畸点. 图 3 是 $(\sup_k \{d\})^{-1} - f_o$ 的图像. 畸点理应被筛除. 故客观上存在一个筛选算子 DE. 若将 DE 对点列 $\{f_i\}$ 在所有坐标上连续作用一次 (简称 DE 作用一个周期), 至少可将 n 个一阶畸点筛除.

DE 在坐标 k 上对 $\{f_i\}$ 作用一次, 相当于将点列 $\{f_i\}$ 在坐标 k 上按对 f_o 的一维距离 $|x_{ik} - x_{ok}|$ 由大到小排列趋向于 f_o , 并筛去序列首项.

图3 $(\sup_k \{d\})^{-1} f_0$ 的图像

算子 DE 作用的第一个周期可表为

$$\begin{aligned} \text{DE}^{(1)}(\{f_i\}) &= \{f_1^1, f_2^1, \dots, f_{m-1}^1\} = \{f_1^1\}, \\ \text{DE}^{(2)}(\{f_i^1\}) &= \{f_1^2, f_2^2, \dots, f_{m-2}^2\} = \{f_1^2\}, \\ &\vdots \\ \text{DE}^{(n)}(\{f_i^{n-1}\}) &= \{f_1^n, f_2^n, \dots, f_{m-n}^n\} = \{f_1^n\}. \end{aligned}$$

$\{f_i\}$ 是未经 DE 作用的原序列, $\{f_i^1\}$ 为子列 $\{f_i^{1-1}\}$ 经 DE 作用后的子列, 每个子列的项数比上一个子列少 1.

DE 作用的第二个周期为

$$\begin{aligned} \text{DE}^{(n+1)}(\{f_i^n\}) &= \{f_1^{n+1}, f_2^{n+1}, \dots, f_{m-n-1}^{n+1}\} = \{f_1^{n+1}\}, \\ \text{DE}^{(n+2)}(\{f_i^{n+1}\}) &= \{f_1^{n+2}, f_2^{n+2}, \dots, f_{m-n-2}^{n+2}\} = \{f_1^{n+2}\}, \\ &\vdots \\ \text{DE}^{(2n)}(\{f_i^{2n-1}\}) &= \{f_1^{2n}, f_2^{2n}, \dots, f_{m-2n}^{2n}\} = \{f_1^{2n}\}. \end{aligned}$$

$\{f_i\}$ 经 DE 连续作用第二个周期后, 至少将 $\{f_i\}$ 中的 n 个二阶畸点剔除, 自然还可有第三个周期、第四个周期 ..., 这就叫辗转坐标筛选.

3. 物理上的最近点

稠密集里将 DE 一直作用下去就能输出收敛点 f_0 . 但最近距离在有限集里的多值性将导致下面“荒谬”情形. 在 DE 作用的后几个周期里, 不仅 $(\sup_i \{d\})^{-1} \neq (\sup_j \{d\})^{-1}$ 的现象早就产生, 而且也会产生 $(\sup_i \{d\})^{-1} = (\inf_j \{d\})^{-1}$ 的现象. 这就是说, 在第 i 个坐标上与 f_0 有最大距离的点, 在第 j 个坐标上却是和 f_0 有最近距离的点. 数学上的坐标毕竟不同于物理上的因子. 如果坐标 j 恰是最大权重的因子, 则点 $(\sup_i \{d\})^{-1} = (\inf_j \{d\})^{-1}$ 有可能是 f_0 在物理上的最近点, 那么算子 DE 在先行坐标 i 上就将该点剔除, 后续坐标 j 上该点已不复存在, 这显然有悖实际情形.

以下两个条件导致了物理上的唯一最近点的输出. 第一, 用实验确定 DE 的最大作用周期 t 以保证物理上的最近点不被剔除. 第二, 确定物理上最重要的一个因子, 即输出坐标. 不失一般性, 可设第一个坐标 x_1 是主要因子. 令 DE 作用 t 周期后, 在 x_1 上

输出子序列, 该子序列的末项 f_{m-m-1}^{in+1} 即为有限集里的最近点 (在物理上) f_c .

二、算法特点

1. 再谈值相似和形相似^[2]

稠密集里几何上的最近点 (收敛点) 就是物理上的最近点, 因而值相似和形相似是完全统一的. 由于多值情形, 这种统一性在有限集里不复存在. 气象上的样品曲线不同于几何图形, 离开了值相似的形相似是没有意义的, 如文献 [2] 图 1 中的样品曲线 1 与 3, 离开了形相似的值相似是不确定的 (多值性), 如文献 [2] 图 2 中的曲线 1 与 4, 1 与 2. 但是值相似应该是本质的.

算子 DE 作用在某个坐标上, 就是求 f_0 在该坐标上的值相似. 算子 DE 作用一个周期, 就是在值相似的基础上求 f_0 的形相似. 最大作用周期 t 越长, 则筛去畸点的阶数就越高, 形相似的精度也越高. 这是指立足于值相似的形相似. 由于第一节第三段里的情形, 求形相似只能到此为止, 其精度是筛去了 $m-nt$ 个畸点. 下一步是在输出坐标上求值相似. 该值相似又是在 nt 阶形相似的基础上求得的.

2. 权重问题

当预报量是诸如降水分布这样复杂的对象时, 就很难用一个数来表示, 从而给确定预报因子的权重带来困难. 即使权重可定, 则该权重一经确定后就不能改变. 这对新样品来说, 无疑是一个大弊病. 在本算法中, 每个因子的权重在该因子所在的坐标上为 1, 同时其余因子的权重皆为零. 在 DE 作用的一个周期中, 每个因子都有一次成为最大的权重因子. 在欲输出结果的时候, 空间元素已由 m 个减少到 $m-nt$ 个. 即在经过 $m-nt$ 次筛选变换后的空间里, 输出坐标的因子取得了权重 1, 其余 $n-1$ 个因子的权重一律降为零. 从表面上看, 本算法避开了确定因子权重这么一个棘手问题. 实际上在 DE 的每次作用里都把权重处理成 1 或零; 但在 DE 作用的全过程中, 权重又是在改变的. 这有点象求积分时, 在每个小区间上将被积函数视为常数的处理方法.

由此可知, 要求有一个且只有一个主要因子作输出坐标是本算法的前提条件.

3. 非线性性

由第一节第二段 DE 的作用形式可见, $k+1$ 坐标的输入就是 k 坐标的输出. $k+1$ 坐标的输出经过一个周期后又反馈给 k 坐标. 这种相互作用关系随 DE 作用次数的增加越来越密切, 传递也越来越远. 这实际上机械地体现了因子之间的相互作用, 也即体现了因子对预报量的非线性作用.

三、实际应用步骤

结合台风总降水量分布预报加以概述.

1. 构造样品空间

规定以温州为圆心, 以冲绳岛为半径的 ± 50 km 的环带为起报区. 将 1956—1984 年进入该起报区的台风个例共 135 个作为样品空间. 即 $m=135$. 样品序号按日期先后从 1 排到 135 (自然数). 由此组成序列 $\{f_i\} (i=1, 2, \dots, 135)$.

2. 确定因子 (坐标)

上述筛选法的思想萌发于对台风降水预报的多年探索. 台风路径被公认为台风降水的最重要因子, 这就解决了使用上述算法的前提条件. 我们也理所当然地将移动方向作为输出坐标. 但是台风降水的复杂性显然也不能由路径唯一确定. 另外几个与台风降水直接有关的因子是: 台风中心强度; 台风中心强度变化; 台风位置; 台风风圈范围. 台风降水应视为台风和中纬度环境流场相互作用的结果. 环境流场的因子是从 500 hPa 上将指标站的风矢进行分解, 按区域相加得出. 它们是:

- ① 福州、温州、衢州、赣州、南昌 SE 分速之和;
- ② 上述站 SW 分速之和;
- ③ 银川、延安、西安、太原、北京、郑州、宜昌、济南 NW 分速之和;
- ④ 上述站 SW 分速之和;
- ⑤ 石桓、冲绳、庵美 NE 分速之和;
- ⑥ 上述站 NW 分速之和;
- ⑦ 女岛、济州岛、射阳 NE 分速之和;
- ⑧ 上述站 NW 分速之和.

其中奇数序号者是对台风降水有正贡献的因子, 偶数序号者是对台风降水有负贡献的因子. 还有一个因子是本省出现不稳定降水的站点数. 一共是 9 个环境流场因子.

为取得比较稳定的台风移动方向, 将台风 6 h、12 h、18 h 的移动方向均作为因子, 这与台风有关的因子有 7 个. 总共有 16 个因子, 即 $n=16$.

3. 构造筛选网格 $\{\varepsilon_{kl}\}$

本筛选法其实也简单, 无非是对每个样品、每个因子多层次地用不等式 $|x_{ik} - x_{ok}| < \varepsilon_{kl}$ 加以判别排序. 故首先要在已知样品空间里对每个因子设计出筛选网格序列 $\varepsilon_{k1} > \varepsilon_{k2} > \dots$. 等差序列 $\{\varepsilon_{kl}\}$ 为正有理数, 我们取因子数 $k=16$, 序列项数 $l=31$. 序列首项 ε_{k1} 和公差由因子值在样品空间里的离散程度统计得出. 例如, 描述台风位置的经纬度, 离散度小, 网格就较细, 它的 $\{\varepsilon_{2l}\}$ 的首项 $\varepsilon_{21}=1.50$, 公差为 0.05; 描述环境流场的因子③, 离散度大, 网格就粗, 它的 $\{\varepsilon_{7l}\}$ 的首项 $\varepsilon_{71}=90.00$, 公差为 3.00.

如第一段所述, 样品空间 $\{f_i\}$ 是以日期先后为序号的全序集. 依据每个因子的 $\{\varepsilon_{kl}\}$, 连续进行 DE 变换, 可由空间 $\{f_i\}$ 得出空间 $\{f_i^{l+1}\}$. 该空间则是以距离大小为序号的全序集. 最后一个序号 $f_{m-i, n-1}^{l+1}$ 代表了与待报样品距离最近的历史样品. 应该强调的是, 我们得到的是一个历史样品和待报样品的全序关系, 而不是它们之间距离的值. $\{\varepsilon_{kl}\}$ 的作用只在于建立全序关系. 图 4 的棱锥通道形象地表示了 $\{\varepsilon_{kl}\}$ 的作用. $|x_{ik} - x_{ok}|$ 好比一只球, 它从 ε_{k1}^2 的通道大口处滚入, 当球的直径大于或等于通道边长时就停止. 依据停止时的 l 值, 将所有历史样品在第 k 个坐标上排序. 这就是




图4 $\{\varepsilon_{kl}\}$ 作用的形象表示

DE ($\{f^{k-1}\}) = \{f^k\}$ 的直观表述.

将 16 组的 $\{\varepsilon_{kl}\}$ 连同历史样品因子值作为数据文件存入盘中, 当待报台风进入起报区时, 即从台风情报电码和天气图上读数, 将数据从键盘上输入 PDP-11 或 IBM-PC (编译), 从风矢的预处理到输出最近历史样品约 5—6 分钟.

四、效果初析

经试验, 取最大作用周期 $t=5$.

所谓最近样品是与待报台风 f_e 在后期路径和降水分布上最接近的历史台风 f_e . 本筛选法正确与否, 就看其输出序列的末项 $f_{m-tN-1}^{tN+1} = f_{135-5 \times 16-1}^{5 \times 16+1} = f_{54}^{81}$ 是否为 f_e .

1. 拟合情形

对 135 个历史样品中的每一个进行筛选, 由于欲拟合者处在样品空间中, 故输出序列的末项 f_{54}^{81} 必为其本身, 序列的最后第二项 f_{53}^{81} 才是筛选结果. 该结果中有 119 个确系 f_e , 还有 16 个不是 f_e . 换句话说, 在历史样品中还能找到更接近于 f_e 的样品. 故本筛选法对 16 个样品是失败的, 拟合率大于 96%.

2. 试报情形

本筛选法对 1985—1986 年 5 个台风进行了业务预报, 其中 4 个找到了历史上的最近台风. 8617 找到的是 7410, 而 8617 的 f_e 却是 6721, 故本筛选法对本次台风预报失败 (见表 1). 本筛选法对 8510 台风的预报优于其它预报方法. 图 5、图 6、图 7 为 8510 与其最近点 7503 的比较.




图5 7503 台风浙江省过程降水分布




图6 8510 台风浙江省过程降水分布




图7 8510 与 7503 台风的路径

3. 与多维点聚法的比较

表 1 辗转坐标筛选与多维点聚法的比较

待 报 台 风		8506	8510	8605	8615	8617
与待报台风最接近的样品 f_e		6126	7503	6506	7615	6721
输 出 结 果	辗转坐标筛选下的末项 f_{54}^{81}	6126	7503	6506	7615	7410
	多维点聚下的最小欧氏距离	7805	7806	5905	7910	6120

多维点聚法^[3]实际上是求欧氏距离. 欧氏距离最小的点即为欧氏距离下的最近点. 该点是否为 f_e 呢? 经对同一样本空间的统计, 拟合率仅为 47%. 如表 1 所示, 5 次试报台风中用多维点聚法所找到的历史台风竟没有一个是 f_e . 这并不奇怪, 单用欧氏距离过于简单化, 其误差随维数的增多而急剧加大. 且不谈本筛选法所具有的特点, 至少本筛选法与多维点聚法比起来是好的.

参 考 文 献

- [1] 郑维行、王声望, 1985, 实变函数与泛函分析概要, 第五章, 第六章, 高等教育出版社.
- [2] 李开乐, 1986, 相似高度及其使用技术, 气象学报, 44, 第 2 期, 174 — 183.
- [3] 谭冠日, 1980, 气象站数理统计预报方法, 第六章, 科学出版社.