

文章编号: 1006-4354 (2004) 06-0001-04

支持向量机方法在天气预报中的应用

赵国令¹, 肖科丽²

(1. 陕西省气象局, 陕西西安 710014; 2. 陕西省气象台, 陕西西安 710014)

摘 要: 简要介绍了支持向量机方法(SVM)方法的基本原理和使用方法。用高空 500 hPa 月平均高度、海洋温度以及地面资料作为因子, 对西安 6—9 月份降水总量建立了 SVM 预报模型。

关键词: 支持向量机; SVM; 预报模型

中图分类号: P456.9

文献标识码: A

对于非线性划分问题, 一种新的数学方法——支持向量机(Support Vector Machines 简称 SVM)方法, 正在迅速推广使用, 为解决非线性分类问题提供了一种新方法。陈永义教授首先将其介绍并应用到了气象领域^[1-2]。本文简要介绍了 SVM 方法的基本原理和使用方法, 并用此制作了西安 6—9 月汛期降水短期气候预测方法。

1 SVM 方法简介

1.1 线性划分问题

在 N 维向量空间 $x \in \mathbf{R}^N$ 中(预报业务中 x 代表 N 个因子序列), 预报对象 y 的类别是完全分离的(假定 y 只有两种情况), 则可用一超平面 L 将两类对象进行划分(见图 1), L_1, L_2 为两个边界超平面。超平面 L 的方程为:




图 1 完全分离的两类样本示意图

$$(\mathbf{w} \cdot \mathbf{x}) + b = 0. \quad (1)$$

其中 \mathbf{w}, \mathbf{x} 为向量, \mathbf{w} 为超平面的法向向量, b 为方程参数, $(\mathbf{w} \cdot \mathbf{x})$ 为内积运算。假定两条边界 L_1 和 L_2 其与 L 的距离是 1, 则两条边界的方程为:

$$(\mathbf{w} \cdot \mathbf{x}) + b = \pm 1. \quad (2)$$

设 N 维空间上的点 \mathbf{x}_1 在 L_1 上, \mathbf{x}_2 在 L_2 上, 则满足方程:

$$(\mathbf{w} \cdot \mathbf{x}_1) + b = -1,$$

$$(\mathbf{w} \cdot \mathbf{x}_2) + b = +1,$$

$$\text{两式相减有: } (\mathbf{w} \cdot (\mathbf{x}_2 - \mathbf{x}_1)) = 2. \quad (3)$$

进而有:

$$\left(\frac{\mathbf{w}}{\|\mathbf{w}\|} \cdot (\mathbf{x}_2 - \mathbf{x}_1) \right) = \frac{2}{\|\mathbf{w}\|}, \quad (4)$$

$\|\mathbf{w}\|$ 为向量 \mathbf{w} 的模。(4)式左边恰好就是连接 $\mathbf{x}_1, \mathbf{x}_2$ 的向量在划分超平面法方向上的投影, 它是最大间隔的 2 倍。 L_1 与 L_2 距离越大, 说明两类样本分开的越远, 效果越好。求最大间隔等价于求 $\|\mathbf{w}\|$ 的最小值问题。为计算方便, 它等效于求 $\|\mathbf{w}\|^2$ 的最小值问题。

要使所有训练样本点分类正确, 应成立:

$$(\mathbf{w} \cdot \mathbf{x}_i) + b \geq 1, \text{ 若 } y_i = 1;$$

$$(\mathbf{w} \cdot \mathbf{x}_i) + b \leq -1, \text{ 若 } y_i = -1.$$

其中 $y_i \in \{-1, 1\}$ 为预报量。两式可以合并为:

$$y_i ((\mathbf{w} \cdot \mathbf{x}_i) + b) \geq 1, \quad (5)$$

这样, 建立线性支持向量机的问题转化为求解如下一个二次凸规划问题:

收稿日期: 2004-07-16

作者简介: 赵国令 (1961-), 男, 河北沧州人, 学士, 高工, 从事气象业务管理工作。

$$\left\{ \begin{array}{l} \min \left(\frac{1}{2} \| \mathbf{w} \|^2 \right) \\ \text{约束条件: } y_i \left((\mathbf{w} \cdot \mathbf{x}_i) + b \right) \geq 1, \end{array} \right.$$

可求得最优超平面决策函数为:

$$M(\mathbf{x}) = \text{Sgn} \left(\sum_{s, v} \alpha_i^* y_i (\mathbf{x} \cdot \mathbf{x}_i) + b^* \right). \quad (6)$$

其中 α_i^* , b^* 为确定最优划分超平面的参数,

Sgn 为符号函数。求和号 \sum 下的 s, v 表示只对支持向量求和, 非支持向量对应的 α_i 都为零。支持向量一般只占样本的少数。

只有少数几个训练样本点就决定了最优超平面, 其余的样本均不起作用, 称这样的样本点为支持向量。超平面的划分不是依赖于所有点, 而只是由支持向量决定, 这样可极大地减少计算量。

1.2 线性不可分的情况

对于线性不可分的情况, 通过引入松弛变量 $\xi_i \geq 0$, 修改目标函数和约束条件, 应用完全类似的方法可以求解。与 (6) 类似的新的规划问题为:

$$\left\{ \begin{array}{l} \min \left(\frac{1}{2} \| \mathbf{w} \|^2 + C \sum_i \xi_i \right) \\ \text{约束条件: } y_i \left((\mathbf{w} \cdot \mathbf{x}_i) + b \right) \geq 1 - \xi_i \end{array} \right. \quad (7)$$

若 ξ_i 都为零, (7) 式就变成了线性可分问题 (6) 式。(7) 式中大于零的 ξ_i 对应错分的样本, 参数 C 为惩罚系数。加大 C 的值就会逐渐减少错分样本的个数。

1.3 非线性划分问题

对于高度非线性的分类问题, 对 (6) 式通过一个非线性映射

$$\mathbf{X} = \Phi(\mathbf{x}) \quad (8)$$

可把样本空间映射到一个高维以至无穷维的特征空间中, 使其转化为线性问题, 如图 2。

这样就可应用线性学习机的方法分类。求解过程只需增加计算核, 并不需要非线性映射 $\Phi(\mathbf{x})$ 的显式表达式。将 (8) 式代入 (6) 式得:

$$M(\mathbf{x}) = \text{Sgn} \left(\sum_{s, v} \alpha_i^* y_i (\varphi(\mathbf{x}) \cdot \varphi(\mathbf{x}_i)) + b^* \right), \quad (9)$$

令 $K(\mathbf{x}, \mathbf{x}_i) = \varphi(\mathbf{x}) \cdot \varphi(\mathbf{x}_i)$, 则:

$$M(\mathbf{x}) = \text{Sgn} \left(\sum_{s, v} \alpha_i^* y_i K(\mathbf{x}, \mathbf{x}_i) + b^* \right). \quad (10)$$

二元函数 $K(\mathbf{x}, \mathbf{x}_i)$ 通常称为核函数 (简称核)。对称正定的连续核称为 Mercer 核, 由点积




图 2 非线性划分问题 (a) 经过线性变换: $\mathbf{X} = \Phi(\mathbf{x})$, 转为线性划分问题 (b) 的示意图

定义的核 ($K(\mathbf{x}, \mathbf{x}_i) = \varphi(\mathbf{x}) \cdot \varphi(\mathbf{x}_i)$) 必是 Mercer 核。Mercer 核很多, 如径向基函数核、多项式函数核等。

(10) 式就是非线性支持向量学习机的最终分类决策函数。虽然用到了特征空间及非线性映射, 但实际计算中并不需要知道他们的显式表达。只需要求出支持向量及其支持的“强度”和阈值, 通过核函数的计算, 即可得到原来样本空间的非线性划分输出值。

对非线性不可分的情况, 可采取与线性不可分相同的方法处理。

通过上述变换和计算, 用线性的 SVM 算法解决了非线性 SVM 问题。而线性 SVM 的算法归结为一个凸约束条件下的二次凸规划问题, 对此已有很多成熟的算法和应用软件, 其中陈永义教授组织在 Windows 下开发了应用集成软件, 已在全国气象部门推广使用。

2 用 SVM 方法预报汛期 (6—9 月) 降水

在日常应用中, 必须把总样本分为三部分, 即训练样本、实验样本和检验样本。训练样本用于学习训练建立模型, 样本的绝大部分应放在这里; 实验样本用于进一步调整模型的参数, 根据经验, 这部分样本可控制在总样本的 1/4 左右; 检验样本用于预报检验。

对短期气候预测而言, 影响汛期降水的因素很复杂, 很难找出物理意义明确的因子, 所以用线性相关系数法普查方法选择月平均海温、500 hPa 月平均高度与汛期 (6—9 月) 总降水量相关密切的因子。由于每个月都有多个格点的海温和高空资料与降水相关较高, 为了能将更长时间尺

度的信息反映进来, 只是逢双月分别选一个高空和海温因子。共选出 21 个因子。其中地面因子 9 个, 海温和高空各 6 个。降水资料长度为 1960—2001 年, 共 42 a。逐旬平均地面温度、旬平均气温与降水的线性相关不明显, 因此用点聚图方法选择。这种方法无具体定量指标, 只要认为多雨点与少雨点在点聚图上分离的较好即可入选。例如, 西安 4 月上旬、10 月中旬气温与汛期降水的相关系数都只有 0.2 左右, 但点聚图效果非常好。

表 1、表 2 给出了 6—9 月降水量与前一年海温、500 hPa 平均高度的相关系数。相比之下地面因子的相关系数很小, 如果用常规统计方法建立模型, 地面因子很难入选。而 SVM 模型是非线性的, 与因子的相关系数无关, 这就是 SVM 的优势所在。

42 a 资料中, 用 30 a 作为训练样本, 8 a 实验样本, 4 a 检验样本。取径向积核函数:

$$K(\mathbf{x}, \mathbf{x}_i) = \exp(-g \|\mathbf{x} - \mathbf{x}_i\|^2),$$

表 1 6—9 月总降水量与前期海温的相关系数

时间/月份	纬度/°N	经度	相关系数
02	0	125°W	0.46
04	15	135°E	0.45
06	30	145°W	0.41
08	30	145°W	0.43
10	40	145°W	0.46
12	10	165°W	0.43

表 2 6—9 月总降水量与前期 500 hPa 平均高度的相关系数

时间/月份	纬度/°N	经度	相关系数
02	15	80°E	0.46
04	30	140°E	-0.48
06	15	0	-0.45
08	70	140°E	-0.54
10	75	160°W	-0.41
12	55	90°E	-0.50

通过训练学习后求得决策函数为:

$$M(\mathbf{x}) = \text{Sgn} \left(\sum_{s,y} \alpha_i y_i K(\mathbf{x}, \mathbf{x}_i) + b \right),$$

式中 g 为迭代筛选确定的, α_i 为建模过程中依据条件约束自动生成, 不需人为选取。

尽管选定径向积函数作为建立 SVM 模型的核函数, 但伴随参数值选取的不同, 函数形态会发生较大变化, 引起 SVM 模型的变化。由于参数的选择没有规律, 因而进行了大量的试验, 表 3 给出了其中 7 次有代表性的结果。由表 2 可见, 惩罚系数 C 和 g 初值的选择, 使结果发生很大变化, 而且选择都是人为的, 这也是 SVM 方法的不足之处。当 $C > 100$ 或 $C < 0.5$ 时, 结果变化不大, 因此表中未给出。通过试验, 当取 $C = 0.9$, $g = 1$ 时, 所得结果较为满意。此时历史拟合无一次错误; 4 a 预报, 有 3 a 正确, 只是所有用来训练的样本, 都成为支持向量。

表 3 7 次不同初值的迭代结果

C 初值	C 增量	g 初值	g 增量/倍	C 值迭代结果	g 值迭代结果	支持向量数	错分样本数	4 a 预报准确数
100	10	10^{-9}	10	120	0.01	19	0	1
100	10	0.1	2	100	0.1	22	0	2
50	5	10^{-4}	5	85	0.01	18	0	1
1	2	10^{-5}	3	5	0.02	25	4	1
0.5	0.5	0.01	5	2.5	0.05	27	2	2
0.5	0.1	0.1	2	1	0.2	29	2	2
0.5	0.1	0.1	5	0.9	1	30	0	3

3 小结

3.1 SVM 模型最大特点是非线性的, 因此选择

因子时, 不一定只是依靠相关系数, 可根据物理意义, 或用点聚图等方法多方面选择, 因子不需

文章编号: 1006-4354 (2004) 06-0004-04

西北区一次联合探测层状云系云物理特征分析

陈争旗¹, 陈保国¹, 许新田², 李照荣³, 郭 强¹

(1. 陕西省人工影响天气办公室, 陕西西安 710014; 2. 陕西省气象台, 陕西西安 710014;
3. 甘肃省人工影响天气办公室, 甘肃兰州 730020)

摘 要:对 2003-09-17 我国西北地区东部层状云降水天气过程的层状云系进行了联合探测。经观测对比分析发现: 对同一天气系统开展多省联合探测, 对认识云系发展变化、结构特征及降水潜力很有帮助; 同一条锋面云系由于流场结构的差异, 其不同位置的云层结构、温度、湿度、水汽含量存在一定差异; 陇东和陕北虽然同处于副高西侧的偏南气流里, 但是, 低层天水处于反气旋区, 抑制了水汽辐合, 而延安处于横切变右侧的气旋性辐合区, 有利于低层水汽辐合上升, 促使该地区云系发展加强, 其过冷层厚度大于天水地区; PMS 粒子测量系统测得在整个过冷层中, 小云粒子的数浓度平均值天水比延安少 1 个量级, 2D-P 测出延安的粒子谱较宽, 说明上述条件下天水地区人工增雨潜力较小, 延安地区相对条件较好, 人工增雨潜力大。

关键词: 联合探测; 层状云系; 结构特征

中图分类号: P426.5

文献标识码: B

为了进一步开发云中水资源, 提高人工增雨作业的科技水平和效益, 近年来一些省市相继在飞机上安装了宏微观的大气探测设备, 以加深当地降水云系特征, 特别是云微物理结构的了解。但由于各种条件限制, 多数情况下仅为一架飞机单独开展探测和人工增雨作业, 这对大尺度天气背景降水云系的探测有一定局限性。针对我国西北

地区东部一次层状云降水天气过程, 陕、甘两省制定了飞行探测方案, 2 架飞机开展了跨省联合飞行探测, 通过对云系不同演变阶段宏微观大气的资料对比分析, 加深了对西北地区降水性层状云系发展变化及其云物理特征的认识。

1 天气形势分析

2003-09-17, 受西太平洋副热带高压外围西

收稿日期: 2004-08-31

作者简介: 陈争旗 (1959-), 男, 陕西兴平人, 学士, 高工, 从事天气预报和人工影响天气工作。

基金项目: 国家科技部“西部开发科技行动”重大攻关项目 (2001BA901A41)

线性化。

3.2 SVM 模型中不受因子个数的限制, 也不受因子间相关与否的影响。

3.3 模型经过非线性变换, 将非线性问题转为线性, 其判断条件的确定, 不一定由所有样本决定, 而由关键的少数支持样本 (支持向量) 决定。

3.4 方法只是初次应用, 所建的方法还有待于在实践中检验。参数初值的选择有一定人为性, 而且初值的不同, 影响迭代结果; 程序并不一定保证收敛到最优值, 因此需要多次人为选择试验。

参考文献:

- [1] 陈永义, 俞小鼎, 高学浩, 等. 处理非线性分类和回归问题的一种新方法 (I)——支持向量机方法简介 [J]. 应用气象学报, 2004, 15 (3): 345-353.
- [2] 冯汉中, 陈永义. 处理非线性分类和回归问题的一种新方法 (II)——支持向量机方法在天气预报中的应用 [J]. 应用气象学报, 2004, 15 (3): 356-365.