

支持向量预选取的域着色 Vorono 图方法

杨 洁 郑 宁 徐海涛 刘 董 徐 明

(杭州电子科技大学计算机学院 浙江 杭州 310018)

摘 要 支持向量机是建立在统计学习理论基础上的 一种机器学习方法,它通过对支持向量的训练而具有很好的分类推广能力。但是从训练样本中选取合适的支持向量很困难,而对噪音样本的训练会使支持向量机的泛化能力下降。在分析了支持向量的分布特性和 Vorono 图在特征空间划分的优势后,提出一种利用域着色 Vorono 图来选取支持向量的方法。该方法能大量减少训练样本集中的非支持向量,排除孤立噪音样本,最终得到一个包含候选支持向量的训练样本集。仿真实验结果说明了该方法的有效性和可行性。

关键词 支持向量 预选取 噪音 Vorono 图

REGION COLOURED VORONOI DIAGRAM FOR PRE-EXTRACTING SUPPORT VECTOR

Yang Jie Zheng Ning Xu Haitao Liu Dong Xu Ming

(College of Computer Hangzhou Dianzi University Hangzhou 310018, Zhejiang China)

Abstract Support Vector Machine (SVM) is a machine learning method based on statistical study rationale. It has excellent classified promotion ability through on training support vectors (SV). However, it is difficult to get proper SVs from training sample. Training noise sample would make SVM's generalization goes down. In this paper, a new method for pre-extracting support vectors using region coloured Vorono diagram was introduced after analyzing the distribution character of SV and the advantage of Vorono diagram in feature space partition. This method reduced the non-support vectors centralized in the training sample greatly and eliminated the lone noise sample, and obtained a training sample set which only consists of the instances that were likely to be SV. The emulation experiment result indicates the validity and feasibility of this method.

Keywords Support vector Pre-extracting Noise Vorono diagram

0 引 言

统计学习理论是在上个世纪 70 年代逐渐发展建立起来的一门理论,它是机器学习的一个重要组成部分。该理论系统地研究了机器学习的有关问题,特别是对有限样本下的统计学习问题。在统计学习理论创立的同时,Vapnik 等人也在研究如何构造基于统计学习理论的机器学习算法。90 年代,Vapnik 等人提出了支持向量机算法(SVM)^[1]。该算法主要应用于模式识别领域。当前,把入侵检测看作一个模式识别的问题,使用 SVM 来进行研究,已经成为一种趋势^[2,3]。

在支持向量机中,计算的复杂度不再取决于空间维数,而是取决于样本数,尤其是样本中的支持向量(SV)的数目。因此,当样本的数量太多的时候,训练就需要耗费大量的时间。在实际的样本获取过程有可能存在噪音^[4]。当样本中含噪时,SVM 可能会产生过学习的问题,使它的泛化能力下降^[5]。这些都是影响支持向量机应用推广的主要问题。支持向量机利用边界的少数向量(支持向量)构造一个最优分类超平面,那些远离分类超平面的样本对分类不起作用^[6]。在训练分类器的过程中,支持向量位于样本空间两类的交遇区^[7]。因此,通过预先对训练样本进行筛选,选取其中的支持向量,剔除掉混杂于其中噪音样本,可以很大地降低计算量,提高训练的速度,提高训练的效果,

获得更好的分类性能。目前,对支持向量预选取的一些方法对噪音样本难以处理,相关的阈值等参数要靠经验数据来设定^[4]。

本文提出一种域着色 Vorono 图方法 RCMV(Region Colored Vorono diagram Method)来预先对样本进行处理。该方法利用对 Vorono 图中的域进行着色来剔除掉其中可能存在的孤立噪音样本,得到一个基本上只包含支持向量的少量候选样本的集合。由于支持向量机只训练候选样本,这样可以加快训练速度。对孤立噪音样本的修剪也降低了噪音样本对向量机分类能力的干扰,提高了训练效果,有效地防止了因大量孤立噪音样本混杂而造成 SVM 过学习和泛化能力的减弱。

1 支持向量机

支持向量机是一种在高维特征空间使用线性函数假设空间的学习系统。根据最优化理论,它选择一个合适的学习算法进行训练。支持向量机寻找一个满足分类要求的最优分类超平面,用这个超平面对样本数据进行分类。它最大的特点是根

收稿日期:2007-07-09 浙江省自然科学基金(Y106176);浙江省科技厅科技计划项目(2007C33058)。杨洁,硕士生,主研领域:网络安全,入侵检测。

据 Vapnik 风险最小化原则, 尽量提高学习机的泛化能力。即 SVM 通过对少量样本的学习就具有很好的分类推广能力。因此, 将 SVM 应用到入侵检测中, 可以保证在先验知识不足的情况下, 分类器仍能保持较好的分类正确率^[3], 使得系统有较好的检测性能。但是 SVM 直接训练可能含有噪音的所有样本数据, 不但会大量增加计算量, 而且可能会降低 SVM 的泛化能力。如果能在 SVM 训练前对所有样本数据进行一些过滤, 将其中的一些噪音和不能影响 SVM 分类能力的样本数据排除掉, 那么, 可以很大地提高 SVM 的学习速度和效果。

2 支持向量预选取的 RCM 方法

2.1 Vorono 图

Vorono 图也称为泰森多边形。设 $P_i (i=1, 2, \dots, n)$ 为二维欧氏空间(平面)上的 n 个点, 将由 $V(P_i) = \bigcap_{1 \leq j \leq n, j \neq i} \{p | d(p, P_i) < d(p, P_j)\} (i=1, 2, \dots, n)$ 所给出的对平面的分割, 称为以 $P_i (i=1, 2, \dots, n)$ 为生成元的 Vorono 图, 通常简称为 Vorono 图, 其中 $d(p, P_i)$ 为 P_i 和 p_i 之间的 Euclid 距离^[8]。

Vorono 图在地理、气象等许多领域都有广泛的应用。它具有很多特性, 这里只列出一些跟本文应用相关的特点。在 Vorono 图中, 任何一个 Vorono 区域内的点到该区域中心的距离都比到另外区域中心的距离要小。Vorono 图根据样本数据集合中的点在特征空间中的分布特性给出了一种对特征空间的划分, 体现了样本数据在空间的局部邻接特性^[7]。Vorono 图在特征空间中给每个点划分一个域(大部分都是封闭多边形, 但不一定所有的域都是封闭的多边形)。

2.2 域着色 Vorono 图

定义 1 在大量支持向量机的训练样本中, 只与另一类样本相邻的噪音样本称为孤立噪音样本。

SVM 将待测数据使用超平面分为两类, 同类样本都是聚集的, 只在超平面附近才有两类不同样本相邻。在大量训练样本的情况下, 同类样本能很好地体现其聚集性。这就是在大量样本中判断孤立噪音样本的理论依据。在同类样本聚集的区域中, 如果出现了异类的孤立样本, 那么, 可以判定这个孤立样本是孤立噪音样本。进行支持向量的预选取的一个重要原因是因为训练样本点的数量过大, 严重地影响了 SVM 的训练速度。因此, 在极少量样本(如几个, 十几个)情况下来讨论支持向量的预选取是没有什么实际意义的, 也不能在这种条件下来判定孤立噪音样本。由于 Vorono 图在体现样本数据在空间的局部邻接特性上具有优势, 本文将采用 Vorono 图来判断任意两个样本之间是否相邻。

定义 2 域着色 Vorono 图为一个三元组 $G = \langle S, C, R \rangle$ 。

S 表示有 n 个样本点的训练样本集合 $S = \{e_1, e_2, \dots, e_n\}$ 。对于 S 中的每个元素, 都有其类别(class)属性, 表示为 $e_i.class$, 取值为 $class_first$ (第一类样本)或者 $class_second$ (第二类样本), 可用 0 1 表示。

C 表示 Vorono 图中的颜色, $C = \{red, blue, null\}$ 。red(红色)表示着红色的域是选取的有效域, 域内的训练样本为候选的训练样本; blue(蓝色)表示着蓝色的域是修剪掉的无效域, 域内的训练样本为孤立噪音样本; null(不着色)表示不着色的域是普通域, 域内的训练样本不会进入候选训练样本集合。

R 表示使用 Vorono 图对 S 中的 n 个点进行划分后, 得到的

Vorono 图中包含有训练样本的 n 个域的集合 $R = \{r_1, r_2, \dots, r_n\}$, $R \Leftrightarrow S$ R 中的元素与 S 中的元素一一对应。对于 R 中的每个元素, 即每一个域, 都有其颜色(color)属性, 表示为 $r_i.color \in C$ 。 $r_i.color$ 的初始值为 null, 用 $labors(r_i, ColorType)$ 表示与 r_i 相邻并且颜色属于 $ColorType$ 的域的集合, $labors(r_i, ColorType) \subset R$ 。

定义在三元组 $G = \langle S, C, R \rangle$ 上的函数 $num(RegionSet, ClassType)$, 返回值为在域集合 $RegionSet$ 中, 域所对应训练样本的类别属性(class)为 $ClassType$ 的样本数量。则域的颜色 color 可用下面的公式表示:

$$r_i.color = \begin{cases} red & num(labors(r_i, red) | null), e_i.class > 0 \\ & and \ num(labors(r_i, red) | null), \rightarrow e_i.class > 0 \\ null & num(labors(r_i, red) | null), \rightarrow e_i.class = 0 \\ blue & num(labors(r_i, red) | null), blue, e_i.class = 0 \end{cases}$$

对于任意一个 Vorono 图中的域, 它的 color 由它及其周围的域对应的训练样本点的 class 来决定。当域 r_i 对应样本点与 r_i 的相邻域对应的所有样本点的 class 都一致时, r_i 显然不是处于两类样本相邻的位置, 域内的样本不是 SV, 因此 color 仍为 null。当域 r_i 对应样本点与 r_i 的相邻域对应的所有样本点的 class 都不一致时, r_i 内的样本是孤立噪音样本, 因此 color 为 blue。其他情况下, r_i 既与其它类样本相邻, 又不是孤立噪音样本, 它就是需要寻找的候选训练样本, 因此 color 为 red。需要说明的是, 这个公式并不适用于极少量样本, 这点在定义 1 中已经有说明。

2.3 RCM 方法

RCM 算法在实现过程中, 虽然要在 Vorono 图构造完成后才能对其中的域进行着色, 但是实际上在构造 Vorono 图的过程中就能得到初步的着色信息。因为训练样本点和域之间存在一一对应的关系, 所以可以在实际构造 Vorono 图的同时, 将样本和其对应的域之间的信息绑定在一起, 利用训练样本来记录它所在的域的颜色信息。因此, 在下面算法的实现步骤中, 并不严格地区分样本与其对应的域, 所说的样本的颜色和域的颜色具有相同的含义。在构造完 Vorono 图时, 根据训练样本中记录的颜色信息也就得到了初步的 RCV(Region Colored Vorono diagram)图。然后在此基础上, 识别并修剪孤立噪音样本, 得到最终的 RCV 图。

RCM 算法的步骤:

(1) 对给定的有限训练样本集 $S = \{e_1, e_2, \dots, e_n\}$, 定义集合 S 上的 Vorono 图着色函数 $region_paint(e_i, e_j)$ 。利用填色函数 $region_paint(e_i, e_j)$ 构造 S 的 Vorono 图。在构造的过程中, 如果 e_i 和 e_j 相邻, 判断 e_i 和 e_j 是否是属于同一类的训练样本, 如果不是, 则将 e_i 和 e_j 的颜色置为 red。待 Vorono 图构造完成后, 根据训练样本中记录的颜色信息就得到了初步的 RCV 图。将 red 样本存放到待筛选的样本集合中。

(2) 假设 $V = \{x_1, x_2, \dots, x_j\}$, $x_i \in \{e_i | i=1, 2, \dots, n\}$ 是通过 (1) 和 (2) 得到的 red 样本集。对 V 中每一个样本, 顺时针方向逐个比较与其相邻的(与其所在域有公共的边)样本。考查在所有与它相邻的样本中是否含有与它属于同一类的样本, 如果没有, 则根据定义 1 可以判定它为孤立噪音样本, 将颜色置为 blue。比如, x_i 是 V 中的一个第一类样本, 如果与 x_i 相邻的样本都是第二类样本。那么, 根据定义 1 可以判定 x_i 为孤立噪音样

本,用 blue 标记 x_i 所在的域。

(3) 对得到的每一个 blue 样本,用类似 (2) 中的方法考查与 blue 样本相邻的所有 red 样本。如果被考查的 red 样本和与其相邻的所有 red 样本属于同一类,就取消被考查的样本的颜色。比如, x_i 是一个属于第一类样本的孤立噪音样本, x_j 是一个与 x_i 相邻的第二类 red 样本。判断与 x_i 相邻的 red 样本中是否存在第一类样本,如果没有,则将 x_i 的颜色取消。

经过上面的算法,得到了最终的 RCV 图,其中颜色为 red 的少量样本就是最终的候选训练样本,其中包含绝大部分的 SV 甚至全部的 SV 并裁减掉了部分可能存在的噪音样本。由上面的算法实现过程可以看出,RCVM 的时间复杂度主要考虑的是 Vorono 图的构造过程和构造后对孤立噪音样本的修剪过程。Vorono 图的构造过程的时间复杂度为 $O(n \log n)$ [9],而修剪过程的时间主要取决于孤立噪音样本点的数量及其周边分布情况。通常孤立噪音样本点的分布是比较稀疏的,多个孤立噪音样本点的邻域不会重叠,此时的时间复杂度为 $O(n)$ 。并且,在实际的预选取过程中,孤立噪音样本点数量是远小于 n 的,耗费的时间很少。因此,RCVM 的时间复杂度为 $O(n \log n)$ 。

3 仿真试验

仿真实验模拟的样本实例是两类同心圆样本, $x + y = z$ 。仿真实验的样本集合 S 包含 61 个二维坐标点,随机分布在 $x + y = 19$ 的范围内。第一类样本点 16 个,其中 15 个随机均匀分布在半径为 $r \in [0, 10]$ 的范围内;第二类样本点 45 个,随机均匀分布在半径为 $r \in (10, 19)$ 的范围内。并在 $r \in (10, 19)$ 的范围内人为添加一个第一类样本点。为使其成为孤立噪音样本点,在 $r \in (10, 19)$ 的范围内随机选取一个离其他的第一类样本点距离足够远的位置。

在下面两个实验图中,实心圆点表示的是第一类样本;空心圆点表示的是第二类样本;单向斜线阴影表示的是 red 交集斜线阴影表示的是 blue 空白表示的是 null 图 1 是样本点原图执行了算法步骤 (1) 和 (2) 之后的初步 RCV 图。可以从图 1 中看到,61 个样本点被划分到 61 个多边形域中,每一个点对应一个多边形域。图 1 中共有 31 个 red 域。在 16 个第一类样本点中有 10 个样本点所在域为 red 在 45 个第二类样本点中,有 21 个样本点所在域为 red 可以清楚地看到,两类样本点交界的域都为 red 把这些 red 域内的样本点加入到候选训练样本集 V 中,那么 V 中含有 31 个样本。




图 1 完成算法步骤 (1) 和 (2) 之后的初步 RCV 图

图 2 是执行完步骤 (3) 后最终得到的 RCV 图。可以从图 2 中看到,在 61 个多边形域中,共有 28 个 red 域。在 16 个第一类样本点中有 9 个样本点所在域为 red 在 45 个第二类样本点中,有 19 个样本点所在域为 red 并且,右上方有一个第一类样本点所在域被标记为 blue 这个第一类样本点就是需要剔除的孤立噪音样本点。与图 1 相比,图 2 中的 red 域进一步减少了 3 个,而且识别并标记了一个孤立噪音样本点。最终得到的候选训练样本集 V 包含有 28 个样本,即图 2 中 red 域内的样本点。




图 2 完成算法后得到的最终 RCV 图

因为原样本数据集合存在噪音,在将原样本数据集合 S 除去噪音后得到样本数据集合 S' 。选取二次多项式核函数: $K(x, x_i) = [(x \cdot x_i) + 1]^2$ 来进行试验。用除噪后的样本数据集合 S' 和预选取边界向量集合 V 分别对非线性可分的两类同心圆样本进行训练。

得到的实验结果是除噪后样本数据集合 S' 和预选取边界向量集合 V 训练后得到相同的支持向量。这说明经过 RCVM 方法得到的预选取边界向量集合不但去除了原样本数据集合中存在的孤立噪音样本,而且包含了原数据集合中的支持向量。充分说明了该方法的有效性和可行性。

因为 RCVM 方法是在样本数据训练前先进行预选取,因此,相对于直接对样本数据进行训练,增加了预选取的时间。但是,这个增加的时间相对于由于训练样本数量增加所带来的训练时间的增长是微不足道的。同时,RCVM 方法的另一个好处是能排除孤立噪音样本,消除了直接训练可能对支持向量机泛化能力造成的不良影响。

4 结 论

本文根据支持向量和孤立噪音样本的分布特点,利用 Vorono 图在样本空间的划分特性,提出了一种使用域着色 Vorono 图的支持向量预选取方法,即 RCVM 方法。该方法通过构造域着色 Vorono 图来识别并修剪孤立噪音样本,选取在分类面附近的样本作为训练样本。从仿真试验中可以看到,该方法能大量地减少训练样本的数量,排除孤立噪音样本,但基本不遗漏支持向量。在处理两类样本混杂严重而造成分类器过学习和泛化能力减弱的情况时具有很大的优势。由于训练样本的减少,支持向量机的训练速度得到很大的提高。因此,RCVM 方法是一种很有效的支持向量预选取方法。今后的工作是对该方法作进一步的理论分析和用更多的实际样本数据进行测试验证,同时将该思想应用到实际的基于 SVM 的网络入侵检测中去。

(下转第 105 页)

$$\begin{pmatrix} \frac{\partial f_1(x_1^{(k)}, x_2^{(k)})}{\partial x_1} & \frac{\partial f_1(x_1^{(k)}, x_2^{(k)})}{\partial x_2} \\ \frac{\partial f_2(x_1^{(k)}, x_2^{(k)})}{\partial x_1} & \frac{\partial f_2(x_1^{(k)}, x_2^{(k)})}{\partial x_2} \end{pmatrix}^{-1} \begin{pmatrix} f_1(x_1^{(k)}, x_2^{(k)}) \\ f_2(x_1^{(k)}, x_2^{(k)}) \end{pmatrix}$$

也可简记为

$$x^{(k+1)} = x^{(k)} - F'(x^{(k)})^{-1} F(x^{(k)}) \tag{10}$$

注意对于非线性方程组 (9), 其中的四个偏导数分别为:

$$\begin{aligned} \frac{\partial f_1(x_1, x_2)}{\partial x_1} &= x_2 + 2x_1x_2 \\ \frac{\partial f_1(x_1, x_2)}{\partial x_2} &= x_1 - 2x_2 + x_1^2 \\ \frac{\partial f_2(x_1, x_2)}{\partial x_1} &= 2x_1 \\ \frac{\partial f_2(x_1, x_2)}{\partial x_2} &= 2x_2 - 6 \end{aligned}$$

而且当取初始近似 $x^{(0)}$ 为 $x = (1.5 \ 1)$ 时, 迭代公式 (10) 收敛, 于是将其转化为当取初始近似 $x^{(0)}$ 为 $(0 \ 0 \cdots, 0)$ 时也收敛的迭代法:

$$\begin{aligned} x^{(k+1)} &= x^{(k)} - F'(x^{(k)} + x)^{-1} F(x^{(k)} + x) \\ k &= 0 \ 1 \ 2 \ \cdots \end{aligned} \tag{11}$$

因此利用 Excel 的循环引用只需进行如下操作 (注意: 为观察牛顿迭代法 (11) 对选取不同初始近似值时的收敛情况, 我们用两个单元格 A3 A4 存放初始近似 $x = (1.5 \ 1)$ 的值):

- 在 Excel 的工作表 Sheet3 中:
- 1) 在单元格 A3 A4 中分别输入 1.5 1;
 - 2) 在单元格 B1 B2 中分别输入公式: $=A1+A3=A2+A4$
 - 3) 在单元格 C1 D1 E1 C2 D2 E2 中分别输入以下公式:
 $=B2+2*B1*B2=2*B1=B1-2*B2+B1^2$
 $=2*B2-6=B1*B2-B2^2+B1^2*B2-5$
 $=B1^2+B2^2-6*B2+1$

于是单元格区域 B1 E2 中的值见图 2 所示。

	A	B	C	D	E
1		1.5		1.75	-2.25
2		1		-4	-1.75
3	1.5				
4	1				

图 2 单元格区域 B1 E2 中输入公式后的计算结果

(其中单元格区域 B1 B2 中的值为初始近似 $x^{(0)} + x$ 的值; 单元格区域 C1 D2 中为四个偏导数在 $x^{(0)} + x$ 值的计算公式; 单元格区域 E1 E2 中为函数向量在 $x^{(0)} + x$ 值的计算公式)

- 4) 选择单元格区域 A1 A2 输入公式:
 $=A1:A2-MMULT(MNVERSE(C1:D2), E1:E2)$
(说明: 公式中的 MNVERSE 为 Excel 提供的求逆矩阵的函数)
- 5) 按 Ctrl+Shift+Enter 键形成数组公式即完成操作。

此时, 单元格区域 A1 A2 中的值 $(0.499999998 \ -2.48168E-09)$ 与 $x = (1.5 \ 1)$ 相加, 也就是单元格区域 B1 B2 中的值 $(1.999999998 \ 0.999999996)$ 即为非线性方程组 (9) 的近似解, 与相应的精确解 (2.1) 相比, 显然已具有较高的计算精度, 并且满足我们设置的“最大误差”为 0.0000001 的精度要求。

此外, 若还要计算选取其它初始近似值时, 利用 Excel 的自动计算功能, 牛顿法 (11) 的收敛情况, 这将变得更加简单。例如, 若要计算取初始近似值为 $x = (1.5)$ 时, 我们只需将单元格

区域 A3 A4 中存放的 x 修改为 (1.5) 即可, 此时单元格区域 B1 B2 中的值 $(2.000000001 \ 4.999999999)$ 即为非线性方程组 (9) 的另一个根 (2.5) 的近似解。如图 3 所示。

	A	B	C	D	E
1	1.000000001	2.000000001	25	-4	2.02E-08
2	-5.70137E-10	4.999999999	4	4	3.55E-15
3		1			
4		5			
5					

图 3 修改单元格 A3 A4 的值为 1.5 后, A1 E2 中的数据

4 结 论

开发 Excel 的强大计算功能用于求解数值计算问题^[4], 既不需要设计程序, 也不需要专门的数学软件, 而且计算精度控制方便、操作简单, 同时注意到 Excel 软件在各类计算机上随处可见, 这不仅为课堂教学, 而且也为解决工程计算问题提供了极大的便利。

参 考 文 献

[1] 张威, 陈海波. 中文 Microsoft Office XP 完全手册 [M]. 北京: 北京希望电子出版社, 2001.

[2] 李庆杨, 王能超, 易大义. 数值分析 [M]. 北京: 清华大学出版社, 2001.

[3] 冯果忱. 非线性方程组迭代解法 [M]. 上海: 上海科学技术出版社, 1989.

[4] 彭海静. 基于 Excel 求高次方程的解 [J]. 计算机应用与软件, 2006 23(2).

(上接第 95 页)

参 考 文 献

[1] Vapnik V N. The Nature of Statistical Learning Theory [M]. 张学工, 译. New York: Springer-Verlag, 1995.

[2] Zhang Xueqin, Gu Chunhua, Lin Jiajun. Support Vector Machines for Anomaly Detection. Proceedings of the 6th World Congress on Intelligent Control and Automation, 2006 [C]. Dalian, China, 2006.

[3] 李昆仑, 黄厚宽, 田盛丰, 等. 模糊多类支持向量机及其在入侵检测中的应用 [J]. 计算机学报, 2005 28(2): 274-280.

[4] 李青, 焦李成, 周伟达. 基于向量投影的支撑向量预选取 [J]. 计算机学报, 2005 28(2): 3-10.

[5] Hu W J, Liao Y H, Venuri V R. Robust anomaly detection using support vector machines [J]. IEEE Trans on Pattern Analysis and Machine Intelligence.

[6] Navneet Panda, Edward Y Chang, Gang Wu. Concept Boundary Detection for Speeding up SVMs. Proceedings of the 23rd International Conference on Machine Learning, 2006 [C]. Pittsburgh, PA, 2006.

[7] 裴继红, 杨烜. 支撑矢量预选取的双色 Voronoi 图方法 [J]. 电子与信息学报, 2003 25(11): 56-60.

[8] 张有会. 关于一般图形 Voronoi 图的近似构造法的研究 [J]. 数值计算与计算机应用, 2002(3): 216-225.

[9] Chen D. Efficient geometric algorithm on the EREW PRAM [J]. IEEE Trans on Parallel Distrib. Syst. 1995 6(1): 41-47.