

基于支持向量机的多传感器信息融合算法

陶秀凤,周鸣争

(安徽工程科技学院 电气工程系,安徽 芜湖 241000)

摘要:支持向量机(Support Vector Machine, SVM)是一种基于结构风险最小化原理,具有很高泛化性能的学习算法。针对工业多传感器测控系统中,被测系数与相关参数之间存在有较大的非线性和模糊关系,提出了一种基于支持 SVM 的多传感器信息融合模型及算法。为小样本、非线性、高维数一类多传感器信息融合问题的建模提供了一种有效的途径。通过对“纸张水份在线测量系统”应用表明,基于 SVM 的多传感器信息融合模型及算法在测量精度和推广性能上都具有一定的优越性。

关键词:支持向量机;传感器;信息融合;水份测量

中图分类号:TP301.6

文献标识码:A

文章编号:1673-629X(2006)06-0177-03

An Algorithm of Multiple Sensor Information Fusion Based on SVM

TAO Xiu-feng, ZHOU Ming-zheng

(Dept. of Electrical Eng., Anhui University of Technology and Science, Wuhu 241000, China)

Abstract: The support vector machine(SVM) is an algorithm based on structure risk minimizing principle, having high generalization ability. In the course of multiple sensor information fusion of industrial control, sensor has bigger nonlinearity and fuzzy relation between coefficient and relevant parameter. A kind of model and algorithm of multiple sensor information fusion based on the support vector machine are proposed. The model offered a kind of effective way for little sample, non-linear, high dimension. Through use to "paper moisture content online measuring system", the model and algorithm have certain superiority in measuring precision and performance of popularization.

Key words: SVM; sensor; information fusion; moisture measurement

0 引言

多传感器信息融合可综合使用多传感器信息,使系统具有完成某一特定任务所需的完善信息。经过集成与融合的多传感器信息能完善和精确地反映环境特征;具有信息的冗余性、互补性、实时性和低成本性,因而得到广泛的应用。

现代工业生产以综合、复杂、大型、互联为其特点,采用了大量各式各样的传感器来监测和控制生产过程。在这种多传感器系统中,各传感器所提供的信息的时间、空间、表达式不同,可信度、不确定程度不同。这对信息的处理提出了新的要求。在传统的方式中,各传感器采集的信息单独、孤立地进行加工处理,不仅会导致处理工作量增加,而且割断了各传感器间信息的联系,丢失了信息的有机组合蕴涵的信息特征,因此,基于多传感器信息融合的工业测控系统受到广泛的关注。目前常用的算法主要有择多判决法、贝叶斯估计法、D-S 证据理论法、模糊推理法和自适应神经网络法^[1,2]等。它们中有的依赖于类先

验概率分布及条件概率分布;有的依赖于信度函数以及模糊隶属度。另外,对于一类小样本、高维特征空间条件下的信息融合问题,迄今仍没有一个有效的方法。

支持向量机(SVM)最初是由 Vapnik^[3]提出的一种新兴的基于统计学习理论的学习机。与神经网络的启发式学习方式和实现中带有很大的经验成分相比,SVM 具有更严格的理论和数学基础,不存在局部最小问题。小样本学习使它具有很强的泛化能力,不过分依赖样本的数量和质量。SVM 成为当前机器学习的一个研究热点。文中将该理论引入到多传感器信息融合研究中,提出了一种基于 SVM 理论的多传感器信息融合方法。具体实际应用表明,该方法对解决小样本、高维特征空间和不确定条件下的多传感器信息融合问题,具有较好的效果。

1 基于 SVM 的多传感器信息融合算法

多传感器信息融合是指对来自多个传感器信息源的数据进行检测、关联、相关、估计和综合等多级、多方面的处理,以获得对被测对象状态的精确估计和评价,提高监测系统的整体性能。

在工业测控系统中,一般情况下,其多传感器信息融合模式结构如图 1 所示。

收稿日期:2006-01-24

基金项目:安徽省教育厅自然科学基金资助项目(2004kj033zd)

作者简介:陶秀凤(1956-),女,江苏人,实验师,研究方向为信息融合与智能控制。

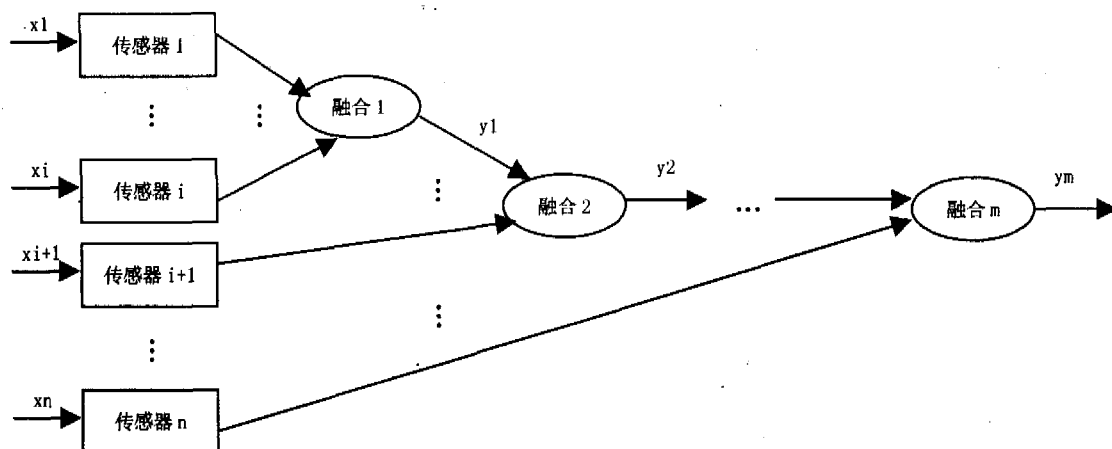


图 1 多传感器信息融合系统结构

由 n 个传感器组成多传感器系统,提供对象及环境信息,系统中设立 m 个融合节点对这 n 个信息进行融合,每个融合节点可以融合多个输入信息。最终被融合成结果信息 y 。实际中选择何种融合方式应由具体问题确定。

基于 SVM 理论的每个信息融合节点的融合问题可表示为:对一个 n 维输入参数 x ,根据 k 个独立分布观测样本 $(x_1, y_1), \dots, (x_k, y_k), x \in R^n, y \in R$

求一个最优的函数 $f(x)$,用以表示 x 与 y 之间的依赖关系。支持向量机的解决方法是:把 x 域用一个非线性函数 ϕ 映射到一个高维特征空间,再在高维特征空间进行线性回归,从而取得原空间非线性回归的效果。它的最优函数表示为:

$$f(x) = w \cdot \Psi(x) + b \quad (1)$$

现在的问题成为,根据已知的 k 个样本,确定向量 w 和标量 b 。对于这样一个回归问题,基于支持向量机的最优回归函数是指满足结构风险最小化原理,其最小化^[4]表示为:

$$\phi(w) = \frac{1}{2} \|W\|^2 + c \cdot R_{\text{emp}}(f) \quad (2)$$

其中 c 是预先确定的常数, $R_{\text{emp}}(f)$ 是经验风险。对于 $R_{\text{emp}}(f)$,可以采用不同的代阶函数来描述,如二次函数、Huber 函数和 ϵ -insensit 函数,其中 Vapnik 提出的 ϵ -insensit 函数具有很好的性质^[4]。当回归测度函数为 ϵ -insensit 代阶函数时,式(2)表示为:

$$\phi(w) = \frac{1}{2} \|W\|^2 + \frac{1}{k} \sum_{i=1}^k |y_i - f(x_i)|_\epsilon \quad (3)$$

特别地,当所有训练数据都可以在精度 ϵ 下无误地用线性函数拟合,即:

$$\begin{cases} y_i - w \cdot x_i - b \leq \epsilon \\ w \cdot x_i + b - y_i \leq \epsilon \end{cases} \quad i = 1, \dots, k \quad (4)$$

式(3)显然等价于 $\frac{1}{2} \|W\|^2$;在允许拟合误差的情况下,引入松弛因子 $\zeta_i \geq 0$ 和 $\zeta_i^* \geq 0$,则式(4)变为:

$$\begin{cases} y_i - w \cdot x_i - b \leq \epsilon + \zeta_i \\ w \cdot x_i + b - y_i \leq \epsilon + \zeta_i^* \end{cases} \quad i = 1, \dots, k \quad (5)$$

式(3)回归问题最小化表示为:

$$R(w, b, \zeta, \zeta^*) = \frac{1}{2} \|W\|^2 + c \sum_{i=1}^k (\zeta_i + \zeta_i^*) \quad (6)$$

式(6)中,第一项使回归函数更为平坦,从而提高泛化能力,第二项使误差为最小。从式(5)可以看出,误差函数 E 可取为:

$$E = \begin{cases} 0 & \text{如果 } |wx_i + b - y_i| < \epsilon \\ |wx_i + b - y_i| - \epsilon & \text{其他} \end{cases} \quad (7)$$

这是一个凸二次优化问题,引入 Lagrange 函数:

$$\begin{aligned} L(w, b, \zeta, \zeta^*, a, a^*, r, r^*) = & \frac{1}{2} \|W\|^2 + c \sum_{i=1}^k (\zeta_i + \zeta_i^*) \\ & - \sum_{i=1}^k a_i [\zeta_i + \epsilon - y_i + w \cdot x_i + b] - \sum_{i=1}^k a_i^* [\zeta_i^* + \epsilon \\ & + y_i - w \cdot x_i - b] - \sum_{i=1}^k (\zeta_i r_i + \zeta_i^* \cdot r_i^*) \end{aligned} \quad (8)$$

其中 $a_i, a_i^* \geq 0, r_i, r_i^* \geq 0, i = 1, 2, \dots, k$,函数应对 w, b, ζ_i, ζ_i^* 最小化,对 a_i, a_i^*, r_i, r_i^* 最大化,函数 L 的极值应满足条件:

$$\frac{\partial}{\partial w} L = 0, \frac{\partial}{\partial b} L = 0, \frac{\partial}{\partial \zeta_i} L = 0, \frac{\partial}{\partial \zeta_i^*} L = 0 \quad (9)$$

从而得到对偶形,对 Lagrange 因子 a_i, a_i^* 最大化目标函数:

$$\begin{aligned} w(a, a^*) = & -\frac{1}{2} \sum_{i,j=1}^k (a_i - a_i^*)(a_j - a_j^*) [\phi(x_i) \cdot \phi(x_j)] \\ & + \sum_{i=1}^k (a_i - a_i^*) \cdot y_i - \sum_{i=1}^k (a_i + a_i^*) \epsilon \end{aligned} \quad (10)$$

其约束为:

$$\sum_{i=1}^k (a_i - a_i^*) = 0 \quad (11)$$

$$0 \leq a_i, a_i^* \leq c \quad (12)$$

式(11)中 $\phi(x_i) \cdot \phi(x_j)$ 为高维特征空间的点积运算,而函数 ϕ 是未知的,高维的。支持向量机理论只考虑高维特征空间的点积运算 $K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j)$,而不直接使用函数 ϕ ,从而有效地解决了这个问题。一般称 $K(x_i, x_j)$ 为核函数。根据泛函的有关理论,只要一种核函数 $K(x_i, x_j)$ 满足 Mercer 条件,它就对应某一变换之间的内积。常用的核函数有:多项式核函数、RBF(Radial Basis Function)核函数、Sigmoid 核函数和样条(Spline)核函

数^[4]。因此高维空间的内积运算可以通过原空间的运算实现。只要采用适当的内积函数 $K(x_i, x_j)$, 就可以实现某一非线性函数拟合, 此时目标函数变为:

$$w(\alpha, \alpha^*) = -\frac{1}{2} \sum_{i,j=1}^k (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) K(x_i, x_j) + \sum_{i=1}^k (\alpha_i - \alpha_i^*) \cdot y_i - \sum_{i=1}^k (\alpha_i + \alpha_i^*) \epsilon \quad (13)$$

且回归函数变为:

$$f(x) = \sum_{SVs} (\alpha_i - \alpha_i^*) k(x, x_i) + b^* \quad (14)$$

对 α 和 α^* , 可按式(12)和式(11)约束表示的优化采用相应的算法求解(如内点算法^[5]), 向量 w 的值可由式(9)中对 w 的偏导数公式求得。

$$w = \sum_{SVs} (\alpha_i - \alpha_i^*) \phi(x_i) \quad (15)$$

由于任何一组 α_i 和 α_i^* 都不会同时为非零, 对应于 $\alpha_i = c$ 或 $\alpha_i^* = c$ 的 $f(x_i)$ 与 y_i 的误差大于 ϵ , 对应于 $\alpha_i \in (0, c)$ 或 $\alpha_i^* \in (0, c)$ 的 $f(x_i)$ 与 y_i 的差等于 ϵ , 因此 b 可用以下两式求解:

$$\begin{cases} \epsilon - y_i + f(x_i) = 0 & \text{对 } \alpha_i \in (0, c) \\ \epsilon + y_i - f(x_i) = 0 & \text{对 } \alpha_i^* \in (0, c) \end{cases}$$

解得:

$$b^* = -\frac{1}{2} \sum_{i=1}^k (\alpha_i - \alpha_i^*) [k(x_r, x_i) + k(x_s, x_i)] \quad (16)$$

综上所述, 基于支持向量机的多传感器信息融合模型可用图 2 表示。其中 N 为支持向量个数, 该模型较之其它多传感器信息融合模型具有以下几个特点:

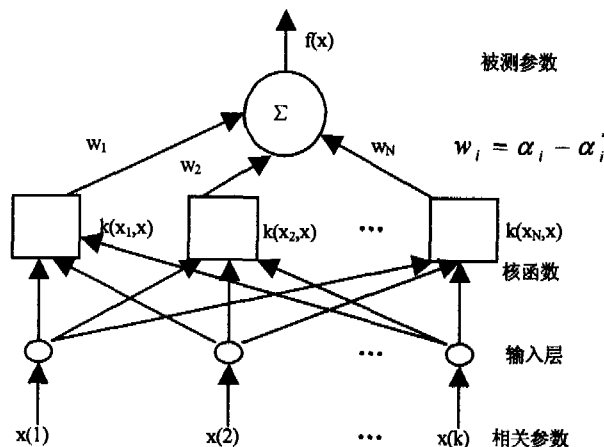


图 2 基于 SVM 的多传感器信息融合模型

(1) 该模型在输入输出节点上与一般信息融合过程完全等效, 将被测参数与相关参数之间模糊非线性关系转变为模型中的映射关系, 内部也可用信息融合的有关概念去解释。

(2) 测试系统中各参数的确定与修改, 均转变为模型中回归函数 $f(x)$ 的求解; 同时求解过程是一个凸二次优化问题, 能够保证所得的极值解就是全局最优解, 模型具有一定的通用性。

(3) 对同一测试过程, 可通过调整 ϵ 和核函数 $K(x_i,$

$x_j)$ 及相关参数, 提高系统的融合测试精度。

(4) 该模型在解决各相关系数与被测参数之间非线性、高维数问题时, 不是对输入空间的样本作非线性变换, 而后再在特征空间中求解。而是输入空间比较向量, 然后再对结果作非线性交换, 这样, 大量的工作将在输入空间而不是在高维特征空间中完成。有效解决了其它算法可能导致的“维数灾难”问题, 利用图 2 的模型, 进行实际参数的多传感器信息融合时, 其算法步骤为:

Step1 根据实际系统要求, 确定输入传感器 x 的个数, 并使该节点的输出等于输入。

Step2 实测(或凭经验)采集各传感器数据, 生成训练样本。

Step3 选择某一核函数 $K(x_i, x_j)$, 确定精度误差和核函数的相关参数, 其步骤为:

Step3.1 选择某一值固定不变。

Step3.2 对所选的核函数, 通过不断修改其参数, 用训练样本进行训练学习, 以获得在固定值下结果最佳的核函数参数。

Step3.3 以最佳情况下核函数参数作为核函数参数, 通过不断修改 ϵ 值, 再用训练样本进行训练学习, 获得最佳情况下的 ϵ 值。

Step3.4 用所获得的最佳值情况下的 ϵ 值和核函数参数作为系统模型的精度误差 ϵ 和核函数参数。

Step4 利用式(11)和式(12)采用相应的算法(如内点算法)求解 α 和 α^* 及式(13)、式(15)计算出 b^* 和 w 。

Step5 通过学习后, 对所确定的 $\alpha, \alpha^*, \epsilon, w$ 和 b^* , 利用式(14), 用测试样本进行测试, 若能满足系统精度要求, 则用式(14)作为多传感器信息融合应用系统模型, 实现对被测参数的检测, 否则, 再选择另一核函数重复 Step3, 直到达到满足系统精度为止。

2 算法的应用实例

基于上述的模型及算法, 对造纸过程中纸张含水量进行了多传感器融合测试。由于纸张水份与纸浆浓度、烘干温度、纸张在烘箱内运动的速度及环境湿度等参数相关, 据此, 选取输入参数 X 为 4 进行信息融合, 用以测量纸张水份的值。同时考虑到有些参数波动频繁, 为避免上述模型对该类参数的作用过于敏感, 对参数进行了下述的纯化处理:

$$\begin{aligned} D_{\max} &= D_{\max} + \alpha(D_{\max} - D_{\min}) \\ D_{\min} &= D_{\min} - \alpha(D_{\max} - D_{\min}) \end{aligned} \quad (17)$$

其中 α 为纯化因子, 取 $\alpha = 0.35$; 经过上述处理后, 在正常工况范围内(0.1% ~ 10%), 各选取 20 个输入输出模式对, 构成训练样本和测试样本值。取 RBF 为算法核函数^[4], 即

$$k(x, y) = \exp\left(-\frac{(x - y)^2}{2\delta^2}\right) \quad (18)$$

(下转第 183 页)

方球门的危险区域;进攻时(即我方持球)尽量让球射入对方球门或让球进入对方球门禁区。

下面以防守为例,说明队员协作的具体运用。防守时有 3 个动作:盯人(Mark)、阻截(Block)和跑本位点(Formation)。盯人的目的是防止被盯的对手接到传球;阻截的目的是阻碍对方控球队员带球前进;本位点是每个队员根据自己角色的和当前球的位置得出的一个活动区域的重心,跑本位点是指球员站在本位点处防守,即进行区域防守。每个队员根据自己角色的不同有不同的防守区域,即不同本位点。每个队员对自己的防守区域都有个承诺:保证对方不会带球穿过我方的防守区域,同时它对其他队友也有个信念:队友一定不会让对手带球穿过队友的防守区域。正是每个防守队员基于这样的承诺和信念,球队在面对对方的进攻时能保持良好的队形,不会让对手轻易突破防线。但是,由于队员的能力有限并不能绝对保证能成功拦截。因此,队员在选择防守动作时,应能根据当前的环境信息和其他队员模型判断其成功履行承诺的概率。建立其他队员的模型是在比赛前训练出来的,训练的方法有再励学习、决策树、神经网络等。

5 个体行为层

个体行为层定义智能体单独完成任务的行为,包括抢断、射门、清理球、传球、拦截、盘带、到定点、盯人、面向球等。这些行为都是预设的。

(上接第 179 页)

通过使用 Matlab SVM Toolbox 训练仿真比较,结果如表 1 所示。最终选择 $\epsilon = 0.05, \delta = 1.0, c = \infty$ 作为实际测量模型参数,并用 VC++ 编制了相应的测试应用程序。投入运行后,测试误差 $< 0.1\%$, 满足工艺设计精度 $< 0.3\%$ 的要求,取得较好的测试效果。

表 1 训练仿真结果($c = \infty$)

序号	ϵ	δ	支持向量数(svs)	最大误差(%)
1	0.004	2.0	12	0.448
2	0.008	2.0	12	0.400
3	0.032	2.0	12	0.248
4	0.05	2.0	12	0.150
5	0.128	2.0	12	0.223
6	0.25	2.0	12	0.470
7	0.05	4.0	12	0.354
8	0.05	1.0	12	0.053
9	0.05	0.5	12	0.232
10	0.05	0.1	12	0.470

3 结束语

主要结论是:

6 实际结果与结论

实验中,笔者在自己的球队 Winlet2005(底层技术采用 UVA2003)的基础上加以改进,注重球员之间的配合,加快攻防转换的节奏,在与单结构如反应结构、慎思结构球队以及不注重协作能力的球队(Winlet2003)的比赛中战果显赫,在 100 场的较量中取得 83 胜、10 平、7 负的成绩。多次实验结果充分说明文中提出的 Multi-Agent 层次协作模型是合理的、有效的。

参考文献:

[1] Omicini A, Papadopoulos G A. Why Coordinate on Models and Language in AI[J]. Applied Artificial Intelligence, 2001, 15 (1):1-11.

[2] Stone P. Layered Learning in Multi-agent Systems[D]. America: Carnegie Mellon University, 1998.

[3] Reis L P, Lau N, Oliveira E C. Situation Based Strategic Positioning for Coordinating Team of Homogeneous Agents[EB/OL]. <http://www.ieeta.pt/robocup/archive.htm>. 2002-05.

[4] 仵博, 吴敏, 曹卫华. 一种基于行为的 Multi-Agent 决策算法及其在 RoboCup 中的应用[J]. 机器人技术与应用, 2002(2):46-50.

[5] Stone P, Riley P, Veloso M. Defining and Using Ideal Teammate And Opponent Agent Models. AT&T Labs[EB/OL]. <http://www.research.att.com/pstone>. 2001-05.

(1)在多传感器信息融合过程中,采用支持向量机的学习算法是可行的,可有效解决小样本、非线性、参数之间存在模糊关系的信息融合建模问题;

(2)该模型结构灵活,无需人工经验,可从实测数据集直接建立模型,具有一定的推广性;

(3)核函数的类型及相关参数的选择对融合精度有一定的影响,如何优化,有待做进一步的研究。

参考文献:

[1] 袁布儿, 杨东勇, 林毅. 多传感器信息融合及其在工业控制中的应用[J]. 浙江工业大学学报, 1999, 27(4):281-286.

[2] 王军, 苏剑波, 席裕庚. 多传感器融合综述[J]. 数据采集与处理, 2004, 19(1):72-77.

[3] Vapnik V. The nature of statistical learning theory[M]. New York: Springer-Verlag, 1995.

[4] Gunn S. Support Vector machine for classification and regression[Z]. Jsis report, Canada: Image Speech & Intelligent System Group, University of Southampton, 1998.

[5] Vanderbei R J. LOQO: An Interior Point Method for Quadratic Programming[R]. NJ: Princeton University, 1994.