

一种具有渐进学习能力的融合方法

王 军, 苏剑波

(上海交通大学自动化所, 智能机器人系统与技术研究中心, 上海 200030)

摘 要: 运行在动态与未知环境下的多传感器系统往往会面临环境与自身结构的渐进式变化, 导致一般的具有学习能力的融合方法很难适用. 本文提出了一种具有渐进学习能力的融合方法, 它具有良好的自适应性和鲁棒性. 该方法由一种名为接受域加权回归(Receptive Field Weighted Regression)的渐进式学习算法和加权平均的融合算法组成. 最后以三个摄像机联合定位作为研究对象, 对该方法进行了仿真, 验证了其有效性, 同时还和基于 BP 神经网络的融合方法进行了比较.

关键词: 传感器融合; 渐进式学习算法; 接受域加权回归

中图分类号: TP242 **文献标识码:** A **文章编号:** 0372-2112 (2002) 10-1496-05

A Fusion Method with Incremental Learning Ability

WANG Jun, SU Jiabo

(Institute of Automation & Research Center of Intelligent Robotics, Shanghai Jiaotong University, Shanghai 200030, China)

Abstract: The multisensor systems under the dynamic and unknown environment often encounter the incremental modification of environment and its configuration. This results in the fact that the fusion methods with learning ability cannot be suitable any more under this condition. In this paper, a new fusion method with incremental learning ability is proposed. This method utilizes an incremental learning algorithm called Receptive Field Weighted Regression (RFWR), and weighted average is used as the fusion strategy, thus it is more adaptive and robust than previous ones. The problem of three cameras positioning is taken into account and the corresponding simulation is implemented. Simulation results verify the effectiveness of this method. Comparison with BP neural network-based fusion method is also provided.

Key words: sensor fusion; incremental learning algorithm; RFWR

1 引言

多传感器融合是一个复杂的不确定信息处理过程, 如传感数据的处理、信息的融合等均带有明显的不确定性, 使得很难甚至无法为其建立精确的数学模型, 因此具有学习能力的融合方法就有重要的研究价值^[1~4]. 由于神经网络所具有的特性及其广泛应用, 它已经成为研究具有学习能力的融合方法的有力工具^[5~9].

在多传感器融合系统中, 融合处理中心需要能够在环境或系统结构发生渐进式变化的情况下完成信息的融合处理. 例如, 具有学习能力的融合方法经过训练可以得到某个传感器的模型(或者融合模型), 且该模型只对确定的感知区域有效. 但由于应用需求的变化, 要求扩大传感器的感知区域, 或者增加新的传感器, 无论哪种情况, 都会对整个融合系统产生影响. 已有的融合方法均只能放弃已建立的模型, 重新在整个感知区域(包括原来区域在内)建立新的模型, 这样原来有效的模型就不能利用, 造成了低效和浪费. 因此, 为了能够减少这种变化对整个融合系统的影响, 以及充分利用已经学习得

到的模型, 需要研究具有渐进学习能力的融合方法. 这种方法能够在不断学习的过程中使模型不断的进化, 从而能够更好地适应环境的变化. 本文提出了一种具有渐进学习能力的融合方法. 该方法不仅具有渐进学习的能力, 而且具有简单灵活的结构, 使系统对动态变化具有更好的自适应性和鲁棒性.

2 接受域加权回归算法

接受域加权回归算法是 Schaal 在 1998 年提出的一种基于局部区域的渐进式学习算法^[10], 它既可以看成是一种局部学习, 又可以看成是一种渐进式学习. 其实质是通过多个局部线性模型对函数在不同局部区域上的拟合, 来实现对函数在整个空间上的拟合. 图 1 所示, (a) 是一个接受域的示意图, 其中 $y=f(x)$ 是待拟合的函数, 两条虚线之间的区域表示噪声以及其它不确定因素产生的影响. 所谓接受域是指 x 上的一个局部区域, 在这个区域上定义了两个函数: $\hat{y}=l(x)$ 和 $w=u(x)$, $\hat{y}=l(x)$ 就是用来拟合 $y=f(x)$ 的局部线性模型, \hat{y} 是在该接受域上对 y 的估计值, 而 $w=u(x)$ 则是用来描述拟合的效果(即 \hat{y} 相应的权值), 如 c 点, $u(c)=1$ 说明该线性模

型在 c 处的拟合效果最好. 在实际应用中, 一个函数往往需要多个这样的接受域来拟合, 如图 (b) 所示, 因此在每一个接受域上, 都可以得到其线性模型在 x 点对 y 的估计值 \hat{y} 及相应的权值 w . 这里将接受域上定义的两个函数 $\hat{y} = l(x)$ 和 $w = u(x)$ 分别称之为接受域的回归模型和不确定性模型. 常用的回归模型除了线性模型还有低阶多项式模型; 不确定性模型一般用核函数来表示, 图 1 中采用的是高斯核函数, 其它常用的还有对称钟型核函数. 在 RFWR 中, 回归模型采用的是线性模型, 不确定性模型为高斯核函数.




图 1 接受域

在 RFWR 算法中, 通过训练可以产生新的接受域, 可以更新局部线性模型使其能够更好地拟合局部函数, 而且能够调整局部不确定性模型使其能够更加准确地描述拟合的效果. 最终得到一个由多个接受域组成的模型, 称之为 RFWR 模型, 如图 1(b).

假设 $y = f(x)$ 是待拟合的函数, 其中 x 是 n 维列向量, 并且通过训练最后得到一个包含 K 个接受域的 RFWR 模型, 则 K 个接受域的回归模型可以表示为:

$$\hat{y}_k = (x - c_k)^T b_k + b_{0,k} = \tilde{x}^T \beta_k, \quad k = 1, 2, \dots, K \quad (1)$$

其中 $\tilde{x} = ((x - c_k)^T, 1)^T$, $\beta_k = (b_k^T, b_{0,k})^T$, \hat{y}_k 是第 k 个接受域在 x 处对 y 的估计值. β_k 和 $(c_k^T, b_{0,k})$ 分别被称为第 k 个接受域的线性模型参数和参考点. 高斯核函数表示为:

$$w_k = \exp\left[-\frac{1}{2}\right] (x - c_k)^T D_k (x - c_k), \quad k = 1, 2, \dots, K \quad (2)$$

其中, w_k 为 \hat{y}_k 相应的权值. D_k 称为距离矩阵, 用来决定接受域的尺寸和形状, 为了方便, 可将 D_k 表示为上三角矩阵 M_k 的乘积形式 $D_k = M_k^T M_k$. 最后根据公式(1)和(2), 通过对所有的估计值进行加权平均, 就可以得到 RFWR 模型在 x 处对 y 的估计值 \hat{y} ,

$$\hat{y} = \sum_{k=1}^K w_k \hat{y}_k \bigg/ \sum_{k=1}^K w_k \quad (3)$$

根据上面的表达式, 可以把 RFWR 算法的训练过程分为以下几个部分: 线性模型参数 β_k 和距离矩阵 D_k (或 M_k) 的更新, 以及接受域的增加和删除, 详见文献^[10].

由于接受域之间相对独立, 因此各接受域的学习过程相对独立. 如果将每个接受域视为一个独立的系统, 那么该算法本身就是一个融合系统.

3 基于接受域加权回归的融合方法

利用 RFWR 算法不仅可以得到传感器的模型, 而且能够得到其相应的不确定性模型, 这为融合处理提供了方便; 同时, 这种算法能够使融合方法具有渐进学习的能力, 有利于解决动态和不确定环境下的多传感器融合问题. 然而, 该算法在计算复杂性和模型定义方面还存在一些问题, 并且影响其在

融合方法中的应用. 因此, 本文通过深入分析对 RFWR 算法进行了必要的改进, 并且在此基础上提出了一种具有渐进学习能力的融合方法.

3.1 改进的接受域加权回归算法

在原算法中, 线性模型的维数是 $n + 1$, 如式(1). 通过变换, 可以把线性模型的维数降低为 n 维. 定义 $\tilde{y}_k = \hat{y}_k - b_{0,k}$, 则式(1)变为:

$$\tilde{y}_k = (x - c_k)^T b_k = \tilde{x}^T \beta_k \quad (4)$$

其中, $\tilde{x} = x - c_k$ 和 $\beta_k = b_k$ 均降为 n 维列向量. 降维处理尽管简单, 但好处是明显的:

(1) 不仅减少了参数和变量所需的存储量, 而且降低了计算量. 假设输入空间为 2 维, 接受域的数目为 40 个, 那么计算表明, 因为降维可以节省 400 个存储单元, 减少 112 次乘法运算和 70 次加法运算. 随着接受域数目的增加, 尤其是在多传感器系统中, 这种改进对系统性能上的提高将会更加明显.

(2) 根据线性模型和不确定性模型的定义, 在接受域中 c_k 所对应权值为 1, 而通过线性模型得到其相应的估计值为 $b_{0,k}$. 但是在原算法中线性模型参数 β_k 的修改会造成线性模型在 c_k 处的估计值出现较大的偏差, 因此无法保证该处误差最小, 这和该处权值为 1 的含义不一致, 从而影响对不确定性的描述, 该问题可以在改进后的算法中得到解决.

另外, 还对原算法程序流程做了修改, 如图 2. 在原算法中不管训练样本对应权值的大小, 都会用来修改所有的接受域, 但实践表明, 如果样本在某个接受域上权值过小 (如 < 0.01), 则不会对该接受域上的模型产生大的影响, 反而会增加运算量, 甚至会使算法产生奇异. 为了避免这种情况, 可以设定一个阈值, 规定只对权值大于该阈值的接受域进行修改. 此外还在算法中加入了异常情况的处理. 例如, 一个样本如果在所有接受域上的更新都无法正常完成 (如分母为零的情况发生), 则增加一个新的接受域.




图 2 算法流程图

可以设定一个阈值, 规定只对权值大于该阈值的接受域进行修改. 此外还在算法中加入了异常情况的处理. 例如, 一个样本如果在所有接受域上的更新都无法正常完成 (如分母为零的情况发生), 则增加一个新的接受域.

3.2 基于接受域加权回归的融合方法

以改进后的 RFWR 作为学习算法, 以加权平均作为融合策略, 我们提出了一种适用于动态环境下多传感器融合的具有渐进学习能力的融合方法, 如图 3 所示. 其中, RFWR_i 代表通过训




图 3 基于 RFWR 融合方法的框架图

练得到的第 k 个传感器模型, x_k 和 \hat{y}_k 分别是第 k 个模型的输入值和输出值, y_k 代表训练阶段第 k 个模型的输出样本, \hat{y}_f 是最后的融合结果. 假设 $K_i (i=1, 2, \dots, n)$ 表示第 i 个模型接受域的个数, 根据公式(1)、(2)、(3)可得该融合方法的解析表达式,

$$\hat{y}_f = \frac{\sum_{i=1}^{K_1} w_{1i} \hat{y}_{1i} + \sum_{i=1}^{K_2} w_{2i} \hat{y}_{2i} + \dots + \sum_{i=1}^{K_n} w_{ni} \hat{y}_{ni}}{\sum_{i=1}^{K_1} w_{1i} + \sum_{i=1}^{K_2} w_{2i} + \dots + \sum_{i=1}^{K_n} w_{ni}} \quad (5)$$

其中, w_{ij} , \hat{y}_{ij} 分别表示输入值在第 i 个模型的第 j 个接受域所对应的权值和输出估计值.

基于 RFWR 的融合方法包括训练阶段和使用阶段. 在训练阶段, 需要采集训练样本, 为每一个传感器建立 RFWR 模型; 在使用阶段, 利用 RFWR 算法以及公式(5)计算最后的融合结果. 和其他方法相比, 该方法具有以下几个显著的特点:

(1) 在基于 RFWR 的融合方法中, 每个 RFWR 模型也可以被认为是一个融合系统. 在这个融合系统中每个接受域就相当于一个待融合的子系统, 融合算法也是加权平均, 因此图 3 所示的融合系统就可以看成是由多个结构相同的子融合系统组成的. 这样的框架结构为整个融合系统的扩展提供了方便, 能够更好地适应环境与系统的变化.

(2) RFWR 算法是一种渐进学习算法, 接受域之间相互独立, 当新的接受域产生时不会影响已有的接受域, 因此当样本空间扩大时, 只需要根据新样本产生新的接受域, 扩展后的模型不仅适用于新的样本空间, 而且同样适用于原来的样本空间, 不需要在整个样本空间重新进行训练, 这保证了该融合方法具有渐进学习的能力; 另外, 由于采用 RFWR 模型作为传感器模型, 因此采用了较为简单的融合算法, 即是加权平均, 为整个融合方法的扩展提供了方便.

(3) 利用 RFWR 算法不仅可以得到传感器的近似模型(回归模型), 而且同时可以得到相应的不确定模型. 此外, 该方法实现了不确定性的传播, 这些都是其它方法所无法实现的.

以上这些特点使该融合方法对环境动态变化以及系统结构变化具有良好自适应性.

4 仿真

我们考虑一个由三个摄像机组成的多传感器系统. 以带有噪声和径向畸变的针孔模型作为摄像机的实际模型^[11]. 三个摄像机镜头的焦距均为 6mm, 径向形变系数均为 0.01, 像平面均为 $6 \times 3 \text{mm}^2$ 的矩形. 摄像机 1、2、3 分别固定在世界坐标系中三个不同位置 (400, -50, 450)、(400, 50, 450) 和 (500, 0, 450) (单位 mm), 其欧拉角 ($\alpha \gamma \chi$) 都是 (180°, -90°, 90°). 用高斯噪声 $N(0, 0.001)$ 来模拟图像噪声. 在这个系统中, 每个摄像机都能得到一个物体在工作平面上的位置测量, 为了提高定位的准确性以及整个系统的鲁棒性, 可以采用基于接受域加权回归的融合方法来实现三个摄像机的联合定位. 为简单起见, 这里以确定 x 坐标值为例来说明融合过程, 其余坐标方向可以用相似的过程进行处理.

4.1 两个摄像机的情况

先只考虑摄像机 1 和 2. 这里用 $R[(x_1, y_1); (x_2, y_2)]$ 来定义一个矩形区域 R , 其中 (x_1, y_1) 和 (x_2, y_2) 为其两个相对顶点的坐标. 假设两个摄像机的视场分别为 $S_1[(500, -150); (300, 50)]$ 和 $S_2[(500, -50); (300, 150)]$, 它们的交集为 $S_{12}[(500, -50); (300, 50)]$. 首先以 S_{12} 作为该系统目前的工作区域, 分别均匀产生两组样本点各 90 个, 其中 60 个用于训练两个摄像机在该工作区域的模型, 其余的 30 个样本作为融合检验. 输入样本为物体在图像坐标系中像点的坐标, 而输出样本是物体在世界坐标系中 x 方向的坐标值. 训练的目标: x 方向定位的最大误差不超过 1mm, 训练和融合结果如表 1 所示.

表 1 在上 RFWR 模型的训练结果及其融合结果

项 目	RFWR1		RFWR2		Fusion	
	训练样本	检验样本	训练样本	检验样本	训练样本	检验样本
最大误差(ME)	0.2320	0.2730	0.2164	0.3599	0.1756	0.2117
均方差(MSE)	0.0052	0.0157	0.0069	0.0204	0.0046	0.0128

表 1 中, RFWR1 和 RFWR2 分别是通过在 S_{12} 上训练得到的摄像机模型, Fusion 表示基于 RFWR 的融合方法得到的融合结果. RFWR1 和 RFWR2 分别包括 15 个接受域, 训练周期的次数分别为 4 和 1. 此外, 仿真过程中还发现 RFWR 算法的训练周期数和训练样本的次序有着密切的关系, 例如在 RFWR1 的训练中, 颠倒训练样本的次序后重复同样的学习过程, 结果只需 1 个周期即可达到所要求的精度. 显然, 该问题的解决有待于 RFWR 算法的深入研究.

为了展示 RFWR 算法在固定样本集上的学习能力, 文献 [10] 将该算法和其他经典的学习算法进行了对比, 其中包括 3 层结构的 BP 神经网络. 结果表明, 为达到相同的精度, 神经网络往往需要更大的代价. 同样, 为了说明基于 RFWR 的融合方法的有效性, 本文将这种方法和基于 BP 神经网络的融合方法进行了简单的比较. 在基于 BP 神经网络的融合方法中, 采用 BP 神经网络作为融合方法, 以两个像点坐标作为输入, 以物体的 x 坐标值作为输出, 在这种方法中不需要为摄像机单独建立模型, 该方法是一种常用的形式. 但是这种方法的结构缺乏灵活性, 例如新传感器的加入将会引起神经网络结构的变化, 因此必须放弃已有的模型, 重新训练新的神经网络. 这里采用和上面相同的样本, 并且通过对神经网络参数和结构的不断调整, 得到了一组比较满意的结果, 如表 2 所示.

表 2 两种融合方法的比较

项 目	BP-based		RFWR-based	
	训练样本	检验样本	训练样本	检验样本
最大误差(ME)	0.2471	0.5585	0.1756	0.2117
均方差(MSE)	0.0141	0.0517	0.0046	0.0128

采用 MATLAB 神经网络工具箱自带的基于 Levenberg Marquardt 算法的 3 层 BP 神经网络. 其中, 隐节点个数为 12, 其训练周期为 1000 次. 在上面的仿真过程中, 尽管采用相同的训练样本和网络结构, 但是由于权值初始值的不同而造成不

同的训练结果, 严重影响了训练的稳定性. 其次, 通过调整网络结构(如增加隐节点的个数), 虽然可以提高学习收敛的速度, 但是往往要以降低泛化能力为代价, 因此在仿真过程中很难同时满足收敛速度和泛化能力的要求, 而且这方面缺乏理论上的指导, 通常只能采用穷举的办法, 直到找到满意的结果为止. 显然, 这些问题都是神经网络本身所存在的缺陷, 它们的解决还有待于进一步地研究. 和基于 BP 神经网络的融合方法相比, 基于 RFWR 的融合方法由于采用了 RFWR 算法, 不仅使其具有渐进学习能力, 而且在学习过程中表现出许多良好的特性, 如训练周期数少, 精度高, 而且训练的稳定性好. 此外, 基于 RFWR 的融合方法比单独的 RFWR 模型更加准确, 而且可以在一定程度上减小单个 RFWR 模型偏差对融合结果的影响, 这也正是融合方法本身所要实现的目标.

4.2 两个摄像机工作区域扩展的情况

假设系统工作区域扩展至 S_1 和 S_2 的并集. 对于上述的两种基于神经网络的融合方法, 必须放弃原来的模型, 在扩大后的工作空间重新训练来建立新的模型. 如果试图通过在新增空间上的训练来扩展原来的模型, 则可能造成新模型无法适合原来的工作空间. 如果采用了 RFWR 算法, 那么扩展后整个视场上的测量模型只需在原来模型的基础上做简单的扩展, 这就是渐进式学习的含义. 仿真结果如表 3 所示.

表 3 在扩展后整个空间上 RFWR 模型的训练结果及融合结果

项 目	RFWR1		RFWR2		Fusion
	$S_1 - S_{12}$	S_{12}	$S_2 - S_{12}$	S_{12}	S_{12}
最大误差(ME)	0.5947	0.2753	0.4453	0.4885	0.2428
均方差(MSE)	0.0441	0.0198	0.0555	0.0260	0.0158

其中, $S_1 - S_{12}$ 代表 S_1 中不包含 S_{12} 的部分, $S_2 - S_{12}$ 代表 S_2 中不包含 S_{12} 的部分. RFWR1 和 RFWR2 的训练周期分别为 15 和 1, 接受域个数分别为 27 和 30. 仿真表明, 为了适应新的工作空间各 RFWR 模型的接受域个数都有所增加, 但扩展空间上的训练几乎不会对原来的接受域产生影响. 和表 1 相比, 扩展后的模型和原来模型在 S_{12} 上的精度基本相同.

4.3 三个摄像机的情况

增加一个摄像机 3, 相当于对上节系统的结构进行了扩展. 由于采用基于 RFWR 的融合方法, 因此使融合系统的扩展变得非常简单. 只需在 S_3 上训练就可以得到摄像机 3 相应的模型 RFWR3, 结合已有摄像机 1、2 的模型 RFWR1 和 RFWR2, 利用式(5)就可以得到一个扩展后的融合系统. 在这个仿真中, 从 S_3 中均匀选取 100 个样本点, 然后经过 2 个周期的训练, 就可以得到满足训练目标的模型 RFWR3. 仿真结果如表 4 所示.

表 4 系统结构扩展后 RFWR 模型的训练结果及融合结果

项 目	RFWR1	RFWR2	RFWR3	Fusion
	S_1	S_2	S_3	$S_1 \cap S_2 \cap S_3$
最大误差(ME)	0.5947	0.4885	0.3508	0.1763
均方差(MSE)	0.0319	0.0408	0.0299	0.0068

其中, $S_1 \cap S_2 \cap S_3$ 为三个摄像机的公共工作区域. RFWR1、RFWR2 和 RFWR3 的接受域个数分别为 27、30 和 26. 仿真表明, 新模型的加入不会对已有模型产生任何影响, 更不需要对原来的融合方法做太大的修改, 通过简单的加权平均就可以在原来方法的基础上扩展为一个新的融合方法. 相反, 如果采用第一种基于 BP 的融合方法, 则必须放弃已有的神经网络模型, 重新对三个摄像机的情况进行训练建模. 另外, 可以看出在公共区域通过融合可以得到更高的精度, 这也是采用多传感器融合的一个重要原因.

最后考虑该方法的鲁棒性. 在前面的仿真中, 图像噪声设定为 $N(0, 0.001)$. 下面, 将图像噪声设定为 $N(0, 0.01)$, 然后重新采样, 得到一组样本点, 它对样本点的影响如表 5.

表 5 噪声 $N(0, 0.001)$ 对样本点(在 S_{12} 上)的影响

项 目	RFWR1		RFWR2	
	训练样本	测试样本	训练样本	测试样本
最大误差(ME)	1.9898	2.1534	2.2924	1.7788
均方差(MSE)	0.5738	0.5859	0.5319	0.5063

重复 4.1 节中的仿真, 结果如表 6 所示.

表 6 在 S_{12} 上 RFWR 模型的训练结果及其融合结果

(噪声: $N(0, 0.01)$)

项 目	RFWR1		RFWR2		Fusion	
	训练样本	检验样本	训练样本	检验样本	训练样本	检验样本
最大误差(ME)	1.9694	2.8724	2.3171	2.1435	1.4865	1.7001
均方差(MSE)	0.5549	0.7033	0.7729	0.8384	0.3262	0.4128

通过表 5 和表 6 的比较可以看出, 基于 RFWR 的融合方法能够有效克服噪声的影响. 其中 RFWR1 和 RFWR2 的训练周期、接受域个数分别为: (1 epoch, 16RF) 和 (14 epoch, 15RF).

通过上面的仿真, 可以看出基于 RFWR 的融合方法是一种鲁棒的、具有渐进学习能力的融合方法. 和其他具有学习能力的融合方法相比, 它不仅具有很强的学习能力, 而且在学习过程中表现出良好的特性, 如训练周期短, 训练精度高, 而且稳定性好. 此外, 渐进的学习能力和灵活的融合结构使其具有良好的适应性, 从而能够很好地适应感知区域以及融合结构的变化. 最后, 该方法具有一定的鲁棒性, 能够有效地克服噪声等不确定因素的影响. 综上所述, 基于接受域加权回归的融合方法, 为我们提供了一种解决动态与未知环境下融合问题的有效方案, 即渐进式学习与融合方法的结合.

5 结论

本文提出了一种具有渐进学习能力的多传感器融合方法, 即基于接受域加权回归的融合方法. 该方法是基于局部区域的信息处理与信息融合的结合. 它能够有效地解决以往方法所面临的问题, 通过学习不仅能够得到传感器模型, 而且可以得到其相应的不确定性模型. 更重要的是该方法具有很好的灵活性, 为整个系统的扩展提供了保证. 典型应用的仿真结

果已经说明了所提方法的性能和特点. 今后工作将要集中在如何进一步降低算法的计算量, 提高算法的实时性, 以便更好地满足实际应用的要求.

参考文献:

- [1] Yongtae Do. Application of Neural Network for Stereo Camera Calibration[A]. Proceedings of International Conference on Neural network [C]. Washington: IEEE, 1999.
- [2] X Dai, S Khonam. Data fusion using artificial neural networks: a case study on multitemporal change analysis[J]. Computers, Environment and Urban Systems, 1999, 23(2): 19- 31.
- [3] Guoqing Wei, G Hirzinger. Multisensory Visual Serving by a Neural Network[J]. IEEE Trans. on Systems, Man and Cybernetics, 1999, 29(2): 276- 280.
- [4] Joris W M van Dam, Ben J A Krose, Francisus C A Groen. Adaptive Sensor Models[A]. Proceedings of the 1996 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems[C]. Washington: IEEE, 1996.
- [5] Ren C Luo, Michael G Kay. Multisensor Integration and Fusion in Intelligent Systems[J]. IEEE Trans. on Systems, Man and Cybernetics, 1985, 19(5): 901- 931.
- [6] Ren C Luo, Michael G Kay, W Gary Lee. Future Trends in Multisensor Integration and Fusion[A]. Proceedings of Industrial Electronics[C]. , Italy: IEEE International Symposium on Published, 1994.
- [7] Daiki Masumoto, Himshi Yamakawa, Takashi Kimoto, Shigemi Nagata. Hierarchical Sensory-Motor Fusion Model with Neural Networks[A]. Proceedings of the 1994 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems[C]. Las Vegas. IEEE, 1994.
- [8] Harouna Kabre. On the Active Perception of Speech by Robots[A]. Proceedings of the 1996 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems[C]. Washington: IEEE, 1996.
- [9] Futoshi Kobayashi, Fumihito Arai, Toshio Fukuda, Makoto Onoda, et al. Sensor Selected Fusion System[A]. Proceedings of the 1999 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems[C]. Taiwan: IEEE, 1999.
- [10] Stefan Schaal, Christopher G. Atkeson. Constructive Incremental Learning From Only Local Information[J]. Neural Computation, 1998, 10(8): 2047- 2084.
- [11] 陆建峰, 唐振民, 杨静宇, 刘克, 邬永革. 多传感器的联合标定方法[J]. 机器人, 1997, 19(5): 365- 371.

作者简介:



王 军 男, 1973 年 4 月出生于陕西省宝鸡市, 1998 年毕业于西安交通大学系统工程研究所, 获工学硕士学位, 同年, 考入上海交通大学自动化研究所攻读博士学位, 师从席裕庚教授.

苏剑波 男, 1969 年 11 月生于江苏靖江, 现为上海交通大学自动化系教授, 博士生导师.