

基于信息势能的鲁棒估计器及其在同时定位与地图构建问题中的应用

刘 葵¹, 任雪梅¹, A. B. RAD²

(1. 北京理工大学 自动化科学院, 北京 100081; 2. 西蒙菲沙大学 机械电子系, 加拿大 素里 V3T 0A3)

摘要: 提出了一种基于信息势能鲁棒估计器来解决机器人室内的同时定位与地图构建(SLAM)问题. 结构化的室内环境可以用线段近似表示. 然而动态环境中, 测距传感器测得的数据通常湮没在大量的噪声信号中. 本文采用“分割与合并”(split-and-merge)方法进行线段的分类, 根据信息势能的性能指标衡量每个采样数据对该线段的信息贡献量. 按照信息优化理论设计估计器, 选择信息量贡献大的样本点作为信息内点提取线段参数, 构建局部地图. 采用粒子滤波器进行地图及机器人路径的更新. 采用递推的方法估计信息势能, 降低了对样本点的信息量贡献做估计时的复杂度. 仿真和实验结果证明, 本文所提出的方法具有较强的鲁棒性, 提高了SLAM策略的准确性和实时性.

关键词: 信息势能; 自主机器人; 鲁棒估计; 定位与地图构建

中图分类号: TP242.6 **文献标识码:** A

Robust estimator based on information potential and its application to simultaneous localization and mapping

LIU Yan¹, REN Xue-mei¹, RAD A B²

(1. School of Automation, Beijing Institute of Technology, Beijing 100081, China;

2. Department of Mechatronic Systems Engineering, Simon Fraser University, Surrey V3T 0A3, Canada)

Abstract: We present a novel robust estimator based on information potential optimization techniques and apply it to simultaneous localization and mapping on segment-based maps. Structured indoor environment can be efficiently described with Segment-based maps. Usually, in dynamic environment, sample data collected by range-finders suffer from noises and disturbances. Sample data are divided into clusters with split-and-merge. Inliers of the segment are selected according to the information contribution which is measured by information potential. After the local map is built, particle filters are adopted to update robot poses and maps. The recursive information potential reduces computations of information contribution of each sample. Simulations and experimental results validate the strong robustness of the proposed estimator, and the accuracy and efficiency of the proposed strategy based on the robust estimator.

Key words: information potential; autonomous robot; robust estimator; localization and mapping

1 引言(Introduction)

移动机器人的同时定位与地图构建(simultaneous localization and mapping, SLAM)是机器人研究领域的热点课题. 其核心问题是研究在未知环境中, 机器人利用自身的传感器探测环境构建地图的同时, 进行实时的定位. SLAM问题研究过程中, 如何有效地表示地图构建及定位过程中的不确定性及如何降低这种不确定性是研究的难点. 基于扩展卡尔曼滤波器(extended Kalman filter, EKF)的SLAM方法首先在1987年由Smith和Cheeseman提出^[1]. 该方法假定环境特征必须是唯一确定的, 而且系统的输入噪声和观测噪声服从高斯分布, 并采用EKF来更新机器人的位姿及环境特征的后验概率. 然而由于

SLAM问题的高度非线性, EKF的线性化过程容易导致估计的发散, 同时噪声模型的高斯假设也限制了该方法的应用^[2].

近年来, 粒子滤波(particle filter, PF)技术^[3]逐渐被引入SLAM问题中. 粒子滤波是一种蒙特卡洛方法, 通过从提议分布的采样获得粒子集, 以该粒子集表示机器人的位姿和路径的后验分布^[4]. 虽然粒子滤波是一种近似估计, 但是这种方法是非参数且非线性的, 是解决SLAM问题强大的工具^[3]. 然而粒子滤波技术也存在着计算量大、粒子集易贫化等问题. EKF和PF都是基于贝叶斯网络的滤波技术, EKF假设噪声服从高斯分布, 而PF以粒子集来逼近噪声的分布. 不确定性是实际工程中普遍面临的问题.

信息熵作为一种不确定性的度量, 已经被广泛地应用在通信领域. 信息熵^[5,6]由Shannon提出, 它表示随机变量携带的信息量的大小. 根据实际工程的不同需要, 不同类型的熵被陆续提出, 进而衍生出一系列的熵优化方法. 近年来, 熵优化方法逐渐被引入SLAM问题中. Manyika和Durrant-Whyte^[7]定义了后验熵(posterior entropy)、前验熵(prior entropy)及似然信息(likelihood information)等度量表示传感器的不确定性, 并基于此提出了一套数据融合及传感器管理方法, 并成功地应用在SLAM问题上. Burgard等人^[8]开创性地提出了一种最小化未来信度熵(entropy of future belief)的方法实现了机器人的主动定位. 应用信息熵表示不确定性需要事先确定随机变量的概率模型.

传统的基于信息优化技术的SLAM策略通常假定噪声服从高斯分布, 并对熵函数进行线性逼近. 然而研究指出, 这样的处理结果会降低信息的利用率, 使结果产生退化. Rao-Blackwellized粒子滤波器(RBPF)技术^[9,10]的引入克服了这一问题. RBPF保留了粒子集中每个粒子的路径, 可以在估计出地图的信度的同时估计出机器人位姿的信度. 通过恰当地定义熵的形式, 可以将地图的不确定性与机器人位姿的不确定性统一考虑, 进而实现全局优化的SLAM. 由于占据栅格(occupancy grid, OG)地图^[3,11]便于计算栅格的概率和信息量, 目前基于信息优化技术的SLAM研究主要采用了OG地图.

OG地图的数据量比较大, 加重了RBPF更新的计算负担. 结构特征明显的室内环境, 可以用基于线段的地图(segment-based map)表示, 在保证精度的同时, 降低数据的存储量, 提高SLAM策略的实时性. 理论上讲, 两个精确的点即可以确定一条直线. 在动态环境下, 在提取线段模型时, 需要采取鲁棒算法来克服噪声的干扰. 从信息论的原理出发, 来自于同一条线段的样本点携带着关于这条线段的信息. 线段的内点(inliers)相对于噪声点(outliers)而言, 应该携带有关于这条线段的更多的信息量. 基于这一思想, 笔者曾提出了一种基于香农熵的鲁棒线性估计器^[12], 用以提取复杂环境下线段的参数.

实验结果表明, 该方法能在强噪声环境下提取出线段的内点进而求得线段的参数, 有很强的鲁棒性. 但是该方法需要反复地进行香农熵的估计, 使得计算量较大. 为解决此问题, 笔者采用信息势能来衡量样本集的信息量. 由于信息势能可以用核函数的和的形式表示, 因此可以方便地推导出信息势能的递推关系, 直接获得采样点对样本集信息量的贡献, 避免了反复的信息熵的估计, 显著地降低了算法的计算量, 提高了算法的实时性. 根据此该鲁棒估计方法设计出动态环境下的SLAM策略, 并通过仿真及实

验验证了笔者提出的方法的有效性.

2 信息势能及其性质(Information potential and its property)

信息熵作为衡量随机变量所携带的信息量的度量, 已经被广泛地应用在各个领域. 香农定义了香农信息熵, 用以表示通信系统中的不确定性, 其形式为

$$H_S(\mathbf{x}) = - \sum_{i=1}^n f_i \log f_i, \quad (1)$$

其中: $\mathbf{x} = (x_1, x_2, \dots, x_n)$ 是 n 维随机变量, $f_i = f(x_i)$ 是其第 i 个元素的概率. 从式(1)可以看出, 计算熵必须首先获得变量的概率密度模型, 它可由核函数概率估计器(kernel density estimator, KDE)^[13]直接从样本中估计:

$$f_i = \frac{1}{n} \sum_{i=1}^n k(\mathbf{x} - x_i), \quad (2)$$

其中 $k(x_i) = \frac{1}{\sqrt{2\pi}\sigma} \exp\{-\frac{x^2}{2\sigma^2}\}$ 为高斯核函数. 将KDE估计出的概率式(2)代入式(1), 便可获得随机变量携带的信息量. 然而由于香农熵中的对数形式, 难于进行信息熵的递推计算, 增加了计算信息熵的复杂度. 信息是一个比较模糊的概念, 关于信息的定义目前尚无统一的形式. 因此在采用熵优化技术时, 首先要明确所示信息的意义并根据实际需要确定熵的形式, 然后采用相应的优化技术进行设计.

信息势能(information potential, IP)^[14]是另一种信息量的度量. 已知随机变量 $\mathbf{x} = \{x_1, x_2, \dots, x_n\}$, 它所蕴含的信息势能可以表示为

$$V_\alpha(\mathbf{x}) = \int_{-\infty}^{+\infty} f_\alpha(\mathbf{x}) d\mathbf{x}, \quad (3)$$

其中 α 为信息势能的阶数. 为方便计算, 通常取 $\alpha = 2$. 将由KDE估计的样本的概率代入式(3), 可得到2阶信息势能的非参数估计形式:

$$\hat{V}_n(\mathbf{x}) = \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n k(x_j - x_i). \quad (4)$$

由于信息势能可采用核函数的和的形式表示, 因此信息势能可以很容易的采用递推形式表示:

$$\begin{aligned} \hat{V}_{n+1}(\mathbf{x}) &= \frac{1}{(n+1)^2} \sum_{j=1}^{n+1} \sum_{i=1}^{n+1} k(x_j - x_i) = \\ &= \frac{1}{(n+1)^2} \left[\sum_{j=1}^n \left(\sum_{i=1}^n k(x_j - x_i) + k(x_j - x_{n+1}) \right) + \sum_{i=1}^n k(x_i - x_{n+1}) + k(0) \right] = \\ &= \frac{n^2}{(n+1)^2} \hat{V}_n + \frac{1}{(n+1)^2} \left[2 \sum_{i=1}^n k(x_i - x_{n+1}) + k(0) \right]. \end{aligned} \quad (5)$$

令 $\lambda = \frac{n}{n+1}$, 则上式可写为

$$\hat{V}_{n+1} = \lambda^2 \hat{V}_n + (1-\lambda)^2 \left[2 \sum_{i=1}^n k(x_i - x_{n+1}) + k(0) \right]. \quad (6)$$

3 信息势能及其性质(Information potential and its property)

激光、声纳等传感器是典型的序贯采样(sequential sampling)测距传感器。当采用基于线段的地图表示实际环境时, 有两个关键问题需要解决:

- 1) 样本数据中包含线段的个数;
- 2) 如何提取出线段的参数。

在确定样本中的线段个数时, 需要采用的相应的聚类方法。由于缺少采样环境的信息, 特别是在动态的复杂的室内环境中, 准确地判断出线段个数并进行分类仍然是一个挑战。在综合比较了各种聚类算法后, 并结合测距传感器的采样特点, 采用一种基于Split-and-Merge的分类方法^[15]进行快速分类, 以提高算法的实时性。

在进行了线段的分类之后, 下一步将进行线段的参数的提取。分类后的线段仍然含有噪声, 因此应采用鲁棒方法以尽量降低噪声的干扰。分类后的每一组线段集中的样本点均被认为采样于同一条线段。鲁棒估计器的目的就是要采用一定的方法甄别出线段的内点及噪声点, 进而用线段内点提取线段的准确的参数。

根据信息论的基本思想, 样本集中的每个样本点都含有关于此线段的信息, 但是线段内点应比噪声点含有更多的信息量。在传感器获得的采样点中, 线段内点的绝对数量可能少于噪声点的数量, 但在线段的真实位置附近, 应该聚集有更多的采样点, 即样本点的出现频率更高。

采用KDE技术, 可以直接从样本集估计样本点的出现的概率。设第 S_1 个线段的样本点集合由 m 个样本点组成, 即 $s_1 = \{(x_i, y_i), i = 1, 2, \dots, n\}$, 则第 i 个样本点的出现的概率可由二维KDE近似表示为

$$\hat{P}(s_1) = \frac{1}{n} \sum_{i=1}^n k(s_1^i - s_1), \quad (7)$$

$$k(s_1^i - s_1) = \det(2\pi\Sigma)^{-\frac{1}{2}} \cdot \exp\left\{-\frac{1}{2}(s_1^i - s_1)^T \Sigma^{-1}(s_1^i - s_1)\right\}. \quad (8)$$

保留出现概率较大的样本作为该线段的主结构域, 即

$$\hat{p}(s_1^i) > \beta(\max \hat{P}(s_1) - \min(\hat{P}(s_1))) + \min(\hat{P}(s_1)),$$

其中 $0 < \beta < 1$ 为概率滤波系数。由于KDE直接从采样集估计样本点的出现概率, 因此主结构域的形状也取决于样本点的实际分布。在实际应用中, 直线

的实际位置附近样本点出现的概率更高, 则得到的主结构域主要由线段内点构成, 如图1所示。图中样本点的出现概率由等概率线表示。可以看到, 样本点的出现概率最大值为0.06, 最小值为0。通常 β 可取为0.5, 这样图中出现概率为0.03的等概率线包围的区域可以认为是该线段的主结构域。然而主结构域仍然受到噪声的影响, 使得该区域不能覆盖所有的线段内点, 同时该区域仍然包含有一定量的噪声点。




图1 包主结构域的提取

Fig. 1 Extraction of main structure of segment

为了便于分析, 以主结构域中的样本点提取出的线段表示这个区域。设表示主结构域的这条线段参数为 (γ, θ) , 其中: γ 为原点距直线的斜率, θ 为该直线的法向量的方向。样本点距主结构域的距离可以样本点距该线段的距离表示:

$$d_j = \rho(r_j - x_j \cos \theta - y_j \sin \theta), \quad (9)$$

其中: 若该点在线段下方, $\rho = 1$; 否则 $\rho = -1$ 。那么样本集携带的关于线段的信息可以用距离的信息势能表示:

$$\hat{V}_n(d) = \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n k(d_j - d_i). \quad (10)$$

从信息论的角度分析, 由于线段的内点携带有更多的信息量, 因此如果将一个线段内点从整个样本集中移除, 那么整个样本集的信息势能的改变量应该远大于移除一个内点而引起的信息量的改变。

由式(6)可知, 在移除一个样本点 d_j 前后, 样本集的距离信息势能的变化量为

$$\Delta \hat{V}_j = \hat{V}_n(d) - \hat{V}_{n-1}^j. \quad (11)$$

由上文分析可知, 使信息势能产生较大变化的样本点为线段内点, 即选择

$$\Delta \hat{V}_j > \eta(\max(\Delta \hat{V}_j) - \min(\Delta \hat{V}_j)),$$

$0 < \eta \leq 1$ 为信息滤波参数。

为了简化计算,可以先移除一个样本点 d_j ,计算这 $n-1$ 个点构成的集合的信息势能

$$\hat{V}_{n-1}^j = \frac{1}{(n-1)^2} \sum_{i \neq j} \sum_{i \neq j} k(d_j - d_i), \quad (12)$$

然后计算增加这个样本点 d_j 后信息势能的变化量,则

$$\begin{aligned} \Delta \hat{V}_j &= \hat{V}_n(d) - \hat{V}_{n-1}^j = \\ &\lambda^2 \hat{V}_{n-1} + (1-\lambda)^2 [2 \sum_{i \neq j} k(d_j - d_i) + k(0)] - \hat{V}_{n-1}^j = \\ &(\lambda^2 - 1) \hat{V}_{n-1}^j + (1-\lambda)^2 [2 \sum_{i \neq j} k(d_j - d_i) + k(0)], \quad (13) \end{aligned}$$

其中 $\lambda = \frac{n-1}{n} < 1$ 为常值. 因此在选择线段内点时,可以根据式(13)选取更为简化的性能指标:

$$I_j = 2(1-\lambda) \sum_{i \neq j} k(d_j - d_i) - (\lambda+1) \hat{V}_{n-1}^j, \quad (14)$$

则满足 $I_j > \eta(\max(I_j) - \min(I_j))$, $0 < \eta \leq 1$ 的样本点就是线段的内点.

相比于文献[12]中提出的方法,以香农熵及信息势能作为信息量的度量选取对样本集信息量贡献大的样本点作为线段内点,均应用了这两个概念自身的鲁棒性特点. 特别是采用KDE进行了样本点概率密度的估计后,实际上已经将样本从二维的距离空间映射到了高维的核空间,使得在二维空间十分复杂的回归问题转化为在核空间以信息势能的变化量为性能指标的可分问题.

从文中的分析可以看到, KDE 以和的形式进行概率密度的估计,这使得它能很好地与信息势能相结合. 相比于香农熵中的对数形式,采用信息势能可以推导出信息量变化的递推形式,使得计算量由 $O(n^3)$ 显著地降为 $O(n^2)$,从而提高了算法的实时性.

4 仿真及实验(Simulations and experiments)

在环境信息未知的情况下,机器人的SLAM策略使得机器人利用自身的传感器采集的信息构建地图并实时地更新地图及机器人的位姿. 在通过上文介绍的基于IP的鲁棒估计器获得了局部地图中的线段的参数后,将利用粒子滤波器进行更新在本节,进行多组仿真及实验以验证基于信息势能的鲁棒估计器的性能及其在SLAM中的应用.

1) 鲁棒估计器的性能的验证.

首先选取一个受到大量噪声干扰的数据集进行仿真,以验证提出的估计器的鲁棒性,如图2所示. 在该图中共有165个样本点,其中: 30个为线段内点,以模拟室内环境中的墙壁,其余的是均匀分布在线段一侧的噪声点. 可知线段内点所占的比例小于20%. 在这样的强噪声环境下,一些鲁棒回归算法如中值滤波器, MM-estimator 等,已不能得到正确结果[16,17].




图2 强噪声条件下鲁棒估计器对线段内点的提取
Fig. 2 Inliers extraction with the proposed robust estimator under severe noises

线段的主结构域由 $\mathbf{x}$ 表示,可以看出,这个区域位于线段的真实位置附近,但是包含有噪音点,受其影响主结构域中的点采用最小二乘回归的线段(由虚线表示)仍略偏离真实位置,但是该区域却可以代表关于这条线段的信息量的集中的区域.

图3所示为每个样本点对该线段的信息量的贡献,及从样本集中移除该点后,该样本集携带的信息势能的变化量. 从图中可以看出只有少量的样本点对整个样本集的信息势能的贡献率较大. 以信息论的角度分析,线段内点对整个样本集的信息量的贡献应大于噪声点. 选取信息势能滤波参数 $\eta = 0.5$,则这些线段内点(见图2)被成功地与噪声点区分开来. 由于本文采取了递推的方法直接计算信息量的变化量,与文献[12]采用香农熵的鲁棒估计方法相比较,计算量显著地下降. 在本例中,从此样本集中成功提取线段耗时2.0255 s,而针对同样的样本集,采用文献[12]中方法需要7.2507 s. 由此验证了本文提出的算法的实时性有了显著提高.




图3 基于信息势能的性能指标
Fig. 3 Index based on information potential

2) SLAM策略的验证.

本部分选取了一个较为复杂的实际环境验证所提出的方法. 如图4所示,该环境涵盖面积比较大,且不断地由人在环境中移动.



图4 实验环境

Fig. 4 Environment of the experiments

包含有里程计原始误差的地图如图5所示. 从图中可以明显看到, 机器人在面积较大的环境中行走一圈后, 其路径不能实现重合, 存在较大的误差.




图5 包含里程计原始误差的地图

Fig. 5 Map with odometer error

应用本文提出的鲁棒估计器构建出每一帧传感器数据中的局部地图. 图6显示的是第82帧表示的局部地图.




图6 第82帧表示的局部地图

Fig. 6 Local map extracted from 82th frame of data

在采用RBPF进行地图及机器人位姿的更新后, 全局地图如图7所示. 由于环境内侧由玻璃构建, 由声纳传感器探测得到, 采用虚线表示. 环境外侧由激光传感器获得, 由实线表示. 全局地图得到了准确地构建, 验证了本文提出的估计器的性能.




图7 全局地图

Fig. 7 Global map

5 结论(Conclusion)

本文针对基于线段的室内环境的SLAM问题, 提出了基于信息势能的鲁棒估计器, 以移除一个样本点前后样本集携带的信息势能的变化量来表征该样本点对整个样本集的信息的贡献, 并选择那些贡献大的样本点作为线段的内点提取线段的参数. 由于信息势能这个物理量自身具有较强的鲁棒性, 因此本文提出的估计器能在复杂环境下克服噪声点的干扰, 准确地提取出线段的参数, 显示出了良好的鲁棒性. 同时由于信息势能便于进行递推计算, 降低了算法的复杂度, 因此基于该鲁棒估计器的SLAM策略的精确性的实时性得到了显著提高.

致谢 第一作者感谢国家留学基金委资助其赴Simon Fraser University进行两年的联合培养.

参考文献(References):

- [1] SMITH R C, CHEESEMAN P. On the representation and estimation of spatial uncertainty[J]. *International Journal of Robotics Research*, 1987, 5(4): 56 – 68.
- [2] HUANG S D, DISSANAYAKE G. Convergence analysis for extended Kalman filter based SLAM[C]//*Proceedings of the 2006 IEEE International Conference on Robotics and Automation*. New York: IEEE, 2006: 412 – 417.
- [3] THRUN S, BURGARD W, FOX D. *Probabilistic Robotics (Intelligent Robotics and Autonomous Agents)*[M]. Cambridge: The MIT Press, 2005.
- [4] DOUCET A, FREITAS N D, GORDON N J, et al. *Sequential Monte Carlo Methods in Practice (Statistics for Engineering and Information Science)*[M]. New York: Springer, 2001.
- [5] SHANNON C E. A mathematical theory of communication [J]. *The Bell System Technical Journal*, 1948, 27: 379 – 423, 623 – 656.
- [6] COVER T M, THOMAS J A. *Elements of Information Theory*[M]. Hoboken: Wiley-Interscience, 2006.
- [7] MANYIKA J, DURRANT-WHYTE H. *Data Fusion and Sensor Management: A Decentralized Information-Theoretic Approach*[M]. Upper Saddle River: Prentice Hall PTR, 1995.

- [8] BURGARD W, FOX D, THRUN S. Active mobile robot localization by entropy minimization[C] // *Proceedings of the Second EUROMICRO Workshop on Advanced Mobile Robots*. Los Alamitos, CA: IEEE Computer Society Press, 1997: 155 – 162.
- [9] DOUCET A, FREITAS N D, MURPHY K, et al. Rao-blackwellised particle filtering for dynamic bayesian networks[C] // *Proceedings of the 16th Conference on Uncertainty in Artificial Intelligence*. San Francisco: Morgan Kaufmann Publishers Inc, 2000: 176 – 183.
- [10] MILLER I, CAMPBELL M. Rao-blackwellized particle filtering for mapping dynamic environments[C] // *Proceedings of the 2007 IEEE International Conference on Robotics and Automation*. New York: IEEE, 2007: 3862 – 3869.
- [11] THRUN S. *Robotic Mapping: A Survey*[M]. San Francisco: Morgan Kaufmann Publishers, 2003.
- [12] LIU Y, et al. Entropy based robust estimator and its application to line-based mapping[J]. *Robotics and Autonomous Systems*, 2010, 58(5): 566 – 573.
- [13] RICHARD O D, PETER E H, DAVID G S. *Pattern Classification*[M]. 2nd Edition. Hoboken: Wiley-Interscience, 2000.
- [14] ERDOGMUS D. *Information theoretic learning: renvi's entropy and its applications to adaptive system training*[D]. Gainesville: University of Florida, 2002.
- [15] BORGES G A, ALDON M J. A split-and-merge segmentation algorithm for line extraction in 2-D range images[C] // *Proceedings of the International Conference on Pattern Recognition*. Los Alamitos, CA: IEEE Computer Society Press, 2000: 441 – 444.
- [16] HUBER P J. *Robust Statistics*[M]. Hoboken: Wiley, 2004.
- [17] YOHAI V J. High breakdown-point and high efficiency robust estimates for regression[J]. *Journal of the American Statistical Association*, 1987, 15(2): 642 – 656.

作者简介:

刘 葵 (1982—), 男, 博士研究生, 研究方向为智能机器人、信息优化算法, E-mail: iamliuyan@yahoo.com.cn;

任雪梅 (1967—), 女, 教授, 博士生导师, 研究方向为智能信号处理、模式识别与智能控制, E-mail: limm@sina.com.cn;

A. B. RAD (1957—), 男, 教授, 研究方向为智能机器人, E-mail: arad@sfu.ca.

下 期 要 目

事件驱动的动态服务组合策略在线自适应优化 江 琦, 奚宏生, 殷保群
 一类离散时变系统的在线无限脉冲响应滤波逆控制 刘建昌, 于 霞, 李鸿儒
 基于非光滑观测器的带死区三明治系统状态估计 周祖鹏, 谭永红
 可控搜索偏向的二元蚁群算法 胡 钢, 熊伟清, 张 翔, 袁军良
 改进型粒子滤波算法在多站纯方位被动跟踪中的应用 李银伢, 谭维茜, 盛安冬
 用于多个机动目标的混合高斯概率假设密度跟踪器 刘贵喜, 周承兴, 王泽毅, 廖兴海
 多时滞线性系统的控制参数优化方法 陈 宁, 沈晓瑜, 桂卫华, 阳春华, 王凌云
 具有数据包丢失及转移概率部分未知的网络控制系统 H_∞ 控制 邱 丽, 胥布工, 黎善斌
 求解资源受限项目调度问题的约束规划/数学规划混合算法 刘士新, 宋健海
 电动舵机的复合自适应非奇异终端滑模控制 李 浩, 窦丽华, 苏 中
 随机非线性动态系统数值模拟与性态分析 彭云建, 程 培, 邓飞其
 一种小样本支持向量机控制器在两足机器人步态控制的研究 王丽杨, 刘 治, 赵之光, 章 云
 汽车横摆的动态模型 刘志远, 周洪亮, 陈 虹
 一种混合有源电力滤波器的电流控制新方法 吴敬兵, 罗 安, 彭双剑, 于 力