



传感器网络分布式稳健 RLS 估计算法

康凯凯, 刘兆霆, 姚英彪

(杭州电子科技大学通信工程学院, 浙江 杭州 310018)

摘要: 针对在传感器网络的参数估计中, 测量环境可能存在冲击噪声或脉冲干扰, 导致测量值中包含大大偏离实际范围的离群值, 从而无法获得有效的参数估计问题, 提出了一种基于节点协作、具有稳健性的分布式 RLS 估计算法, 该算法利用在一段时间内, 节点受到干扰或攻击通常具有偶发性(即稀疏性)的特点, 在代价函数中引入 ℓ_1 范数, 对测量数据中可能存在的离群值进行识别和剔除, 同时利用网络各节点之间的相互协作, 进一步提高参数估计的性能。通过计算机仿真实验, 验证了该算法具有良好的估计性能。

关键词: 传感器网络; 稳健性; 分布式处理; 自适应估计

中图分类号: TP393

文献标识码: A

doi: 10.11959/j.issn.1000-0801.2019002

Distributed robust RLS estimation algorithm over sensor networks

KANG Kaikai, LIU Zhaoting, YAO Yingbiao

School of Communication Engineering, Hangzhou Dianzi University, Hangzhou 310018, China

Abstract: In the parameter estimation of the sensor network, there may be impact noise or pulse interference in the measurement environment, which leads to the outliers that greatly deviate from the actual range, so that the effective parameter estimation problem can't be obtained. A distributed RLS estimation algorithm based on node cooperation and robustness was proposed. The characteristic of interference or attack on a node is usually sporadic (ie, sparse) for a period of time was utilized, ℓ_1 norm was introduced to cost function. The outliers which may exist in the measurement data were identified and eliminated, and the interaction between the nodes of the network was utilized to further improve the performance of the parameter estimation. The computer simulation experiments show that the algorithm has good estimation performance.

Key words: sensor network, robustness, distributed processing, adaptive estimation

1 引言

基于传感器网络的参数估计在军事国防、工

农业控制、环境检测、危险区域远程控制等领域有着广泛的应用^[1-4], 它通过建立一定的统计模型, 并采用各种算法从被噪声污染的信号测量值

收稿日期: 2018-04-08; 修回日期: 2018-09-29

基金项目: 国家自然科学基金资助项目 (No.61671192); 浙江省自然科学基金资助项目 (No.LY16F010012)

Foundation Items: The National Natural Science Foundation of China (No.61671192), Zhejiang Provincial Natural Science Foundation of China (No.LY16F010012)



中获得对某一参数的估计,从而确定不同物理量之间的相互依赖关系。

目前基于传感器网络的参数估计方式主要包括集中式^[5]和分布式^[5-6],传统的集中式估计方法将传感器信息直接送至数据融合中心进行处理,可获得较高的估计精度,然而这种方法要求中央节点必须具有强大的计算和存储能力,因此可靠性差,对计算和通信资源要求高,特别是针对存在大规模节点的传感器网络,这种集中式估计方法的缺点更为明显。相反,若每个传感器节点与其邻居节点以一定的方式进行信息交换,从而通过局部信息影响机制,融合空间和时间的测量信息和冗余度,则往往可以克服集中式估计的缺点,这种信息处理方式称为分布式估计,并成为近年来研究的热点,已经提出了许多相应的算法,如分布式最小均方(least mean square, LMS)算法或递推最小二乘(recursive least square, RLS)算法、分布式稀疏算法^[7-9]、权重自适应的分布式估计算法^[10]、基于删失回归模型的分布式算法^[11]等。

针对大规模分布的传感器网络,不同的网络节点可能处于不同的测量环境中。当某些节点处于冲击噪声或脉冲干扰^[12-13]的测量环境中时,测量数据中可能含有大大偏离实际范围的离群值,使得对应节点的估计性能急剧下降,同时,网络的连通性和节点协作机制使得当一个节点受到干扰或攻击时,该节点产生的不准确的参数估计值将通过一系列的邻居节点扩散到整个网络,使整个网络的分布式估计性能也受到极大的影响。在传统的自适应参数估计算法中,基于残差平方作为代价函数的算法对数据中的离群值非常敏感,造成估计结果非常不稳定。相比之下,采用残差绝对值作为代价函数的算法,对这样的离群值的敏感性较弱,估计结果的稳定性较好,然而该类算法获得估计精度并不高。

注意到,当某些节点受到干扰或攻击时,为了避免网络的估计性能受到影响,保证分布式估

计有效进行,可采用删除这些节点的方法。然而,这会导致网络的拓扑发生改变,影响网络性能,并且在节点在协作过程中,需要对各自的权重进行重新分配,增加计算负担。针对这个问题,本文基于扩散的分布式RLS(d-RLS)算法^[14],利用在一个测量时间窗内节点受到干扰或攻击具有偶发性(稀疏性)的特点,建立具有稀疏约束的代价函数,并对该节点每一个时间窗内的离群值进行在线RLS估计,将获得的离群值估计对输出测量值进行偏差补偿,从而获得较好的参数估计结果。该算法不需要矩阵的转置和求逆,降低了计算的复杂度,收敛速度快,稳定性好,同时无需改变网络的拓扑结构以及重新分配融合权重。

2 传感器网络信号模型

传感器网络如图1所示,考虑一个由 N 个节点构成的传感器网络,每个节点 k 在每个时刻 i 能够获得测量值为 $\{d_{k,i}, u_{k,i}\}$,并且满足下列线性关系:

$$d_{k,i} = u_{k,i}^T w_0 + n_{k,i}, k=1, 2, \dots, N \quad (1)$$

其中, $u_{k,i}$ 为节点 k 在 i 时刻的系统输入,且为一个 M 维列向量, $d_{k,i}$ 对应系统输出, $n_{k,i}$ 为节点 k 在 i 时刻的测量噪声, w_0 是所有节点需要共同估计的系统参数矢量。




图1 传感器网络

假设每个传感器节点只能与其邻居节点进行直接通信,本文的目的是基于该传感器网络各个节点的测量值,并通过节点间的相互协作,获得未知参数 w_0 的分布式估计。特别地,考虑网络中

某些节点受到冲击噪声或恶意干扰情况下的有效估计问题。在这种情况下,受干扰的节点所获得的测量数据中可能包含大大偏离实际范围的离群值,从而网络节点测量模型(1)可以重新表示为:

$$d_{k,i} = \mathbf{u}_{k,i}^T \mathbf{w}_0 + n_{k,i} + o_{k,i}, \quad k=1, 2, \dots, N \quad (2)$$

其中, $o_{k,i}$ 为节点 k 测量数据中包含的离群值,若该节点不存在冲击噪声或干扰, $o_{k,i} = 0$; 否则, $o_{k,i} \gg \mathbf{u}_{k,i}^T \mathbf{w}_0 + n_{k,i}$, 即当节点 k 的测量数据中包含离群值时, $d_{k,i}$ 的值将远远超出实际范围。

在传统的 d-RLS 自适应算法中,各个节点根据收集到的测量值 $\{d_{k,i}, \mathbf{u}_{k,i}\}$ 获得未知参数的局部估计 $\hat{\mathbf{w}}_{k,i}$, 然后每个节点以基于扩散的协作方式将这些局部估计值与来自邻居节点的局部估计值进行融合。根据上述算法思想,应用传统的 d-RLS 算法,估计步骤主要为:

$$\begin{cases} \mathbf{h}_{k,i} = \frac{\lambda^{-1} \mathbf{P}_{k,i} \mathbf{u}_{k,i}}{1 + \lambda^{-1} \mathbf{u}_{k,i}^T \mathbf{P}_{k,i} \mathbf{u}_{k,i}} \\ \varphi_{k,i} = \hat{\mathbf{w}}_{k,i-1} + \mathbf{h}_{k,i} (d_{k,i} - \mathbf{u}_{k,i}^T \hat{\mathbf{w}}_{k,i-1}) \\ \mathbf{P}_{k,i} = \lambda^{-1} \mathbf{P}_{k,i} - \lambda^{-1} \mathbf{P}_{k,i} \mathbf{u}_{k,i}^T \mathbf{P}_{k,i} \\ \hat{\mathbf{w}}_{k,i} = \sum_{k=1}^K c_{k,i} \varphi_{k,i} \end{cases} \quad (3)$$

其中, $\mathbf{h}_{k,i}$ 是增益向量, $\mathbf{P}_{k,i}$ 是 $M \times M$ 的矩阵,表示系统的输入向量 $\mathbf{u}_{k,i}$ 的自相关矩阵之逆, λ 表示加权因子或遗忘因子, $\varphi_{k,i}$ 表示节点 k 仅根据前一时刻的估计值 $\hat{\mathbf{w}}_{k,i-1}$ 获得的中间的估计值,而 $\hat{\mathbf{w}}_{k,i}$ 是利用了其邻居节点的估计值的融合, $c_{k,i}$ 表示节点 k 与邻居节点 l 的融合权重,并且节点 k 与其所有邻居节点的融合权重可以组成 $N \times N$ 的矩阵 $\mathbf{C}$, 满足 $\mathbf{C}\mathbf{I} = \mathbf{I}$, $\mathbf{I}^T \mathbf{C} = \mathbf{I}^T$, $\mathbf{I}$ 是单位矩阵。

在上述的分布式估计算法中,由于冲击噪声或脉冲干扰使得测量值中包含离群值,导致参数估计值出现很大的偏差,并且由于网络的连通性和节点协作,这种估计偏差会通过邻居节点扩散到整个网络,导致传统分布式 RLS 算法的估计性能急剧下降。为了解决这个问题,本文提出一种

具有较好顽健性的分布式 RLS 算法。该算法的基本思想是,利用获得的离群值的估计对采样信号进行偏差补偿。

3 分布式 RLS 顽健性估计算法

通常,如果各个节点测量数据中的离群值 $o_{k,i}$ 是已知的,利用 $o_{k,i}$ 对系统输出 $d_{k,i}$ 进行偏差补偿,进而对 $d_{k,i} - o_{k,i}$ 应用分布式 d-RLS 算法可获得未知参数的估计值 $\hat{\mathbf{w}}_{k,i}$, 根据这一思路,假设每个传感器遇到的冲击噪声或脉冲干扰是偶发的,这等效于,在一段时间窗 T 内的数据 $\{o_{k,i}, o_{k,i-1}, \dots, o_{k,i-T+1}\}$ 中,只有少数个 $o_{k,j}$ ($i-T+1 \leq j \leq i$) 是非零的。也就是说,矢量:

$$\mathbf{o}_{k,i} = [o_{k,i}, o_{k,i-1}, \dots, o_{k,i-T+1}]^T \quad (4)$$

是稀疏的,于是考虑如下的联合优化问题:

$$\{\hat{\mathbf{w}}_{k,i}, \hat{\mathbf{o}}_{k,i}\} = \arg \min_{\mathbf{w}, \mathbf{o}} \frac{1}{2} \|\mathbf{d}_{k,i} - \mathbf{G}_{k,i}^T \mathbf{w} - \mathbf{o}\|_2^2 + \gamma \|\mathbf{o}\|_1 \quad (5)$$

其中, $\mathbf{d}_{k,i} = [d_{k,i}, d_{k,i-1}, \dots, d_{k,i-T+1}]^T$ 是 $T \times 1$ 矢量, $\mathbf{G}_{k,i} = [\mathbf{u}_{k,i}, \dots, \mathbf{u}_{k,i-1}, \mathbf{u}_{k,i-T+1}]$ 是 $M \times T$ 矩阵。在式(5)中考虑了矢量 $\mathbf{o}_{k,i}$ 的稀疏性,在代价函数中增加了 ℓ_1 范数作为稀疏约束 $\|\mathbf{o}\|_1 = \sum_{t=1}^T |o_t|$, 并通过参数 γ

来控制估计结果的稀疏程度。

这里,将式(5)的联合优化问题分解为下列两个子问题:

$$\begin{cases} \hat{\mathbf{o}}_{k,i} = \arg \min_{\mathbf{o}} \frac{1}{2} \|\mathbf{d}_{k,i} - \mathbf{G}_{k,i}^T \mathbf{w} - \mathbf{o}\|_2^2 + \gamma \|\mathbf{o}\|_1 \\ \hat{\mathbf{w}}_{k,i} = \arg \min_{\mathbf{w}} \frac{1}{2} \|\mathbf{d}_{k,i} - \mathbf{G}_{k,i}^T \mathbf{w} - \hat{\mathbf{o}}_{k,i}\|_2^2 + \gamma \|\hat{\mathbf{o}}_{k,i}\|_1 \end{cases} \quad (6)$$

对于式(6)中的第一个式子,本文采用基于坐标下降^[15]的方法获得离群值的估计:

$$\hat{o}_{k,i,m} = \arg \min_{\mathbf{o}} \frac{1}{2} \left\| \mathbf{d}_{k,i} - \mathbf{G}_{k,i}^T \mathbf{w}_{k,i-1} - \begin{bmatrix} \mathbf{o}_{k,i,1:m-1} \\ \mathbf{o}_{k,i,m} \\ \mathbf{o}_{k,i-1,m+1:T} \end{bmatrix} \right\|_2^2 + \gamma \|\mathbf{o}\|_1 \quad (7)$$

其中, $\hat{o}_{k,i,m}$ 表示对离群值估计矢量 $\hat{\mathbf{o}}_{k,i}$ 中第 m 个



元素值的估计,为了获得 $\hat{\mathbf{o}}_{k,i}$ 的估计,可以将式(7)转化为如下的标量形式:

$$\hat{o}_{k,i,m} = \arg \min_{o_{k,i,m}} \frac{1}{2} (o_{k,i,m} - \alpha_{k,i,m})^2 + \gamma |o_{k,i,m}| \quad (8)$$

其中, $\mathbf{a}_{k,i} = \mathbf{d}_{k,i} - \mathbf{G}_{k,i}^T \hat{\mathbf{w}}_{k,i-1}$, $\alpha_{k,i,m}$ 为矢量 $\mathbf{a}_{k,i}$ 中的第 m 个元素值,可以得到基于软门限函数^[16]的离群值估计: $\hat{o}_{k,i,m} = \max \{ |\alpha_{k,i,m}| - \gamma, 0 \} \text{sign}(\alpha_{k,i,m})$ 。

综上所述,在经过坐标下降法之后可以获得当前 i 时刻离群值估计矢量 $\hat{\mathbf{o}}_{k,i}$,进而对 $\mathbf{d}_{k,i}$ 进行偏差补偿,结合式(3)可以得到如下分布式RLS 顽健估计 (Robust d-RLS) 算法,其估计步骤为:

$$\begin{cases} \hat{o}_{k,i,m} = \max \{ |\alpha_{k,i,m}| - \gamma, 0 \} \text{sign}(\alpha_{k,i,m}) \\ \mathbf{H}_{k,i} = \frac{\lambda^{-1} \mathbf{P}_{k,i} \mathbf{G}_{k,i}}{\mathbf{R} + \lambda^{-1} \mathbf{G}_{k,i}^T \mathbf{P}_{k,i} \mathbf{G}_{k,i}} \\ \boldsymbol{\varphi}_{k,i} = \hat{\mathbf{w}}_{k,i-1} + \mathbf{H}_{k,i} (\mathbf{d}_{k,i} - \mathbf{G}_{k,i}^T \hat{\mathbf{w}}_{k,i-1} - \hat{\mathbf{o}}_{k,i}) \\ \mathbf{P}_{k,i} = \lambda^{-1} \mathbf{P}_{k,i} - \lambda^{-1} \mathbf{H}_{k,i} \mathbf{G}_{k,i}^T \mathbf{P}_{k,i} \\ \hat{\mathbf{w}}_{k,i} = \sum_{k=1}^K c_{k,i} \boldsymbol{\varphi}_{k,i} \end{cases} \quad (9)$$

上述算法的参数估计过程中,采用坐标下降法对每个时间窗内的离群值进行有效的估计,利用获得的离群值估计矢量 $\hat{\mathbf{o}}_{k,i}$ 对系统输出矢量 $\mathbf{d}_{k,i}$ 进行偏差补偿,结合传统的 d-RLS 算法,能够产生可靠的估计结果。

4 性能仿真分析

在仿真实验中,将验证所提出的 Robust d-RLS 算法的性能,并与传统 d-RLS 算法进行比较。如图2所示,采用 $N=20$ 个节点的传感器网络,随机地分布在 10×10 的区域内,并且节点之间的通信距离设置为2.5,各个节点的输入噪声方差如图3所示。设置稀疏约束参数 γ 为0.9,加权因子 λ 设置为0.1,真实的系统参数 $\mathbf{w}_0 = [0.7 \ -1.8 \ 0.6 \ -1.5 \ 0.3]^T$,矢量 $\mathbf{u}_{k,i}$ 为服从标准正态分布的随机序列。另外,初始化 $\hat{\mathbf{w}}_{k,0}$

为全1的列向量, $\mathbf{P}_{k,i} = \delta \mathbf{I}_{M \times M}$, 其中 δ 是一个很小的正常数,设置为0.0005,定义节点 k 对应的稳态均方偏差 (MSD) 为 $\text{MSD}_{k,i} = 20 \lg E \|\hat{\mathbf{w}}_{k,i} - \mathbf{w}_0\|_2^2$ (i 取算法达到稳定状态的值),并且定义网络瞬态平均 MSD 为 $\text{MSD}_i = 20 \lg \sum_{k=1}^N E \|\hat{\mathbf{w}}_{k,i} - \mathbf{w}_0\|_2^2 / N$, 以下的所有仿真结果是通过200次重复试验得到的。




图2 网络拓扑结构




图3 各个节点的输入噪声方差

在图4中,给出了传统 d-RLS 算法和 Robust d-RLS 算法的网络瞬态平均 MSD, 图5给出了两种算法在稳定状态下各个节点对应的 MSD。采用了不同的遗忘因子,并假设测量数据包含 $p=20\%$ (p 为测量数据中离群值的数量与测量数据总数的比值)的离群值,两种算法的时间窗 T 都设置为30。可以看出,在测量数据中存在离群值的情况下,

传统的 d-RLS 算法存在较大的偏差,无法实现有效的参数估计,而新提出的 Robust d-RLS 算法能够获得有效的参数估计,具有良好的顽健性能。




图4 瞬态平均 MSD 与循环时间 i 的比较

在图 6 中,分别给出了测量数据中包含不同数量离群值比例 p 和采用不同长度的时间窗 T 两种情况下, Robust d-RLS 算法在稳定状态下的估计性能。通常,包含的离群值越多,对算法估计性能的不利影响越大,从图 6 (a) 可以看出,在包含一般离群值的情况下(如包含 $p=50\%$ 的离群值), Robust d-RLS 算法仍能够保持好的估计性能。此外,时间窗 T 的长度影响离群值矢量 $\mathbf{o}_{k,i}$ 的稀疏性(见式(4)),随着 T 的增大,在离群值数量不变的情况下,矢量 $\mathbf{o}_{k,i}$ 越稀疏,相应地,在式(6)中获得的估计值 $\hat{\mathbf{o}}_{k,i}$ 也越准确,进而参数估计值 $\hat{\mathbf{w}}_{k,i}$ 也越准确,正如图 6 (b) 的实验结果。




图5 稳定状态时各个节点的 MSD 比较




图6 不同离群值和不同时间窗下的节点的稳态平均 MSD



在图 7 中, 给出了 Robust d-LMS^[17]和 Robust d-RLS 的网络瞬态平均 MSD 和稳定状态下个节点对应的 MSD, 其中将 Robust d-RLS 的稀疏约束参数 γ 设置为 0.5, 可以看出, 同时达到稳定状态下的 Robust d-RLS 算法的性能明显优于 Robust d-LMS 算法的性能, 能够获得更好的参数估计。




图 7 Robust d-RLS 和 Robust d-LMS 性能比较

5 结束语

本文以传感器网络为研究背景, 在传统的分布式 RLS 算法的基础上, 提出了一种在网络节点受到冲击噪声或脉冲干扰等情况下的分布式自适应稳健 RLS 估计算法, 该算法有效地解决了网络节点测量数据中可能存在的离群值导致估计性能严重下降的问题。算法主要基于离群值在网络测量数据中具有稀疏性的思想, 在代价函数中引入

稀疏约束项, 通过优化算法获得离群值的估计, 并对测量值进行偏差补偿, 从而实现系统模型参数的有效估计。通过一系列仿真实验比较了 Robust d-RLS 和现有算法的性能, 结果验证了提出的 Robust d-RLS 算法具有明显的顽健性。

参考文献:

- [1] 孙利民, 李建中, 陈渝, 等. 无线传感器网络[M]. 北京: 清华大学出版社, 2005.
SUN L M, LI J Z, CHEN Y, et al. Wireless sensor network[M]. Beijing: Tsinghua University Press, 2005.
- [2] MA L, WANG Z, LAM H, et al. Distributed event-based set-membership filtering for a class of nonlinear systems with sensor saturations over sensor networks[J]. IEEE Transactions on Signal Processing, 2017, 47(11): 3892-3905.
- [3] 钱萍, 吴蒙. 无线传感器网络隐私保护方法[J]. 电信科学, 2013, 29(1):23-30.
QIAN P, WU M. A privacy preserving method in WSN[J]. Telecommunications Science, 2013, 29(1):23-30.
- [4] 孟凯露, 岳克强, 尚俊娜. 基于元胞蝙蝠算法的无线传感器网络节点定位研究[J]. 电信科学, 2017, 33(11): 56-65.
MENG K L, YUE K Q, SHANG J N. Wireless sensor network nodes localization method based on cellular automata bat algorithm[J]. Telecommunications Science, 2017, 33(11): 56-65.
- [5] 盛积饶. 基于分布式递归最小二乘算法的网络稀疏信号处理研究[D]. 南京: 南京理工大学, 2016.
SHENG J R. Research on network sparse signal processing based on distributed recursive least squares algorithm[D]. Nanjing: Nanjing University of Science and Technology, 2016.
- [6] 马兰申. 自适应网络的分布式估计研究[D]. 苏州: 苏州大学, 2014.
MA L S. Research on distributed estimation of adaptive network[D]. Suzhou: Soochow University, 2014.
- [7] LIU Z T, LIU Y, LI C G. Distributed sparse recursive least-squares over networks[J]. IEEE Transactions on Signal Processing, 2014, 62(6): 1386-1395.
- [8] LIU Y, LI C, ZHANG Z. Diffusion sparse least-mean squares over networks[J]. IEEE Transactions on Signal Processing, 2012, 60(8): 4480-4485.
- [9] LORENZO P D, SAYED A H. Sparse distributed learning based on diffusion adaptation[J]. IEEE Transactions on Signal Processing, 2013, 61(6): 1419-1433.
- [10] TAKAHASHI N, YAMADA I, SAYED A H. Diffusion least-mean squares with adaptive combiners-formulation and performance analysis[J]. IEEE Transactions on Signal Processing, 2010, 58(9): 4795-4810.
- [11] LIU Z T, LI C G, LIU Y G. Distributed censored regression over

- networks[J]. IEEE Transactions on Signal Processing, 2015, 63(20): 5437-5449.
- [12] ZAYYANI H, KORKI M, MARVASTI F. A distributed 1-bit compressed sensing algorithm robust to impulsive noise[J]. IEEE Communications Letters, 2016, 20(6): 1132-1135.
- [13] CHEN P, RONG Y, NORDHOLM S, et al. Joint channel estimation and impulsive noise mitigation in underwater acoustic OFDM communication systems[J]. IEEE Transactions on Wireless Communications, 2017, 16(9): 6165-6178.
- [14] CATTIVELLI F S, LOPES C G, SAYED A H. Diffusion recursive least-squares for distributed estimation over adaptive networks[J]. IEEE Transactions on Signal Processing, 2008, 56(5): 1865-1877.
- [15] ANGELOSANTE D, BAZERQUE J A, GIANNAKIS G B. Online adaptive estimation of sparse signals: where RLS meets the ℓ_1 norm[J]. IEEE Transactions on Signals Processing, 2010, 58(7): 3436-3447.
- [16] BABADI B, KALOUPSIDIS N, TAROKH V. SPARLS: the sparse RLS algorithm[J]. IEEE Transactions on Signal Processing, 2010, 58(8): 4013-4025.
- [17] 康凯凯, 刘兆霆. 传感器网络分布式顽健自适应估计算法[J]. 传感技术学报, 2018, 31(4): 602-606.
- KANG K K, LIU Z T. Distributed robust adaptive estimation algorithm for sensor networks[J]. Chinese Journal of Sensors and Actuators, 2018, 31(4): 602-606.

[作者简介]



康凯凯 (1992-), 男, 杭州电子科技大学通信学院硕士生, 主要研究方向为分布式自适应信号处理。



刘兆霆 (1975-), 男, 博士, 杭州电子科技大学通信学院副教授、硕士生导师, 主要研究方向为统计信号处理和传感器网络。



姚英彪 (1976-), 男, 博士, 杭州电子科技大学通信学院教授、硕士生导师, 主要研究方向为媒体信号处理、无线传感器网络和固态存储。