一种基于加权多尺度分析技术的鲁棒节点定位算法

罗海勇[1,2] 李锦涛[1] 赵 方[3] 林 权[4] 朱珍民[1] 袁 武[5]

摘 要 研究了多种网络拓扑结构及稀疏网络下节点定位的鲁棒性问题. 联合考虑 1 跳邻居数目、邻居节点自身定位精度与测距误差, 引入节点相对定位误差和相对可信度概念, 提出了一种分布式基于加权多尺度分析技术的鲁棒节点定位算法. 该算法根据节点 2 跳局部网络连通度信息及邻居节点相对定位误差大小, 自适应选择综合性能好的邻居节点参与迭代优化, 并采用与节点相对可信度成正比的加权机制, 增加高可信度节点在定位计算中的贡献度. 实验数据显示, 该定位算法能够有效地抑制较大定位误差在网络内的扩散, 同基于高斯核加权的 dwMDS (G) 算法相比, 不仅迭代次数减半, 而且在网络连通度较低或拓扑不规则时, 可提高 5 % 左右的定位精度.

关键词 无线传感器网络, 定位, 分布式加权多尺度分析, 自适应邻居选择, 相对可信度
中图分类号 TP301

Robust Node Localization Based on Distributed Weighted-multidimensional Scaling in Wireless Sensor Networks

LUO Hai-Yong[1,2] LI Jin-Tao[1] ZHAO Fang[3] LIN Quan[4] ZHU Zhen-Min[1] YUAN Wu[5]

Abstract This paper focuses on the robustness of node localization in various topological and sparse network. By taking account of the number of 1-hop neighboring nodes, the node position accuracy and the ranging errors, we introduce concepts of node relative localization error and relative reliability, and then propose a robust node localization algorithm based on distributed weighted-multidimensional scaling. It adaptively chooses those neighboring nodes with high relative reliability to join in the node position refinement according to local node density and their relative localization errors within 2 hops, and adopts a weighting scheme proportional to the relative reliability which emphasizes the lowest relative error within the sensor networks. For received signal strength based range measurements, extensive simulation shows that this algorithm can prevent large localization errors from spreading through the networks. Compared with dwMDS (G), this algorithm can decrease iterative times by one half and gain about 5 % smaller localization errors in sparse node density or anisotropic topologies.

Key words Wireless sensor networks, localization, distributed weighted-multidimensional scaling, adaptive neighborhood selection, relative reliability

无线传感器网络 (Wireless sensor networks, WSN) 是由成千上万个采用电池供电的微型传感器节点 (Sensor nodes, 简称节点), 通过短距离无线通信方式互联构成的大规模网络[1]. 随着传感器、微机电系统和无线通信技术的飞速发展, WSN 正逐渐变为现实. WSN 可广泛应用于工农业生产、环境监测、空间探索、军事侦察和医疗保健等领域. 在 WSN 的诸多应用中, 不知道传感器位置而感知的数据是没有意义的[2]. 例如, 在环境监测应用中, 为详细报告特定事件发生的位置或区域信息, 节点需要预知自身的位置信息; 在库存管理、制造业物流和安全监控等应用中, 需要实现目标的定位和跟踪; 此外, 节点位置信息可用于提高路由效率[3−4]、实现网络拓扑自配置[5]、均衡网络负载[6−7] 及改善网络覆盖质量[8−9] 等.

受成本及能量限制, 为所有节点安装全球定位系统 (Global positioning system, GPS) 接收器或精确测距设备并不现实, 而且在室内/地下等应用中, GPS 信号受阻, 无法实现有效定位. 目前美国有意降低民用 GPS 信号精度 (在 95 % 的可信区间内定位误差为 ± 6.3 米)[10], 使得 GPS 难以满足细粒度定位应用需求. 此外, 大规模部署或危险环境下, 采

收稿日期 2007-05-09 收修改稿日期 2007-09-04
Received May 9, 2007; in revised form September 4, 2007
国家高科技研究发展计划 (863 计划) (2006AA10Z253, 2006AA01Z223, 2007AA12Z321) 资助
Supported by National High Technology Research and Development Program of China (863 Program) (2006AA10Z253, 2006AA01Z223, 2007AA12Z321)
1. 中国科学院计算技术研究所普适计算研究中心 北京 100080 2. 中国科学院研究生院 北京 100080 3. 北京邮电大学 北京 100876 4. 北京航空航天大学 北京 100083 5. 北京理工大学 北京 100081
1. Research Center of Pervasive Computing, Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100080 2. Graduate University of Chinese Academy of Sciences, Beijing 100080 3. Beijing University of Posts and Telecommunications, Beijing 100876 4. Beijing University of Aeronautics and Astronautics, Beijing 100083 5. Beijing Institute of Technology, Beijing 100081
DOI: 10.3724/SP.J.1004.2008.00288

用人工部署或为所有节点输入位置信息也是不可行的. 因此有必要研究适合无线传感器网络的节点自定位技术.

1　相关研究

目前 WSN 节点自定位技术研究有了较大进展[11], 出现了质心算法[12], Amorphous[13], APIT[14] 和 APS[15−16] 等定位算法. 这些算法或利用网络节点间的连通性信息, 或利用未知节点与信标节点间的距离/角度估计信息进行节点定位, 但均存在定位精度相对较低, 算法鲁棒性较差等不足.

近年来, 多尺度分析技术 (Multidimensional scaling, MDS)[17] 开始应用于无线传感器网络节点定位. 这类算法利用整个网络或网络局部所有节点间 (包括未知节点间) 的连通性或测距估计信息, 即使用更多的约束性条件进行优化求解. 同前面介绍的定位算法相比, 可获得更准确的网络拓扑结构, 尤其适合信标节点数目较少情况下的节点定位. 这类算法主要有 MDS-MAP[18]、Local MDS[19]、MDS-MAP (P/R)[20] 和 dwMDS (G)[21] 等.

MDS-MAP 算法是典型基于 MDS 技术的集中式定位算法, 可运行于无需测距模式和测距模式. 在网络密度均匀时, 定位性能较好. 但网络拓扑不规则时, 由于最短路径长度与节点间欧氏距离相差较大, 导致算法定位误差显著增加. 此外 MDS-MAP 算法所采用的集中计算方式不适合大规模网络部署, 扩展性较差.

针对 MDS-MAP 算法的上述不足, 人们陆续提出了分布式 MDS 定位算法[19−21], 这些算法均使用未知节点局部网络范围 (一般小于 2 个跳段) 测距信息, 避免使用误差较大、相距较远节点间的测距信息 (即最短路径), 可获得比 MDS-MAP 算法更好的定位精度. 其中 Local MDS 使用 SMACOF 算法, 对未知节点 1 跳网络测距矩阵进行优化求解, 获得每个节点局部范围所有节点坐标估计. 该算法仅使用 0 和 1 两个加权值, 把同一跳段内邻居节点等同看待; MDS-MAP(P/R) 算法对节点可使用的局部信息范围进行扩展 (跳段数可选 1 跳或多跳), 并使用加权最小二乘法对局部坐标进行优化, 同一跳段内所有测距使用相同加权值, 所有测距参与优化计算, 当选择多跳邻居时, 运算量较大[22]. Local MDS 算法和 MDS-MAP (P/R) 算法让所有选择的邻居参与定位, 没有对较大测距误差 (即粗差) 进行抑制, 存在抗差性较弱的缺点; dwMDS (G) 对 Local MDS 及 MDS-MAP (P/R) 算法的加权机制进行改进, 采用与测距大小相关的高斯核加权机制, 通过赋予距离未知节点较近的节点更大权值, 增加其定位贡献量, 并采用自适应 2 步邻居选择机制减小测距粗差对邻居选择的负偏效应, 具有一定的抗差性能. 不过该算法仅选择 1 跳邻居节点进行定位计算, 要求网络节点密度大且拓扑规则.

总之, 上述分布式 MDS 定位算法要求选择范围内的所有节点, 不论其定位误差大小, 在迭代优化过程中均参与节点定位计算, 这使得在网络连通度较大时, 计算和通信的开销过大. 此外这些算法采用与测距相关的加权方法, 因此会受到测距误差及几何拓扑结构等因素的影响. 由于距离未知节点近的节点, 其定位误差有可能会更大, 如果距离未知节点越近就赋予越大的权值, 则很容易造成距离较近的较大定位误差在网络内扩散. 在网络稀疏、密度分布不均匀或拓扑不规则时, 该扩散效应表现得更为突出, 这将导致定位精度明显下降.

针对上述算法不能适应网络连通度变化、网络拓扑不规则的不足, 本文在综合考虑 1 跳邻居数目、节点自身定位精度与测距误差的基础上, 引入节点相对定位误差和相对可信度概念, 使用自适应邻居选择机制及基于相对可信度的加权方法, 提出了一种分布式基于加权多尺度分析技术的鲁棒节点定位算法[23].

本文主要贡献是提出了一种基于节点 2 跳局部网络连通度信息和节点相对误差的自适应邻居选择机制, 以及一种基于节点定位相对可信度的加权方法. 该自适应邻居选择机制综合考虑了节点定位误差大小及距离未知节点远近等因素, 依据未知节点局部网络节点密度及相对误差大小, 自适应选择相对误差小于规定阈值的节点参与迭代优化计算, 剔除相对误差高于阈值的节点, 抑制较大定位误差在网络内的扩散, 让综合性能好的节点对未知节点定位发挥作用. 该算法还采用与节点定位可信度成正比的加权机制, 对未知节点精选邻居集中相对误差值较小的节点赋予较大的权值, 增加它在定位计算中的贡献度, 进一步提高了算法定位精度及算法收敛性.

2　基于加权多尺度分析技术的鲁棒节点定位算法

为便于描述, 本文假设网络内有 $N = n + m$ 个节点, 其中标号 $1 \sim n$ 的节点是未知节点, 标号 $(n+1) \sim (n+m)$ 的节点是具有先验位置信息的信标节点, N 个节点对应的坐标向量为 $\boldsymbol{X} = [x_1, x_2, \cdots, x_{n+m}]^{\mathrm{T}}$. 这里 $x_i = [x_{i1} \ \cdots \ x_{ik}]$, $k = 2$ 或 3 (分别对应 2 维或 3 维空间). $\hat{d}_{ij}$ 是节点 i 和 j 间的测距. 若节点 i 和 j 是 1 跳邻居时, $\hat{d}_{ij}$ 直接用两节点间测距表示; 若节点 i 和 j 非 1 跳邻居, 则 $\hat{d}_{ij}$ 使用节点

i 和 j 间的最短路径. d_{ij} 为使用节点 i 和 j 的估计坐标 (对于未知节点) 或先验坐标 (对于信标节点) 计算的欧氏距离, 定义如式 (1) 所示.

$$d_{ij}(\boldsymbol{X}) = \sqrt{\sum_{a=1}^{k}(x_{ia} - x_{ja})^2} \tag{1}$$

基于加权多尺度分析技术的鲁棒节点定位算法 (Distributed weighted-multidimensional scaling based on relative error, dwMDS (E)) 采用 SMACOF 算法, 对式 (2) 所示局部代价函数进行最小化优化求解[21], 实现节点定位. SMACOF 二次优化方法可保证每次迭代均能降低代价函数值, 且每次迭代有显式表达式, 计算效率高. 局部代价函数 S_i 中选择对距离差 $\left|\hat{d}_{ij} - d_{ij}\right|$ 平方加权求和, 而不选择对 $\left|\hat{d}_{ij}^2 - d_{ij}^2\right|$ 平方加权求和优化, 可消除经典 MDS 的误差放大效应.

$$\begin{aligned} S_i = &\sum_{j=1,j\neq i}^{n} \omega_{ij}(\hat{d}_{ij}(\boldsymbol{X}) - d_{ij}(\boldsymbol{X}))^2 + \\ &\sum_{j=n+1}^{n+m} 2\omega_{ij}(\hat{d}_{ij}(\boldsymbol{X}) - d_{ij}(\boldsymbol{X}))^2 \end{aligned} \tag{2}$$

式中 ω_{ij} 为加权值, 当节点 i 和 j 之间无距离测量值时, $\omega_{ij} = 0$. 本文假设 $\omega_{ij} \geq 0$, $\omega_{ii} = 0$, $\omega_{ij} = \omega_{ji}$. 欧氏距离 $d_{ij}(\boldsymbol{X})$ 由式 (1) 确定.

采用循环求解方法对式 (2) 进行最小优化, 即 x_i 坐标的第 $(k+1)$ 次迭代结果为

$$x_i^{(k+1)} = a_i \boldsymbol{X}^{(k)} \boldsymbol{b}_i^{(k)} \tag{3}$$

其中

$$a_i^{-1} = \sum_{j=1,j\neq i}^{n} \omega_{ij} + \sum_{j=n+1}^{n+m} 2\omega_{ij} \tag{4}$$

$\boldsymbol{b}_i^{(k)} = [b_1, \cdots, b_{n+m}]^{\mathrm{T}}$ 为向量, 对应分量为

$$\begin{cases} b_j = \omega_{ij}\left[1 - \hat{d}_{ij}/d_{ij}(\boldsymbol{X}^{(k)})\right], & j \leq n,\ j \neq i; \\ b_i = \displaystyle\sum_{j=1,j\neq i}^{n} \omega_{ij}\hat{d}_{ij}/d_{ij}(\boldsymbol{X}^{(k)}) + \\ \qquad \displaystyle\sum_{j=n+1}^{n+m} 2\omega_{ij}\hat{d}_{ij}/d_{ij}(\boldsymbol{X}^{(k)}); \\ b_j = 2\omega_{ij}\left[1 - \hat{d}_{ij}/d_{ij}(\boldsymbol{X}^{(k)})\right], & j > n \end{cases} \tag{5}$$

dwMDS (E) 算法步骤如下: 1) 每个节点使用 ABC[24] 或经典 MDS (SVD)[18] 算法建立初始局部坐标系; 2) 采用第 2.1 节中介绍的增量贪婪算法, 对所有局部坐标系进行融合, 生成全局相对坐标; 3) 利用网络信标节点, 把全局相对坐标变换为初始全局绝对坐标; 4) 根据网络局部属性, 采用基于相对误差 (见第 2.2.1 节介绍) 的自适应邻居选择机制, 选择最终参与局部代价函数优化的精选邻居集; 5) 采用基于相对可信度的加权机制 (见第 2.2.2 节介绍), 对节点初始绝对坐标进行迭代求解, 获得优化后的全局绝对坐标. dwMDS (E) 算法伪代码如表 1 所示.

表 1 dwMDS (E) 算法伪代码

Table 1 Pseudocode of dwMDS (E)

dwMDS (E) 算法

inputs: $\{\hat{d}_{ij}\}$, m, ε;
build local map with ABC or MDS (SVD);
patch local maps into a global relative map;
transform the relative map into an absolute map to get the initial coordinates $\boldsymbol{X}^{(0)}$;
initialize: $k = 0$, $S^{(0)}$, compute a_i from (4);
repeat
  $k \leftarrow k + 1$;
  for $i = 1$ to n
    compute relative error;
    adaptive neighborhood selection;
    compute ω_{ij} from (10);
    compute $b_i^{(k-1)}$ from (5);
    compute x_i^k from (3);
    compute $S_i^{(k)}$;
    $S^{(k)} \leftarrow S^{(k)} - S_i^{(k-1)} + S_i^{(k)}$;
    send $X_i^{(k)}$ to neighbors (for $\omega_{ij} > 0$);
    send $S^{(k)}$ to node $(i+1) (\mathrm{mod}\ n)$;
  end for;
until $S^{(k-1)} - S^{(k)} < \varepsilon$.

2.1 初始全局坐标系构建

初始全局坐标系一般采用随机赋值、基于三边的位置估计和经典 MDS 等方法获得. 由于随机初始坐标往往导致基于梯度搜索的优化迭代算法陷入局部最优, 因此一般不采用.

当未知节点构建好局部坐标系后, 可采取串行或并行顺序对局部地图进行融合, 建立全局坐标系. 本文采用增量贪婪地图融合算法, 该算法首先随机挑选 1 个节点, 把它的局部地图作为核心地图, 然后每次选择与核心地图拥有最多共同节点的邻居地图依次融合, 直到核心地图覆盖整个网络为止.

两个局部地图融合的变换矩阵使用最佳线性变换方法, 即使用最小二乘法最小化两个地图中相同节点的坐标变换误差, 获得变换矩阵, 把其中一个地图变换到另一个地图上, 该变换包括平移、旋转、镜像及缩放. 鉴于局部地图并非刚体, 采用最佳线性变换方法, 具有良好的鲁棒性, 可有效减少地图融合过程中的误差累积效应.

为测试 dwMDS (E) 算法的鲁棒性, 本文实现了基于 ABC 和 MDS (SVD)(P) 初始坐标系构建算法. 一般情况下, 使用 ABC 算法构建的初始全局坐标系精度比 MDS (SVD)(P) 算法构建的全局坐标系精度低. 它们均先建立节点局部坐标系, 然后采用增量贪婪算法进行地图融合, 构建全局坐标系.

2.2　自适应邻居选择及加权机制

2.2.1　自适应邻居选择

dwMDS (G) 采用 2 步邻居选择机制, 它首先使用 1 跳邻居测距计算未知节点坐标, 然后判断欧氏距离是否大于 1 跳邻居距离阈值, 确定节点 i 和 j 是否为真正的 1 跳邻居. 该机制可消除噪声测距环境下 RSSI 测距模型的距离低估效应, 让未知节点挑选出真正 1 跳范围内的邻居节点集进行定位求精. 但该算法要求网络平均连通度较大, 由于在网络稀疏或网络密度不均时, 部分节点 1 跳邻居可能较少, 2 步邻居选择法会减少参与定位的邻居节点数目, 导致定位误差增加, 有时甚至不能实现定位.

本文提出的基于节点定位相对误差的自适应邻居选择机制, 综合考虑未知节点局部网络范围内的节点密度变化、节点定位精度及距离未知节点远近等因素, 依据直接邻居数目多少自适应决定是否引入 2 跳邻居, 并计算所选跳段范围内节点的相对误差, 判断它是否小于相对误差阈值, 从而决定是否最终参与未知节点的定位计算. 该自适应邻居选择机制通过选择精度较高的邻居参与定位运算, 既可减小较大定位误差在网络内的扩散, 提高定位算法的鲁棒性, 同时又可避免选择过多节点参与节点定位计算, 减少计算和通信开销, 提高定位算法的收敛速度.

相对定位误差定义方法为:

1) 在每一次迭代前, 按式 (6) 计算每个节点的定位误差

$$ResAverage(i)=\sum_{j=1}^{M}\left|d_{ij}-\hat{d}_{ij}\right|/M \tag{6}$$

其中 M 为上次迭代计算中, 节点 i 所选择参与优化计算的精选邻居数, 节点 i 和 j 间的欧氏距离 d_{ij} 由式 (1) 确定, $\hat{d}_{ij}$ 为节点 i 和 j 间的测距或最短路径长度.

2) 使用式 (7) 计算节点单位长度的归一化定位误差

$$Norm(i)=\{\sum_{j=1}^{M}\left|d_{ij}-\hat{d}_{ij}\right|\}/\{\sum_{i=1}^{M}\hat{d}_{ij}\} \tag{7}$$

3) 综合考虑节点 j 自身定位误差和到节点 i 的距离, 可得到节点 j 相对节点 i 的相对定位误差

$$TotalRes_i(j)=ResAverage(j)+Norm(i)\times\hat{d}_{ij} \tag{8}$$

式 (8) 中右端第 1 部分 ($ResAverage(j)$) 为节点 j 自身定位误差, 第 2 部分 ($Norm(i)\times\hat{d}_{ij}$) 为节点 j 与节点 i 的测距 $\hat{d}_{ij}$ 所引入的测距误差.

自适应邻居选择步骤如下:

1) 未知节点判断自己 1 跳邻居数是否小于 9, 如果小于 9, 则选择 2 跳邻居; 如果大于 9, 则仅选择 1 跳邻居;

2) 计算初选邻居相对误差, 并按升序排列. 对于 2 跳邻居使用最短路径估计作为到未知节点距离;

3) 计算未知节点与初选邻居测距的标准差 σ;

4) 把按升序排列的相对误差表中第 3 个节点的相对误差加上 2.5σ 作为相对误差阈值 ($TotalRes_{thr}$), 剔除初选邻居表中相对误差大于 $TotalRes_{thr}$ 的节点, 仅使用表中剩余可信度较高的邻居节点 (本文称为精选邻居节点) 进行迭代求精.

这里自适应邻居选择步骤中参数 9 和 2.5σ 的选择由仿真实验得到. 参数 9 同时考虑了定位精度对多约束性条件数目的要求和节点自身计算资源受限等因素; 2.5σ 强化了邻居选择条件, 既保证了一定规模的精选邻居数目, 又减少了算法计算复杂度. 实际应用中可根据定位精度要求及节点计算能力进行相应调整. 本文算法仿真均选用这两个参数值.

2.2.2　权值函数定义

受测距误差及不规则网络拓扑结构的影响, 距离未知节点近的节点, 相对定位误差不一定小, 需综合考虑邻居节点的测距误差和定位误差信息, 让综合性能好的节点对未知节点的定位发挥更大作用, 由此本文提出了基于节点相对可信度 (Relative reliability, RR) 的加权机制. 节点 j 相对节点 i 的相对可信度定义如式 (9) 所示

$$RR_{(i)}(j)=[TotalRes_{(i)}(j)]^{-1}=[ResAverage(j)+Norm(i)\times\hat{d}_{ij}]^{-1} \tag{9}$$

该定义规定节点定位的相对可信度与节点的相对误差成反比, 相对误差越小, 节点定位的相对可信度越高.

对相对可信度进行归一化处理, 即可得到权值函数定义, 如式 (10) 所示

$$\omega_{ij} = \frac{RR_{(i)}(j)}{\sum_{j=1}^{M} RR_{(i)}(j)} \tag{10}$$

该加权函数采用与节点相对可信度成正比的加权机制, 增加相对可信度高的邻居节点在局部代价函数中的贡献量, 提高定位算法精度和算法收敛速度, 详细介绍参见本文第 3 节和第 4 节的内容.

3 算法性能分析

3.1 测距模型

由于无线信道衰落等原因, RSSI 值 (P_{ij}) 服从对数正态分布[25], 如式 (11) 所示

$$\begin{cases} P_{ij} \sim N(\overline{P}_{ij}, \sigma_{dB}^2) \\ \overline{P}_{ij} = P_0 - 10 n_p \lg(d_{ij}/d_0) \end{cases} \tag{11}$$

其中 P_{ij}(dBm) 为节点 j 发射、节点 i 接收的信号功率, P_0(dBm) 为自由空间条件下参考接收点接收的信号强度, d_0 为信标节点到参考接收点的距离, n_p 为无线传输衰减系数, 与环境相关, $\overline{P}_{ij}$(dBm) 为距离 d_{ij} 处的均值接收功率, σ_{dB}^2 为阴影方差.

由式 (11) 可得基于极大似然估计的测距估计 $\hat{d}_{ij}$, 如式 (12) 所示

$$\hat{d}_{ij} = \begin{cases} d_0 \times [10^{(P_0 - P_{ij})/(10 n_p)}], & \hat{d}_{ij} \le d_R \\ \emptyset, & \hat{d}_{ij} > d_R \end{cases} \tag{12}$$

本文采用该 RSSI 测距模型, 由接收信号功率获得节点距离估计, 其中 $\sigma_{dB}/n_p = 1.7$.

3.2 算法收敛性

节点迭代定位过程中, 算法收敛速度对节点通信开销和能耗有较大影响. 考虑到迭代定位算法难以直接获取算法收敛性的显式表达式, 本文采用软件仿真方式进行评估. 图 1 所示仿真验证了如下结论: 剔除定位误差较大的邻居节点, 而选择那些定位相对可信度高的节点参与局部代价函数优化, 可加快代价函数的收敛速度. 该仿真实验条件: 方形均匀随机部署, 网络平均连通度 12, 测距误差 15 %, 使用 ABC 算法建立初始坐标. 作为对比, 实现了 dwMDS (G) 算法. 设无线通信半径为 d, 相同迭代次数下, dwMDS (E) 算法定位精度不仅相对 dwMDS (G) 平均约有 2% d 的优势, 而且其收敛速度更快, 仅经过几次 (≤ 4) 迭代, 算法定位精度改进趋向稳定. dwMDS (E) 只需一半的迭代次数就可获得 dwMDS (G) 算法相同的定位精度. dwMDS (E) 算法较快的收敛速度有助于减少节点的通信、计算开销和定位能耗. 实际应用中, 可在精度与能耗间进行折衷, 通过设置合适的代价函数改进阈值来间接控制算法的迭代次数.

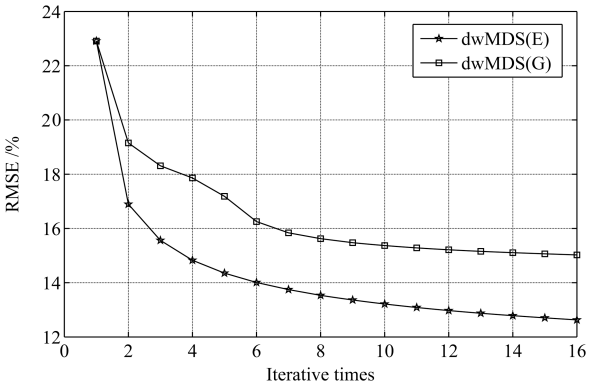


图 1. dwMDS (G/E) 算法收敛性

Fig. 1 Convergence speed of dwMDS (G/E)

3.3 测距误差对算法性能的影响

测距误差是算法定位精度下降的主要原因, 良好的定位鲁棒性要求算法能够自动消除较大测距误差对定位精度的消极影响. dwMDS (E) 算法依据定位精度对参与优化计算的邻居节点进行筛选, 剔除相对定位误差较大的邻居节点, 抑制其误差扩散, 而选择那些相对可信度高的邻居节点, 并赋予更大权值, 有效提高了定位算法鲁棒性, 图 2 所示实验证实了这一结论. 该实验主要测试不同测距误差条件下, dwMDS (E) 算法的定位精度 (RMSE)、标准差与定位覆盖度变化. 由图可见, 随着测距误差的增加, 定位误差和标准差缓慢增加, 当测距误差高达 50 % 时, 平均定位误差在 30 % 左右, 表现出良好的抗差性能. dwMDS (E) 算法定位覆盖度取决于初始坐标



图 2 dwMDS (E) 定位误差、定位覆盖度与测距误差间的关系

Fig. 2 RMSE and localization coverage rate of dwMDS (E) with different ranging errors

的建立, 随着测距误差的增大, 覆盖度仅轻微减少, 均在 95 % 以上, 表现出较好的定位覆盖性能. 仿真条件与图 1 所示算法收敛性实验条件相同.

3.4　算法计算复杂度和通信能量消耗

算法计算复杂度同样采用软件仿真方式进行评估, 如表 2 所示. 表 2 中比较了 dwMDS (G/E) 定位算法在不同网络规模下的仿真计算时间. 由表 2 可见, 随着网络规模的增大, 全局初始坐标建立时间和算法迭代时间呈非线性增长, 平均处理每个节点的时间也相应增加, 当网络节点规模大于 100 时, dwMDS (E) 算法平均仿真计算时间比 dwMDS (G) 算法至少小 50 %. 仿真条件: PC (Pentium D CPU 2.8 GHz, 1 GB), 测距误差为 5 %, 网络平均连通度 9, 节点网格部署.

同计算开销相比, WSN 节点无线通信所消耗的能量占主导地位. 本文采用式 (13)[26] 所示的通信能耗模型

$$\varepsilon(n) = b(n) \times h(n) \times e(n) \tag{13}$$

其中 $b(n)$ 为需要传输的平均比特数, $h(n)$ 为通信平均跳段数, $e(n)$ 为一个跳段内发送 1 比特数据所需能耗.

网络均匀部署情况下, 节点的平均邻居数为 $\mathrm{O}\left(cnd_{thr}^{K}\right)$ (其中 c 为与网络部署面积相关的常数, n 为网络节点数, d_{thr} 为节点通信半径, K 为 2 或 3, 分别对应 2 维或 3 维空间). 由于 dwMDS (E) 算法要求每轮每个节点完成坐标估计迭代计算后, 需要把更新的坐标估计发送给其他节点, 因此平均发送的比特数为 $\mathrm{O}\left(n^2 L d_{thr}^{K}\right)$ (其中 L 为算法迭代次数). 而每次与邻居间的通信为 1 个跳段, 即 $h(n) = 1$. 故 dwMDS (E) 算法的通信能量消耗为

$$\varepsilon_{dwMDS\,(E)}(n) \sim \mathrm{O}\left(n^2 L d_{thr}^{K} e_{dwMDS\,(E)}(n)\right) \tag{14}$$

其中 $e_{dwMDS\,(E)}(n)$ 与 d_{thr} 相关.

4　实验

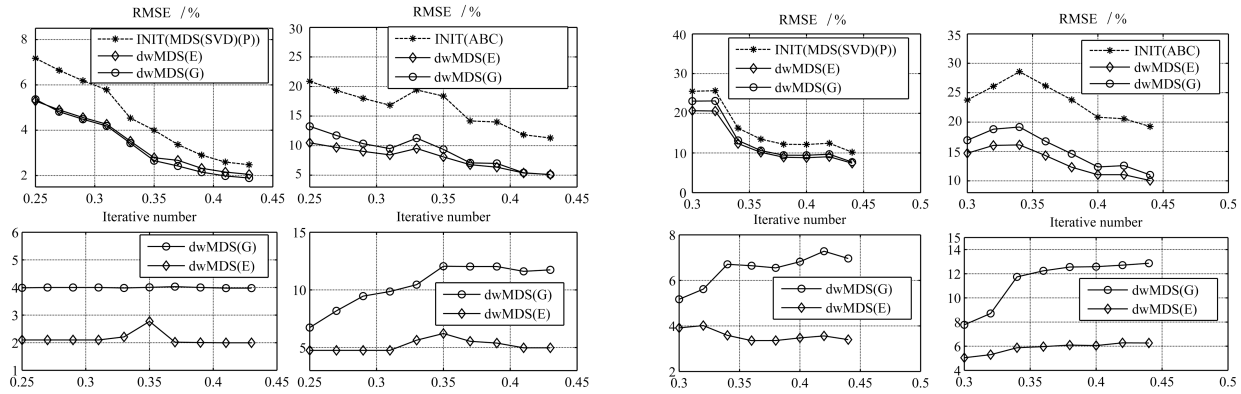
4.1　基于测距模型的仿真实验

本文在 $[0,1] \times [0,1]$ 单位区域进行了 4 种网络拓扑仿真实验: 网格、C 型网格、随机均匀和 C 型随机均匀. 其中 C 型拓扑结构用于仿真测试各向异性网络拓扑下定位性能. 为测试算法在不同初始坐标精度下的定位性能, 实验使用了 ABC 和 MDS (SVD)(P) 两种全局初始坐标系构建方法. 作为对比, 实现了 dwMDS (G) 定位算法.

表 2　网格部署条件下定位算法运行时间比较 (单位: 秒)

Table 2　Typical running time comparison of localiztion algorithms in gird placement (unit: s)

节点数目	初始坐标构建算法	构建初始全局坐标时间	求精算法	算法迭代求精时间	总运行时间	平均每个节点运行时间
50	MDS	1.1	dwMDS (E)	0.6	1.7	0.03
			dwMDS (G)	0.8	1.9	0.04
	ABC	0.8	dwMDS (E)	0.9	1.7	0.03
			dwMDS (G)	1.1	1.9	0.04
100	MDS	3.7	dwMDS (E)	3.8	7.5	0.08
			dwMDS (G)	6.9	10.6	0.11
	ABC	3.0	dwMDS (E)	4.8	7.8	0.08
			dwMDS (G)	8.2	11.2	0.11
200	MDS	20.7	dwMDS (E)	30.6	51.3	0.26
			dwMDS (G)	60.6	81.3	0.41
	ABC	19.3	dwMDS (E)	36.3	55.6	0.29
			dwMDS (G)	69.8	89.1	0.45
300	MDS	65.6	dwMDS (E)	110.9	176.5	0.59
			dwMDS (G)	219.5	285.1	0.95
	ABC	63.3	dwMDS (E)	120.6	183.9	0.61
			dwMDS (G)	231.3	294.6	0.98



(a) 方形网格 (Square grid) (b) C 形网格 (C-shaped grid)

图 3 网格部署 dwMDS (G/E) 定位误差及迭代次数

Fig. 3 RMSE and iterative times of dwMDS (G/E) in different grid deployments

4.1.1 网格部署

网格部署环境下, 针对不同网络连通度 (对应不同的无线通信半径 d) 进行 200 次 Monte Carlo 实验, 计算所有未知节点平均定位误差 RMSE 和算法平均迭代次数. 假设测距误差为 5 %.

方形网格部署条件 (49 个节点, 7×7) 的算法性能如图 3(a) 所示. 当网络平均连通度较低时 (连通度 ≤ 11, 对应 $d\leq 0.35$), 采用 ABC 算法构建初始全局坐标定位误差较大 (约 20% d), 使用 dwMDS (E) 算法的定位性能明显优于 dwMDS (G), 在迭代次数减少近 1/2 情况下, dwMDS (E) 算法的 RMSE 改善约 5% d. 当采用 MDS (SVD)(P) 算法建立初始坐标系时, 不同网络连通度下, dwMDS (E) 与 dwMDS (G) 算法的定位精度相当, 但 dwMDS (E) 算法的迭代次数更少. 实验结果表明, 在方形网格拓扑下, 相同定位算法使用 MDS (SVD)(P) 建立的初始坐标系进行优化, 比使用 ABC 算法建立的初始坐标系进行优化获得的定位精度更高, 可见初始坐标精度对定位算法的定位性能有明显影响, ABC 算法建立的初始全局坐标误差较大, 导致迭代优化算法陷于局部最优, 定位误差相对较大.

图 3(b) 比较了 C 形网格拓扑下 dwMDS (E) 和 dwMDS (G) 算法的定位性能及算法收敛性. 当连通度 ≤ 11 (对应 $d\leq 0.35$) 时, 采用 MDS (SVD)(P) 初始坐标构建方式, dwMDS (E) 的 RMSE 平均比 dwMDS (G) 的值小 2% d, 且迭代次数减半; 当网络连通度增加到 11 后, dwMDS (E) 和 dwMDS (G) 的定位精度相当, 而迭代次数仍平均减少一半. 采用 ABC 算法构建初始坐标系时, dwMDS (E) 算法的定位精度和算法收敛性均优于 dwMDS (G). 当网络平均连通度小于 11 (对应 $d<0.35$) 时, dwMDS (E) 和 dwMDS (G) 算法在 ABC 初值的定位误差比使用 MDS (SVD)(P) 初值的定位误差小 (约 5% d), 验证了网络密度较小且网络各向异性时, MDS-MAP 算法定位性能较差的结论.

4.1.2 随机部署

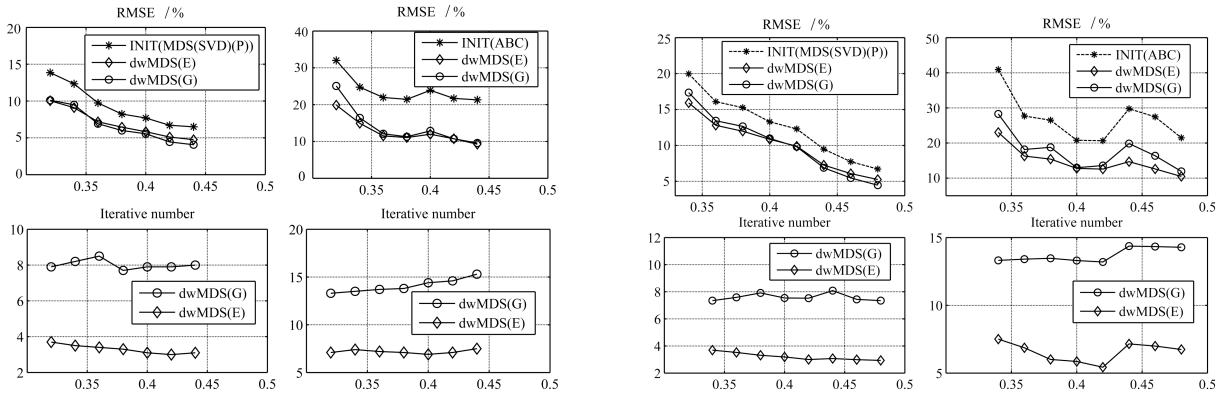
随机均匀部署仿真条件与网格部署类似, 不过测距误差为 10 %. 方形均匀随机部署情况 (共 49 个节点) 如图 4(a) (见下页) 所示, 当网络平均连通度较低时 (连通度 $\leq$ 11, 对应 $d\leq 0.35$), 采用 ABC 算法构建初始全局坐标后, dwMDS (E) 算法的 RMSE 值比 dwMDS (G) 小 5% d, 且迭代次数减少近 1/2. 当采用 MDS (SVD)(P) 算法建立初始坐标系时, 不同网络连通度下, dwMDS (E) 算法定位精度与 dwMDS (G) 算法相当, 但迭代次数明显少于 dwMDS (G) 算法.

图 4(b) 显示了 C 形各向异性网络随机部署情况, 不同 d 值的平均定位误差及算法收敛速度, 其结论与 C 形网格类似. 使用 ABC 算法构建初始全局坐标条件下, 不同 d 值的 dwMDS (E) 算法 RMSE 值比 dwMDS (G) 平均小 5% d 左右, 迭代次数减少近 1/2.

随机部署情况下, 无论均匀方形随机部署, 还是 C 形各向异性随机部署, 使用相同定位算法, 基于 MDS (SVD)(P) 初始坐标比基于 ABC 初始坐标可获得更高的定位精度.

4.2 基于实际测量数据集的算法性能

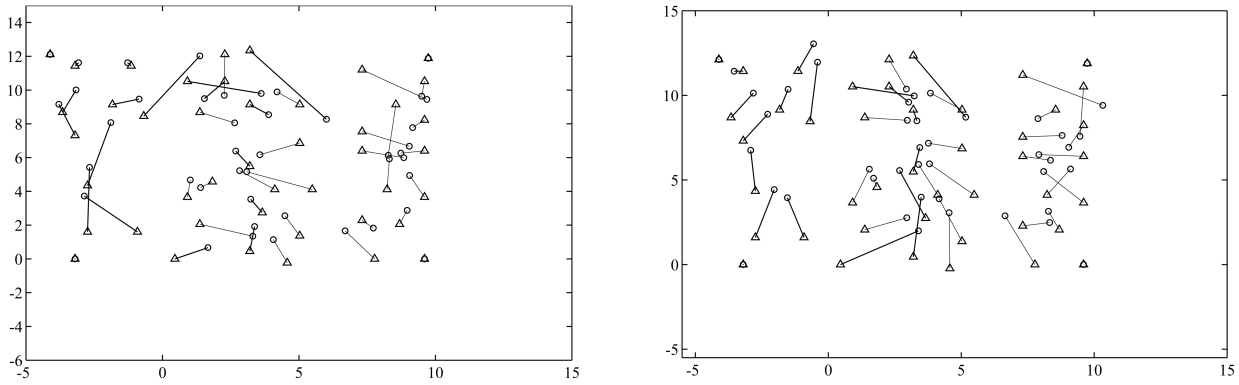
本文利用 Neal Patwari 提供的实际测量数据集[27], 对 dwMDS (E) 算法在实际环境下定位性能进行了评测. 实验共有 44 个节点 (其中包括 4 个信标节点), 部署在 12 m $\times$ 14 m 长方形区域, 使用 RSSI 测距方法. 节点间利用宽带直接序列扩频通信方式, 中心频率为 2.4 GHz. 每个 RSSI 值共进行 10 次测量, 其中每个节点各收发 5 次, 使用最大似然估计获得节点间距离估计值[28].



(a) 方形均匀随机 (Square random)　　(b) C 形均匀随机 (C-shaped random)

图 4　随机部署 dwMDS (G/E) 定位误差及迭代次数

Fig. 4　RMSE and iterative times of dwMDS (G/E) in random deployments



(a) dwMDS (E)　　(b) dwMDS (G)

图 5　基于实际 RSSI 测距数据的定位性能
("△" 为实际位置, "○" 为节点估计位置)

Fig. 5　Location estimates using RSSI range measurements from experimental sensor network
(True and estimated sensor locations are marked, respectively, by "△" and "○".)

利用上述数据集, 本文比较了 dwMDS (G/E) 算法定位性能. 使用 MDS (SVD)(P) 算法构建初始坐标系, 分别使用 dwMDS (E) 和 dwMDS (G) 算法进行迭代求精, 定位结果如表 3 所示. 由表 3 可见, dwMDS (E) 算法定位精度在不同无线通信半径下均高于 dwMDS (G) 算法精度, 且迭代次数约为 dwMDS (G) 算法的 1/2 左右.

使用 dwMDS (G/E) 两种定位算法优化后节点位置估计和实际位置间偏差如图 5 所示. 图中 "△" 表示节点实际位置, "○" 表示节点估计位置, 两者间连线表示估计误差, 实验条件为 $d = 8.5\,\mathrm{m}$. 图 5(a) 为 dwMDS (E) 定位结果, RMSE 为 1.8526 m; 图 5(b) 为 dwMDS (G) 优化定位结果, RMSE 为 2.0382 m. 由此可见, dwMDS (E) 算法相对于 dwMDS (G) 算法有近 10 % 的性能提升.

表 3　基于实际 RSSI 测量数据的 dwMDS (G/E) 算法性能比较

Table 3　RMSE and iterative times comparison of dwMDS (G/E) with actual RSSI-based ranging

无线通信半径 (m)	dwMDS (G) 定位误差	迭代次数	dwMDS (E) 定位误差	迭代次数
6.5	2.5325	15	2.2235	5
7	2.3366	14	2.1502	6
8	2.2287	13	2.0610	5

5　结论

本文综合考虑参与定位的节点定位精度及距离待定位节点的远近, 根据未知节点局部密度信息和节点相对误差大小, 自适应选择定位可信度高的邻居节点参与迭代优化, 同时抑制可信度较低节点定

位误差在网络内的扩散效应, 通过采用与相对可信度成正比的权值选择机制, 增加可信度较高节点在节点定位计算中的贡献度. 仿真与物理实验数据显示, 与单纯基于跳段数或测距的邻居选择和加权机制相比, 基于自适应邻居选择和相对可信度加权的分布式多尺度分析定位算法具有更高的定位精度、更快的收敛速度和更好的鲁棒性, 在初始全局坐标精度较差、各向异性网络拓扑或网络平均连通度较低等情况下, 该优势表现得尤为突出.

dwMDS (E) 算法不仅适用于 RSSI 测距模型, 同样适用于 TOA 等测距模型的节点定位.

References

1 Ganesan D, Krishnamachari B, Woo A, Culler D, Estrin D, Wicker S. An Empirical Study of Epidemic Algorithms in Large Scale Multihop Wireless Networks. Technical Report IRB-TR-02-003, Intel Research Labs, USA, 2002

2 Rabacy J J, Ammer M J, da Silva J J L, Patel D, Roundy S. Picorodio supports ad hoc ultra-low power wireless networking. *Computer*, 2000, **33**(7): 42−48

3 Blazevic L, Giordano S, Le Boudec J Y. Self-organizing wide-area routing. In: Proceedings of the 4th World Multiconference on Systemics, Cybernetics and Informatics and the 6th International Conference on Information Systems, Analysis and Synthesis. Florida, USA: SCI, 2000

4 Ko Y B, Vaidya N H. Location-aided routing (LAR) in mobile ad hoc networks. In: Proceedings of the 4th Annual ACM/IEEE International Conference on Mobile Computing and Networking. Dallas, USA: ACM, 1998. 66−75

5 Cerpa A, Estrin D. Ascent: adaptive self-configuring sensor network topologies. *ACM SIGCOMM Computer Communication Review*, 2002, **32**(1): 62

6 Chang J H, Tassiulas L. Energy conserving routing in wireless ad-hoc networking. In: Proceedings of IEEE Inforcom. Tel Aviv, Israel: IEEE, 2000. 22−31

7 Xu Y, Heidemann J, Estrin D. Geography-informed energy conservation for ad hoc routing. In: Proceedings of the 7th Annual International Conference on Mobile Computing and Networking. Rome, Italy: ACM, 2001. 70−84

8 Meguerdichian S, Koushanfar F, Potkonjak M, Srivastava M B. Coverage problems in wireless ad-hoc sensor networks. In: Proceedings of the 20th Annual Joint Conference of the IEEE Computer and Communications Societies. Alaska, USA: IEEE, 2001. 1380−1387

9 Bulusu N, Heidemann J S, Estrin D. Adaptive beacon placement. In: Proceedings of the 21st International Conference on Distributed Computing Systems. Arizona, USA: IEEE, 2001. 489−498

10 Kwon Y, Mechitov K, Sundresh S, Kim W, Agha G. Resilient localization for sensor networks in outdoor environments. In: Proceedings of the 25th IEEE International Conference on Distributed Computing Systems. Ohio, USA: IEEE, 2005. 643−652

11 Wang Fu-Bao, Shi Long, Ren Feng-Yuan. Self-localization systems and algorithms for wireless sensor networks. *Journal of Software*, 2005, **16**(5): 857−868
(王福豹, 史龙, 任丰原. 无线传感器网络中的自身定位系统和算法. 软件学报, 2005, **16**(5): 857−868)

12 Bulusu N, Heidemann J, Estrin D. GPS-less low-cost outdoor localization for very small devices. *IEEE Personal Communications*, 2000, **7**(5): 28−34

13 Nagpal R, Shrobe H, Bachrach J. Organizing a global coordinate system from local Information on an ad hoc sensor network. In: Proceedings of the 2nd International Workshop on Information Processing in Sensor Networks. Palo Alto, CA: 2003

14 He T, Huang C D, Blum B M, Stankovic J A, Abdelzaher T. Range-free localization schemes for large scale sensor networks. In: Proceedings of the 9th Annual International Conference on Mobile Computing and Networking. San Diego, USA: ACM, 2003. 81−95

15 Niculescu A, Nath B. DV based positioning in ad hoc networks. *Telecommunication Systems*, 2003, **22**(1-4): 267−280

16 Nicolescu D, Nath B. Ad-hoc positioning systems (APS). In: Proceedings of 2001 IEEE Global Telecommunications Conference. San Antonio, USA: IEEE, 2001. 2926−2931

17 Cox T, Cox M. *Multidimensional Scaling*. London: Chapman and Hall, 1994

18 Shang Y, Ruml W, Zhang Y, Fromherz M P J. Localization from mere connectivity. In: Proceedings of the 4th ACM International Symposium on Mobile Ad Hoc Networking and Computing. Annapolis, USA: ACM, 2003. 201−212

19 Ji X, Zha H Y. Sensor positioning in wireless ad-hoc sensor networks using multidimensional scaling. In: Proceedings of the 23rd Annual Joint Conference of the IEEE Computer and Communications Societies. Hong Kong, China: IEEE, 2004. 2652−2661

20 Shang Y, Ruml W, Zhang Y, Fromherz M P J. Localization from connectivity in sensor networks. *IEEE Transactions on Parallel and Distributed Systems*, 2004, **15**(11): 961−974

21 Costa J A, Patwari N, Hero A O. Distributed weighted-multidimensional scaling for node localization in sensor networks. *ACM Transactions on Sensor Networks*, 2006, **2**(1): 39−64

22 Shang Y, Shi H C, Ahmed A A. Performance study of localization methods for ad-hoc sensor networks. In: Proceedings of the 1st International Conference on Mobile Ad-hoc and Sensor Systems. Florida, USA: IEEE, 2004. 184−193

23 Luo H Y, Li J T, Zhu Z M, Yuan W, Zhao F, Lin Q. Distributed multidimensional scaling with relative error-based neighborhood selection for node localization in sensor networks. In: Proceedings of IEEE International Conference on Intergration Technology. Shenzhen, China: IEEE, 2007. 735−739

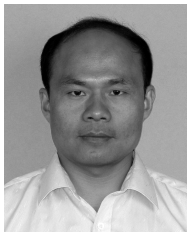
24 Savarese C, Rabaey J M, Beutel J. Locationing in distributed ad-hoc wireless sensor networks. In: Proceedings of IEEE International Conference on Acoustics, Speech, and Signal Processing. New York, USA: IEEE, 2001. 2037−2040

25 Coulson A J, Williamson A G, Vaughan R G. A statistical basis for lognormal shadowing effects in multipathfading channels. *IEEE Transactions on Communications*, 1998, **46**(4): 494−502

26 Rabbat M, Nowak R. Distributed optimization in sensor networks. In: Proceedings of the 3rd International Symposium on Information Processing in Sensor Networks. California, USA: IEEE, 2004. 20−27

27 Matlab measurements data file [Online], available: http://www.eecs.umich.edu/%7Ehero/localize/, September 5, 2007

28 Patwari N, Hero A O, Perkins M, Correal N S, Dea J O. Relative location estimation in wireless sensor networks. *IEEE Transactions on Signal Processing*, 2003, **51**(8): 2137−2148



罗海勇 中国科学院计算技术研究所博士研究生. 主要研究方向为普适计算、无线传感器网络、嵌入式系统. 本文通信作者. E-mail: yhluo@ict.ac.cn
(**LUO Hai-Yong** Ph. D. candidate at Institute of Computing Technology, Chinese Academy of Sciences. His research interest covers pervasive computing, wireless sensor networks, and embedded systems. Corresponding author of this paper.)



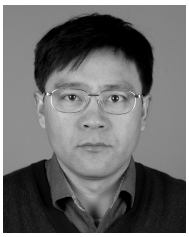
李锦涛 中国科学院计算技术研究所研究员. 主要研究方向为数字媒体处理、普适计算和虚拟现实技术.
(**LI Jin-Tao** Professor, Ph. D. at Institute of Computing Technology, Chinese Academy of Sciences. His research interest covers pervasive computing, multimedia processing, and virtual reality technology.)



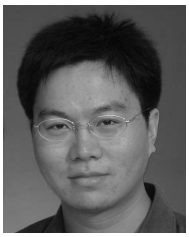
赵 方 北京邮电大学博士研究生. 主要研究方向为无线传感器网络和分布式计算.
(**ZHAO Fang** Ph. D. candidate at Beijing University of Posts and Telecommunications. Her research interest covers wireless sensor networks and distributed computing.)



林 权 北京航空航天大学硕士研究生. 主要研究方向为无线传感器网络和分布式计算.
(**LIN Quan** Master student at Beijing University of Aeronautics and Astronautics. His research interest covers wireless sensor networks and distributed computing.)



朱珍民 中国科学院计算技术研究所教授. 主要研究方向为普适计算、嵌入式系统和并行计算.
(**ZHU Zhen-Min** Professor at Institute of Computing Technology, Chinese Academy of Sciences. His research interest covers pervasive computing, embedded computing, and parallel computing.)



袁 武 北京理工大学讲师, 博士. 主要研究方向为数据网络、数据仓库、网格计算、视频处理.
(**YUAN Wu** Lecturer, Ph. D. at Beijing Institute of Technology. His research interest covers data networking, data warehouse, grid computing, and video coding.)