

基于遗传算法和模拟退火算法的 TDOA 定位技术

侯惠芳^{1,2}, 刘素华², 杨铁军²

(1. 解放军信息工程学院国家数字交换系统工程技术研究中心, 郑州 450002; 2. 河南工业大学信息科学与工程学院, 郑州 450052)

摘要:提出一种基于遗传算法与模拟退火算法的 TDOA 定位估计算法, 该算法通过对求解定位坐标计算时的最大似然函数进行求解, 实现了利用所有 TDOA 测量值对移动台的定位估计。该算法采用实数编码, 自适应交叉率和变异率实现遗传算法的全局搜索, 引入模拟退火的 Boltzmann 机制, 解决遗传算法容易陷入局部最优的问题。实验结果表明, 该算法定位精度高、收敛速度快。

关键词:到达时间差; 遗传算法; 模拟退火算法; 最大似然函数

TDOA Location Technique Based on Genetic Algorithm and Simulated Annealing Algorithm

HOU Hui-fang^{1,2}, LIU Su-hua², YANG Tie-jun²

(1. National Digital Switching System Engineering & Technological R&D Center, PLA Information Engineering College, Zhengzhou 450002;

2. College of Information Science and Engineering, Henan University of Technology, Zhengzhou 450052)

【Abstract】A new TDOA location algorithm based on Genetic Algorithm(GA) and Simulated Annealing(SA) algorithm is proposed. The algorithm utilizing GA and SA algorithm can be applied to all TDOA measures for location by computing the maximum likelihood function of the location coordinate. It achieves global searching by adopting real-code and adaptive crossover and mutation in GA, and solves easy trapping into local optimum value problem of GA by inducing Boltzmann mechanism of SA. Numerical simulations show that the algorithm has higher accuracy and rapid convergence.

【Key words】TDOA; Genetic Algorithm(GA); Simulated Annealing(SA) algorithm; maximum likelihood function

1 概述

随着蜂窝移动技术的迅速发展, 移动台的数目急剧增加, 使得对移动台的定位需求越来越迫切, 其基本原理是利用现有蜂窝网络, 通过对各种位置特征参数的测量和估计, 实现移动用户的定位。与到达时间(TOA)和到达角度(AOA)定位技术相比, 到达时间差(TDOA)定位技术通过检测信号到达 2 个基站的时间差来确定移动台的位置, 对移动台和基站之间的同步要求低、更容易实现且定位精度高, 是目前国内外的研究重点和热点。

在蜂窝网络中采用 TDOA 技术对移动台进行定位估计时, 非线性最大似然函数的计算值影响着定位精度。虽然 Fang 算法^[1]利用最大似然估计法能得到很精确的解, 但其只能利用与未知坐标数目相同的 TDOA 值, 而无法利用冗余的 TDOA 值。鉴于遗传算法(Genetic Algorithm, GA)^[2]和模拟退火算法(Simulated Annealing, SA)^[3]解决大空间、非线性等复杂问题时性能较好, 本文提出一种基于上述算法的 TDOA 定位法, 可利用所有 TDOA 值计算移动台的 2 维或 3 维的坐标。

2 TDOA 定位技术

2.1 基本原理

TDOA 定位^[4]也称双曲线定位, 如图 1 所示, 当已知基站 BS_1 和 BS_2 与移动台 MS 之间的实际距离差 $r_{21} = r_2 - r_1$, 根据 r_{21} 可以确定 MS 在以 BS_1 和 BS_2 为焦点, 且距离差恒为 r_{21} 的双曲线上, 当同时知道基站 BS_1 和 BS_3 与移动台 MS 之间的实际距离差 $r_{31} = r_3 - r_1$, 根据 r_{31} 可以确定 MS 在以 BS_1 和 BS_3 为焦点且距离差恒为 r_{31} 的双曲线上。求得 2 组双曲线的 2 个交

点后, 再根据一些先验经验知识(如小区半径), 即可分辨出真实解, 得到 MS 的位置。

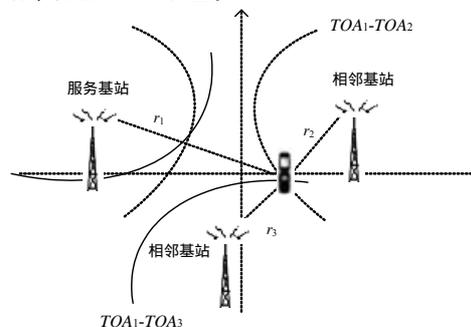


图 1 双曲线定位方法

2.2 数学模型

以 M 个基站 BS 对移动台 MS 进行 2 维定位估计为例, 假定所有 TDOA 测量值都是参照于服务基站 BS_1 发射的信号, 设 (X_i, Y_i) 为第 i 个 BS 的已知位置, (x, y) 为 MS 的待估计位置, r_i 为 MS 到 BS_i 的距离, r_{i1} 为 MS 到 $BS_i (i \neq 1)$ 和到 BS_1 的距离差, c 为电波传播速度, τ_{i1} 是 TDOA 测量值(即

基金项目:河南省科技攻关基金资助重点项目(072102210046); 河南省杰出青年基金资助项目

作者简介:侯惠芳(1972-), 女, 副教授、博士研究生, 主研方向: 无线网络, 智能信息处理; 刘素华, 副教授; 杨铁军, 副教授、博士

收稿日期:2007-08-04 **E-mail:** houht72@163.com

时间差值)。考虑在有噪声的情况下, $cn_{i,1}$ 是测量 TDOA 时引入的高斯白噪声, 由于广义相关(GCC)检测的 TDOA 测量值通常为高斯数据, 服从近似的正态分布, 因此噪声矢量是服从近似的正态分布的高斯白噪声。

根据测量得到的各 TDOA 值建立以下方程:

$$\begin{aligned} r_i &= \sqrt{(X_i - x)^2 + (Y_i - y)^2} \\ r_{i,1} &= cr_{i,1} = r_i - r_1 + cn_{i,1} = \\ &= \sqrt{(X_i - x)^2 + (Y_i - y)^2} - \sqrt{(X_1 - x)^2 + (Y_1 - y)^2} + cn_{i,1} \\ & \quad i = 2, 3, \dots, M \end{aligned}$$

计算移动台的位置最终归结为求解 $M-1$ 个上述方程组成的关于移动台位置 (x, y) 的非线性方程组, 设 $\Delta r, r, r_1, n$ 为 $M-1$ 个基站构成的 $M-1$ 维向量, 则记

$$\begin{aligned} \Delta r &= [r_{2,1}, r_{3,1}, \dots, r_{M,1}]^T = [cr_{2,1}, cr_{3,1}, \dots, cr_{M,1}]^T = \\ r - r_1 + cn &= [r_2 - r_1, r_3 - r_1, \dots, r_M - r_1]^T + cn = \\ &= \begin{bmatrix} \sqrt{(X_2 - x)^2 + (Y_2 - y)^2} - \sqrt{(X_1 - x)^2 + (Y_1 - y)^2} \\ \sqrt{(X_3 - x)^2 + (Y_3 - y)^2} - \sqrt{(X_1 - x)^2 + (Y_1 - y)^2} \\ \vdots \\ \sqrt{(X_M - x)^2 + (Y_M - y)^2} - \sqrt{(X_1 - x)^2 + (Y_1 - y)^2} \end{bmatrix} + cn \end{aligned}$$

其中, $r = [r_2, r_3, \dots, r_M]^T, r_1 = [r_1, r_1, \dots, r_1]^T, n = [n_{2,1}, n_{3,1}, \dots, n_{M,1}]^T$ 。

因为 $r - r_1$ 是确定的, n 服从均值为 0、方差为 δ^2 的正态分布, 所以 Δr 的每一个元素都是均值为 $r - r_1$ 、方差为 δ^2 的正态分布随机变量, 假定 $[x, y, r_1]^T$ 的元素互不相关, 则对应的最大似然函数^[5]为

$$\begin{aligned} & \prod_{i=2}^M \left\{ \frac{1}{\sqrt{2\pi\delta}} \exp \left\{ -\frac{[\Delta r_i - (r_i - r_1)]^2}{2\delta^2} \right\} \right\} = \\ & \left(\frac{1}{\sqrt{2\pi\delta}} \right)^{M-1} \cdot \exp \left\{ -\frac{[(\Delta r - (r - r_1))^T (\Delta r - (r - r_1))] }{2\delta^2} \right\} \end{aligned}$$

求最大似然函数等价于求解下面的最小值问题:

$$(\hat{x}, \hat{y}) = \arg \min_{(x,y)} \{ [(\Delta r - (r - r_1))^T (\Delta r - (r - r_1))] \}$$

为引用方便, 记上式为

$$g(x, y) = \min \{ [(\Delta r - (r - r_1))^T (\Delta r - (r - r_1))] \} = \min \left\{ \sum_{i=2}^M [\Delta r_i - (r_i - r_1)]^2 \right\} \quad (1)$$

显然, 通过求解式(1)可以得到移动台的坐标估计。若要对移动台 MS 进行 3 维定位, 只须把式(1)中对应的坐标变为 3 维即可。但式(1)求解的是非线性多维最优值问题, 用解析法较难求解, 收敛性较差, 甚至有时无法收敛, 而 GA 和 SA 在解决非线性寻优问题时具有收敛速度快、存在最优解等优点, 因此, 本文将两者结合起来求解移动台的坐标。

3 引入 Boltzmann 机制的遗传算法

为了避免 GA 陷入区域优化过程, 本文将 SA 的 Boltzmann 生存方法应用于 GA 中。详细设计如下。

3.1 个体编码

本文采用的是实数编码方式, 将待求的移动台坐标的真实值排列在一起构成一个个体, 即一个染色体。

3.2 初始种群的生成

本文采用如下的方式生成初始种群。设种群规模为 N , 随机生成 n 个(即特定参数个数)实数, 它们排列在一起构成一个个体, 连续产生 N 个这样的个体。

3.3 适应度函数(评估函数)的确定

根据似然法的基本原理, 每个个体以式(1)计算出的 g_i 作为目标函数值, g_i 越小, 个体适应度越高。因此, 个体适应

度可按式(2)计算, 群体总的适应度如式(3)所示。

$$f_i = 1/g_i = 1/\{[\Delta r - (r - r_1)]^T [\Delta r - (r - r_1)]\} \quad (2)$$

$$F = \sum_{i=1}^N f_i \quad (3)$$

3.4 选择算子

本文采用了轮盘赌法, 具体操作过程如下:

(1) 计算每个个体的适应度 f_i 和群体总的适应度。

(2) 计算每一个体的选择概率 $P_i = f_i / F$ 及累计概率

$$q_i = \sum_{j=1}^i P_j$$

(3) 在轮盘赌上按各 P_i 大小分成不等的扇形区域, 再将旋转轮盘赌 N 次即可选出 N 个个体。在计算机上实现的步骤为: 产生 $[0,1]$ 之间的随机数 r , 若 $r < q_i$, 则第 1 个个体入选, 否则, 第 i 个 ($2 \leq i \leq m$) 个体入选, 使满足 $q_{i-1} < r < q_i$ 。

3.5 交叉算子

当交叉率取常数时, 不利于搜索能力的提高, 而让交叉率随着遗传进程自适应地变化, 算法具有更高的鲁棒性、全局最优性和效率。因此, 交换率定义为

$$P_c = \begin{cases} k_1 \times \frac{(f_{\max} - f')}{(f_{\max} - f_{\text{avg}})} & f' > f_{\text{avg}} \\ k_2 & f' < f_{\text{avg}} \end{cases}$$

其中, k_1 和 k_2 为 $[0,1]$ 间的常数且 $k_1 > k_2$; f_{\max} 为群体的最大适应度; f_{avg} 为群体的平均适应度; f' 为 2 个父代中适应度较大的适应度值。

交叉算子的具体操作过程如下:

(1) 对每一个个体随机产生一个 $[0,1]$ 间的数 r , 若 $r < P_c$, 则对应的个体进行交叉操作, 设产生 L 个要交叉的个体;

(2) 将这 L 个个体随机两两组合;

(3) 对每一对个体进行如下的交叉运算: 设 $parent_1, parent_2$ 分别为要进行交叉的两父代个体, $child_1, child_2$ 为新产生的个体, 则

$$child_1 = \alpha \cdot parent_1 + \beta \cdot parent_2$$

$$child_2 = \beta \cdot parent_1 + \alpha \cdot parent_2$$

其中, α, β 为权重, α 是 $[0,1]$ 上的随机数, $\beta = 1 - \alpha$, 该交叉算子可保证搜索区域覆盖 $parent_1, parent_2$ 的所有邻域, 且两者之间的区域搜索几率较大。

3.6 变异算子

变异率越大, 则种群的多样性越好, 发生早熟的可能性越小, 但较大的变异率将使 GA 退化为随机摸索, 进化速度变慢。因此, 定义变异率为

$$P_c = \begin{cases} k_3 \times \frac{(f_{\max} - f')}{(f_{\max} - f_{\text{avg}})} & f' > f_{\text{avg}} \\ k_4 & f' < f_{\text{avg}} \end{cases}$$

其中, k_3 和 k_4 为 $[0.001, 0.01]$ 间的常数, 且取 $k_3 > k_4$; f_{\max} 为群体的最大适应度; f_{avg} 为群体的平均适应度; f' 为该个体对应的适应度值。

变异算子的具体操作过程如下:

(1) 对进行过交叉操作的每一个个体(共 L 个)的每一分量产生 $[0,1]$ 之间的随机小数, 若该数小于变异率, 则对该分量进行变异操作; 否则放弃对该分量变异。

(2) 变异。因为个体编码为实数, 所以为变异的分量 x_i 加上一个服从正态分布的扰动 ξ , 即 $x_i' = x_i + \xi$ 。

3.7 群体更新的 Boltzmann 准则

为了避免 GA 陷入区域优化, 本文在传统 GA 的生存策略中引入 SA 的 Boltzmann 更新机制。

首先定义一个环境参数均方差 $E_p = \frac{1}{N} \sum_{i=1}^N (f_i - f_{avg})^2$, 其中, f_i 为个体 i 的适应度; f_{avg} 为群体平均适应度。设新个体的适应度为 f_2 , 父个体的适应度为 f_1 , 记 $\Delta f = f_2 - f_1$ 。

Boltzmann 准则如下: (1)若 $\Delta f > 0$, 用新个体代替父个体。(2)若 $\Delta f < 0$, 计算 $\exp(-k \cdot \Delta f / E_p)$, 其中, k 为大于 0 的实数, $E_p = 1$ 时, $k = E_p + 1$; 否则, $k=1$ 。当

$$\exp(-k \cdot \Delta f / E_p) \in [0, 1]$$

时, 用新个体代替父个体; 当

$$\exp(-k \cdot \Delta f / E_p) > [0, 1]$$

时, 保留父个体。其中, 遗传环境的表现型均方差 E_p 控制群体更新过程, 以概率 $\exp(-k \cdot \Delta f / E_p)$ 接受劣解。在算法后期, E_p 较小, 群体更新接近代沟为 1 的覆盖更新方式, 防止了 GA 的过早收敛。

4 改进的 TDOA 定位算法

算法具体实现步骤如下:

step1 要定位的移动台发出一个已知信号, M 个基站接收该信号。

step2 获得 TDOA 测量值 τ_{i1} , 将 τ_{i1} 乘以电波传播速度 c , 得到 Δr_i 。

step3 利用 GA 和 SA 求解移动台的坐标。

step3.1 初始化控制参数, 如种群个数 N 、阈值 ε 。

step3.2 随机生成初始群体 G_f , 计算 f_{avg} 及 f_i 。

step3.3 利用选择、交叉、变异算子生成子代, 并计算子代的适应度 f , 实现对新子代的评估: 若新子代优于父代, 用子代替换父代; 否则, 以 Boltzmann 准则接受子代。

step3.4 收敛条件判断。若相邻两代的平均适应度差值小于阈值 ε , 即 $|f_{avg_i} - f_{avg_{i+1}}| < \varepsilon$, 终止搜索, 选择适应值最高的作为最优解; 否则, 转 step3.3。

step4 将计算得到的地理位置发送给移动台, 完成定位。

5 仿真实验与结果比较

实验仿真数据如下: 假定小区半径为 3 000 m, 有 5 个基站, 其中, 服务基站的坐标为 $BS_1(0, 0)$; 相邻基站的坐标分别为: $BS_2(3\ 000\sqrt{3}, 3\ 000)$, $BS_3(0, 6\ 000)$, $BS_4(-3\ 000\sqrt{3}, 3\ 000)$, $BS_5(-3\ 000\sqrt{3}, -3\ 000)$; 移动台位置为 $(1\ 000, 2\ 000)$, 单位为 m。假定无 NLOS 误差, 目标函数对应于式(1)的图像见图(2)。

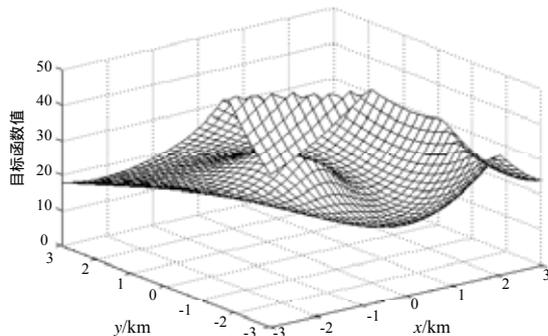


图2 目标函数对应于式(1)的图像

实验 1 设初始种群的个数为 200, $k_1 = 0.9$, $k_2 = 0.6$,

$k_3 = 0.01$, $k_4 = 0.001$, $\varepsilon = 0.001$ 。表 1 是运行结果, 最终求解坐标为 $(1\ 005.5, 1\ 997.2)$, 与真实位置的距离为 6.17 m。

表1 运行结果

迭代次数	x/km	y/km	适应度函数值	平均适应度值	与真实位置距离/km
1	2.145 8	2.399 7	0.210 6	0.091 1	1.213 51
2	2.557 2	1.826 7	0.260 0	1.110 5	1.566 81
3	2.671 3	1.862 8	0.325 4	1.117 9	1.676 92
4	1.091 7	2.078 8	13.105 6	7.764 4	0.120 91
5	1.091 7	1.968 7	53.581 0	9.291 9	0.096 89
6	1.087 1	1.972 5	60.096 8	22.083 3	0.091 34
7	1.042 6	1.968 7	150.843 5	52.057 3	0.052 86
8	1.036 7	1.982 5	294.561 5	55.513 4	0.040 66
9	1.020 7	1.987 9	800.510 9	239.327 6	0.023 98
10	0.986 2	1.993 9	1 096.285 4	624.416 8	0.015 09
11	1.006 2	1.991 9	2 863.024 6	1 101.623 2	0.010 20
12	0.988 9	2.006 1	2 889.740 5	1 720.125 3	0.012 67
13	1.001 5	1.992 9	3 622.401 0	2 053.612 4	0.007 26
14	1.004 3	1.993 9	5 100.347 2	3 550.345 8	0.007 46
15	1.006 3	2.002 8	5 254.340 4	4 000.629 9	0.006 89
16	1.005 8	2.002 6	6 161.897 9	4 131.512 3	0.006 36
17	1.007 5	1.997 8	8 144.091 1	7 378.147 9	0.007 82
18	0.994 9	2.003 7	10 460.445 0	9 030.323 2	0.006 30
19	1.005 5	1.997 2	12 552.979 0	12 034.123 1	0.006 17
20	1.005 5	1.997 2	12 552.979 0	12 034.287 9	0.006 17
21	1.005 5	1.997 2	12 552.979 0	12 034.288 3	0.006 17

实验 2 取 500 个移动台, 其中, x 在 0 m~1 000 m 内随机产生; y 在 0 m~2 000 m 内随机产生, 其他参数不变, 分别采用不引进 SA 的 GA 与引进 SA 的 GA 计算移动台的坐标, 对比结果如表 2 所示, 可以看出, GA+SA 的定位精度和计算时间都得到了改善。

表2 GA 和 GA+SA 实验结果的比较

算法	估计点与真实点平均距离/km	平均进化代数	平均计算时间/s
GA	0.041	50	约 30
GA+SA	0.012	23	约 12

实验 3 设信噪比的变化范围为 -15 dB~15 dB, 每种条件下取 500 个移动台, 其中, x 在 0 m~1 000 m 内随机产生; y 在 0 m~2 000 m 内随机产生, 其他参数不变, 计算移动台的坐标, 并将结果与文献[6]的 chan 算法对比。评价指标为均方误差: $MSE = E[(x - \hat{x})^2 + (y - \hat{y})^2]$, 其中, (x, y) 为 MS 实际位置; (\hat{x}, \hat{y}) 为 MS 估计位置, MSE 越小, 定位精度越高。得到的对比仿真结果如图 3 所示。

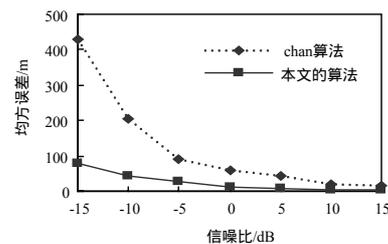


图3 2种算法的仿真结果对比

(下转第 183 页)