

DOI:10.19651/j.cnki.emt.2211322

基于非扩张映射及 SOM 进行特征选择的 DOA 估计 *

谭秀辉 白艳萍 王鹏 胡红萍 程蓉 续婷

(中北大学数学学院 太原 030051)

摘要:为进一步研究窄带水声信号特征与波达方向(DOA)的映射关系,在基于三层自组织神经网络映射对声信号特征向量进行拓扑排序的基础上,提出了结合区域 Lipschitz 系数及局部 Lipschitz 系数进行改进的 DOA 估计模型。该方法通过对信号特征与波达角所形成的映射进行非扩张映射检验,即对区域李普希兹系数进行讨论并对映射的优劣进行评判,以自组织神经网络为训练器,依据特征层拓扑排序并结合局部 Lipschitz 系数构建基于 1-邻域的综合 DOA 估计法则,从而改进了 DOA 估计系统。仿真实验结果显示该方法所选择特征用于对 DOA 的估计效果更优,平均误差、方差均在 10^{-2} 以内;在信噪比(SNR)从 20 dB 下降到 2 dB 的情况下,对照其他常用 DOA 估计算法,估计结果同时显示出良好的鲁棒性。

关键词: 波达方向估计;三层自组织神经网络;特征拓扑排序;非扩张映射;1-邻域估计法则

中图分类号: TP183 文献标识码: A 国家标准学科分类代码: 520.2060

DOA estimation based on non-expansive mapping and self-organizing neural networks for feature selection

Tan Xiuhui Bai Yanping Wang Peng Hu Hongping Cheng Rong Xu Ting

(School of Mathematics, North University of China, Taiyuan 030051, China)

Abstract: To further study the mapping relationship between narrowband hydroacoustic signal features and the direction of the arrival (DOA), an improved DOA estimation model combining regional Lipschitz coefficients and local Lipschitz coefficients is proposed based on the topological ordering of acoustic signal feature vectors based on three-layer self-organizing neural network mapping. This method is used to check the non-expansive mappings formed by the mapping of signal features to angles of arrival, which is a discussion of the regional Lipschitz coefficients as well as a judgment on the superiority of the mapping, using a self-organizing neural network as trainer, based on the topological ordering of feature layers, and combined with local Lipschitz coefficients to construct an integrated DOA estimation law based on the 1-neighborhood-rules. The simulation experimental results shows that the method is effective in estimating the angle of direction of arrival, with the average error and variance within 10^{-2} degree; the estimation results also shows good robustness against other commonly used DOA estimation algorithms, when the signal-to-noise ratio (SNR) decreased from 20 dB to 2 dB.

Keywords: direction of arrival; three-layer self-organizing maps; topological order; non-expansiveness projection; 1-neighborhood estimation rule

0 引言

阵列信号处理是现代信号处理领域的重要分支,其中波达方向(direction of arrival, DOA)的估计问题是阵列信号处理的一个重要问题。近几十年内,许多不同的 DOA 估计算法被提出,其中一类非常重要的方法为特征空间谱

分解(eigenspace spectral decomposition ESD),包括以多重信号分类算法(multiple signal classification, MUSIC)^[1]及旋转不变子空间算法(estimate of signal parameters via rotational invariance technique, ESPRIT)^[2]为代表的许多算法。近年来,以这两种算法为基础的许多算法被提出^[3-6],如实值根 MUSIC 算法(real-valued root-MUSIC,

收稿日期:2022-09-07

* 基金项目:国家自然科学基金面上项目(61774137, 51875535, 61927807)、山西省回国留学人员科研项目(2021-108)、山西省自然科学基金(202103021224195, 202103021224212, 202103021223189, 20210302123019)项目资助

RV-root-MUSIC)^[7], 时频空间谱分解法^[8], 离散傅里叶变换 ESPRIT 法 (discrete fourier transform ESPRIT, DFT-ESPRIT)^[9], 实频多重不变性 ESPRIT 法 (time-frequency multi-invariance ESPRIT, t-f MI-ESPRIT)^[10], 及联合 ESPRIT、MUSIC^[11]方法。它们主要将观察空间的信号利用协方差阵的谱分解, 将特征空间分解为信号子空间及噪声子空间, 依据二者正交的特性得到普函数, 从而进行 DOA 估计。这类算法由于涉及到协方差阵的谱分解运算, 使得计算量颇大, 从而限制了该算法的实时应用可行性。

另一类常用方法是力求建立信号观察空间与 DOA 空间的映射关系, 主要以神经网络为典型代表^[12-16], 其中主要以径向基神经网络 (radial Basis Function Neural Network, RBFNN)^[17-18] 及卷积神经网络 (Convolutional Neural Network, CNN)^[19-20] 为代表, 其通过神经网络建立接收信号特征向量与 DOA 空间之间的非线性映射, 避免了谱分解这样的复杂计算, 但却有着受限于训练数据的不足。要得到信号观察空间到 DOA 空间的精确映射是一件困难的事, 因此一种新的解题思路被提出, 并在通信信号的定位问题中进行了初步讨论, 如在传感器阵元分布为均匀线阵下利用自组织神经网络 (self-organized map, SOM) 进行的水声 DOA 估计^[21-22], 该方法通过寻找阵列信号来波时间差向量 (time difference of arrival, TDOA) 特征空间的拓扑排序与 DOA 空间的拓扑排序的映射关系, 将连续的映射进行离散化, 从而建立具有查询功能的字典, 用于进行定向定位的预测估计, 但仅仅就特定的均匀直线阵下的 TDOA 特征进行了研究, 没能对其他类型阵列以及随机阵列下 TDOA 特征的拓扑排序进行进一步的讨论, 同时所建立的映射匹配原则粗糙, 估计结果过度依赖训练网格的密度, 同时一些研究表明阵列的排布设计对目标的探测起到至关重要的作用^[23]。

本文通过考察不同传感器阵列对应的 TDOA 特征与 DOA 对应映射在训练区域上的 Lipschitzs 系数, 衡量不同特征用于估计 DOA 的性能; 进一步的, 结合训练集中每个元素的局部邻域内 Lipschitzs 系数, 对通过 SOM 神经网络进行的 DOA 估计法则进行 1-邻域范围的加权调整, 得到合理的 DOA 估计模型。最后通过实验验证了 Lipschitzs 系数小的特征对 DOA 进行估计的效果更优, 同时调整后的映射法则更有利于 DOA 估计的准确性, 并在同等信噪比的情况下与其他几种常用的 DOA 估计法进行对比, 得出本文方法同时具有稳定性。该方法为水听器阵列信号特征的选择提供了可行的理论依据, 为 DOA 估计方法的可靠性提供了一种验证方法。

1 基于自组织神经网络的 DOA 估计模型

1.1 基于 TDOA 特征的 DOA 估计原理

二维空间分布着由 M 个传感器所构成的传感器阵列, 其中相邻两传感器之间的距离为 Δ_i , 且有 $\Delta_i \leq \lambda$, ($i = 1, 2, \dots, M - 1$)。其中 λ 为声源波长, 且有 $\lambda = c/f$, 这里 c 为声波在介质中的传播速度, f 为声波的频率。建立空间直角坐标系, 使得传感器 1 放置于坐标原点处作为参考阵元。设有一声源位于同一平面内的 (x, y) 点处, 传感器 i 位于点 (x_i, y_i) ($i = 1, 2, \dots, M$)。

设点 (x, y) 与 $(0, 0)$ 点连线与 x 轴的夹角为波达方向角记做 θ , 传感器 i 得到的观测信号为:

$$u_i(t) = s(t + t_i) + n_i(t) \quad (i = 1, 2, \dots, M) \quad (1)$$

其中, $s(t)$ 为信号源所发出的真实信号, t_i 为传感器 i 的延时, $n_i(t)$ 为噪声, 假设信号与噪声之间是相互独立的, $n_i(t) \sim N(0, \sigma^2)$ 。信号源 (x, y) 到传感器 i ($i = 1, 2, \dots, M$) 的距离为 r_i ($i = 1, 2, \dots, M$), 相邻传感器之间的距离差为 $r_{i,i+1} = r_{i+1} - r_i$, 由此得传感器之间的波达时间差为 $\Delta t_{i,i+1} = r_{i,i+1}/c$ 。因此不含噪的 TDOA 向量为:

$$\mathbf{T}_0 = \mathbf{r}/c = [\Delta t_{1,2}, \Delta t_{2,3}, \dots, \Delta t_{M-1,M}]^T \in R^{M-1} \quad (2)$$

其中, $\mathbf{r} = [r_{1,2}, r_{2,3}, \dots, r_{M-1,M}]^T \in R^{M-1}$ 为距离差向量, 含噪 TDOA 向量为 $\mathbf{T} = \mathbf{T}_0 + \mathbf{n}$, \mathbf{n} 为噪声向量, $\mathbf{n} = [n_{1,2}, n_{2,3}, \dots, n_{M-1,M}]^T \in R^{M-1}$, $n_{i,i+1} = n_{i+1} - n_i$, 也可看作延时误差。

DOA 估计中心问题即要建立起一个映射 $F: R^{M-1} \rightarrow R^1$, 由 TDOA 向量 \mathbf{T}_0 到 DOA 向量角 θ , 即 $\theta = F(\mathbf{T}_0)$, 从而待估参数 θ 由式 $\hat{\theta} = \hat{F}(\mathbf{T}_0)$ 逼近。这里 \hat{F} 表示用于逼近映射 F 的神经网络映射。

1.2 三层 SOM 自组织神经网络的 DOA 估计模型

建立三层 SOM 神经网络。如图 1 所示, 第 1、2 层 SOM 是一个由 R^{M-1} 到 R^2 的映射, 此映射使得距离差向量的拓扑排序得以在二维空间中可视化。输入向量为 R^{M-1} 空间中的向量 \mathbf{r} , 他们被映射到 K ($K \leq N$) 个节点的二维空间上。各节点与输入节点之间的权值向量通过竞争进行不断的调整, 每一个获胜的节点代表一类向量的中心, 每个样本向量对应于一个激活节点, 而该节点与类中心节点的欧式距离代表着输入向量之间的相近程度, 即特征层节点之间的远近程度体现着输入向量之间的欧式距离的大小, 该二维空间中节点的排布体现了输入特征向量的拓扑序排布。

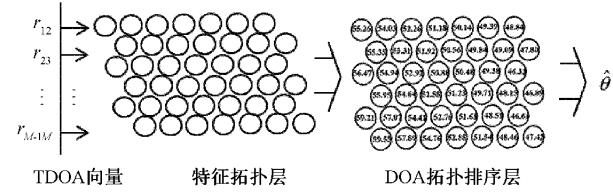


图 1 三层 SOM 神经网络结构

第 3 层映射是一个 $1-1$ 映射, 从二维特征层到 DOA 空间, 二者采用相同的节点排布方式, 即结构一致且节点数一致。每个节点对应于一个 DOA 值, 同时保留着 DOA 的拓扑排布关系。假设第一层中的节点 i 被 n_i ($\sum n_i = n$)

个输入样本向激活, 这些输入样本所对应的信源坐标为 (x_i, y_i) , 点 (x_i, y_i) 处信源的波达方向角为 θ_i 。根据被激活节点个数的不同, 第三层网络的输出值按如下规则进行:

如果节点 i 仅被一个输入训练向量激活, 即 $n_i = 1$, 则训练向量所对应的信源的波达方向角即为输出, 即 $\hat{\theta} = \theta_i$ 。

当节点 i 被不止一个训练向量所激活时, 即 $n_i > 1$, 该节点对应于输出层节点的输出为相应信源波达方向的均值, 即

$$\hat{\theta} = \frac{1}{n_i} \sum_{k=1}^{n_i} \theta_k \quad (3)$$

当节点 i 没有被训练向量激活时, 该节点被视作无效节点。若有新的输入向量激活该节点时, 输出层输出值采取最临近原则, 寻找与之最为接近即欧氏距离最小者对应的输出作为输出值:

$$k = \operatorname{argmin}_i \| \mathbf{r} - \mathbf{w}_i \| \quad (4)$$

$$\hat{\theta} = \theta_k \quad (5)$$

其中, $\mathbf{w}_i \in R^{M-1}$ 为最近邻网络节点的连接权向量。

2 基于非扩张映射改进的 SOM 自组织神经网络的 DOA 估计模型

2.1 基于非扩张映射的特征选择

如果映射 $\varphi(\mathbf{x})$ 满足条件 $\|\varphi(\mathbf{x}) - \varphi(\mathbf{z})\| \leq L \|\mathbf{x} - \mathbf{z}\|$ 且 $L \leq 1$, 则称该映射为非扩张映射, 其中 $\|\cdot\|$ 为欧氏距离。即映射 $\varphi(\mathbf{x})$ 是 Lipschitz 连续函数, $\frac{\|\varphi(\mathbf{x}) - \varphi(\mathbf{z})\|}{\|\mathbf{x} - \mathbf{z}\|} \leq L$, 同时 Lipschitz 系数 < 1 。可见 φ 满足李普希兹条件时, φ 一致连续。即对 $\forall \epsilon > 0$, $\exists \delta > 0$, 当 $\|\mathbf{x} - \mathbf{z}\| < \delta$ 时, 恒有式子 $\|\varphi(\mathbf{x}) - \varphi(\mathbf{z})\| < \epsilon$ 成立。这表明当自变量向量之间的欧氏距离很小时, 因变量之差也很小的。对于 DOA 估计问题, 若某种信号特征向量与 DOA 角之间满足上述映射关系, 即 $L < 1$ 映射为非扩张映射时, 则有特征向量之间的欧氏距离很小时, 波达方向角之差将更小、相近程度更高, 因此可以基于此种特征向量的拓扑排序来进行 DOA 排序, 从而达成 DOA 估计的目的。

为了验证上述的三层 DOA 映射是否为非扩张映射, 进行如下检验。设有位于 (x, y) 处的声源信号, 在其附近处有另一声源信号坐标为 $(x + \Delta x, y + \Delta y)$, 其中 Δx 与 Δy 为微小的位置改变量。设两信源的特征向量分别为 \mathbf{r} 和 $\mathbf{r}_1 = \mathbf{r} + \Delta \mathbf{r}$, 波达方向角分别为 θ 和 $\theta_1 = \theta + \Delta\theta$ 。 \mathbf{r} 与 \mathbf{r}_1 之间的欧式距离为 $\|\mathbf{r}_1 - \mathbf{r}\|$ 。波达方向角增量为 θ 与 θ_1 之间的欧氏距离为 $\|\theta_1 - \theta\|$ 。将二者进行相比, 得:

$$R(x, y, \Delta x, \Delta y) = \frac{\|\mathbf{r}_1 - \mathbf{r}\|}{\|\theta_1 - \theta\|} \quad (6)$$

当 Δx 与 Δy 在 0 附近变化时 R 值有以下 3 种情况:

R 为常函数; 假设 $R = R_0$, 即 $\|\theta_1 - \theta\| = R_0 \|\mathbf{r}_1 - \mathbf{r}\|$, 显见, $\|\mathbf{r}_1 - \mathbf{r}\|$ 与 $\|\theta_1 - \theta\|$ 成正比, 特征向量之间的相近程度与波达方向角之间的相近程度一致, 且程均匀分布, 此种情况属于理想状态, 实际问题中不常见。

R 是一个有界映射; 即存在一个正常数 L 使得 $|R| \leq L$, $(\Delta x, \Delta y) \in (0, a] \times (0, b]$ 。其中 a, b 为正常数, 此时有 $\frac{\|\theta_1 - \theta\|}{\|\mathbf{r}_1 - \mathbf{r}\|} \leq L \cdot \|\mathbf{r}_1 - \mathbf{r}\|$, 即 $\|\theta_1 - \theta\| \leq L \|\mathbf{r}_1 - \mathbf{r}\|$ 。将建立的 DOA 估计系统看作映射 $F: R^{M-1} \rightarrow R^1$, 即 $\theta = F(\mathbf{r})$, 则有 $\|F(\mathbf{r}_1) - F(\mathbf{r})\| \leq L \|\mathbf{r}_1 - \mathbf{r}\|$ 。可见 F 满足李普希兹条件, 当距离差向量之间的欧氏距离很小时, 波达方向角之差也是很小的。特别的, 当 $L < 1$ 时该映射为非扩张映射, 当距离差向量之间的欧氏距离很小时, 波达方向角之差将更小。

R 是无界映射。此时 $\|\mathbf{r}_1 - \mathbf{r}\|$ 与 $\|\theta_1 - \theta\|$ 之间没有固定的大小关系, 该特征不适用于通过构建映射进行 DOA 估计。

综合上述 3 种情况, 对于用于构建特征向量与 DOA 之间映射的特征选择与函数 R 的情况密切相关, 令 $R^p(x, y) = \sup_{\Delta x, \Delta y} R(x, y, \Delta x, \Delta y)$, ($p = 1, 2, \dots, s$) 代表 (x, y) 点处信号特征 p 在 $\Delta x, \Delta y$ 邻域内的 Lipschitz 系数, $R^p(D) = \sup_{(x, y) \in D} R^p(x, y)$, ($p = 1, 2, \dots, s$)。当 $R^p(D) < 1$ 时, 该特征与 DOA 之间映射为非特征映射, 且 $R^p(D)$ 越接近于 0 时该映射的估计效果越优, 因此可作为最优特征选择的依据。

2.2 基于 $R^p(x, y)$ 改进的三层 SOM 自组织神经网络 DOA 估计

由于在不同邻域内, 特征向量与 DOA 所构成映射的 Lipschitz 系数不同, 这导致看似相似的特征向量对应的 DOA 值可能差距很大, 因此单纯依据特征最近邻原则进行的 DOA 估计方法需要进行修正。考虑同等临近特征对 DOA 的有差别的影响, 对通过 SOM 进行拓扑排序的特征向量结合 $R^p(x, y)$ 对三层 SOM 网络映射进行改进。

在三层 SOM 神经网络拓扑层中, 当输入新的特征向量进入网络时, 根据最近邻原则激活节点为 c_0 , 以 c_0 为中心的 1-邻域 ($N_c(1)$) 如图 2 所示, 节点 c_0 的 1-邻域节点分别编号为 $c_1 \sim c_6$ 。令

$$\eta(x, y) = 1 - \frac{R^p(x, y)}{R^p(D)} \quad (7)$$

表示由点 (x, y) 所产生的训练特征在特征层中的影响指数, 则当特征层中某节点由多点对应的训练特征所激活时, 该节点所对应特征的影响指数定义为多点影响指数的均值

$$\eta(c_j) = \frac{1}{k} \sum_{i=1}^k \left[1 - \frac{R^p(x_i, y_i)}{R^p(D)} \right], (j = 0, 1, 2, \dots, 6) \quad (8)$$

令:

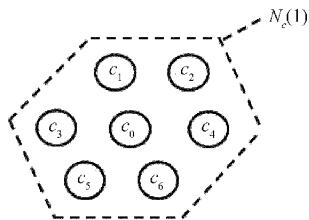


图2 特征拓扑结构中激活节点及其1-邻域节点排布

$$r(c_j) = \frac{\eta(c_j)}{\sum_{j=1}^6 \eta(c_j)} \quad (9)$$

为保持激活节点 c_0 点处的权重比例,令 $r(c_0) = a$, $a \in [0.5, 1]$, 则

$$\hat{\theta}_p = a\hat{\theta}_{c_0} + (1-a)\sum_{j=1}^6 r(c_j)\hat{\theta}_{c_j} \quad (10)$$

为由信号特征 p 所得的 DOA 估计值,其中参数 a 为节点权重调节系数。

本文所建立的 DOA 估计系统分为非扩张映射检验及三层 SOM 神经网络进行 DOA 估计两个模块,如图 3 所示。

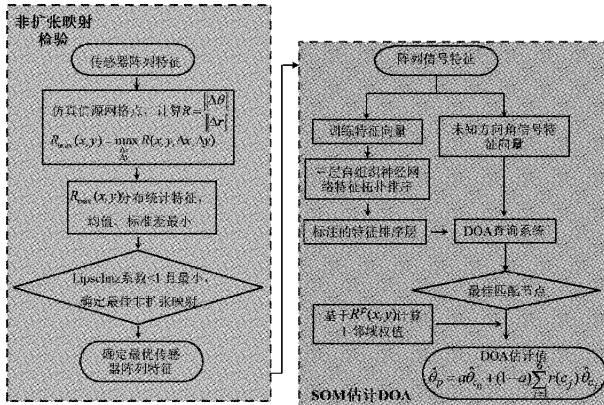


图3 非扩张映射检验及三层SOM进行DOA估计流程

模块1具体步骤:

步骤1)对提取的传感器阵列特征进行仿真信源网格分布,计算每一网格点的 $R_{\max}(x, y)$ 用于近似代替 $R^p(x, y)$;

步骤2)计算 $R_{\max}(x, y)$ 的分布统计特征,其中包括均值及方差;

步骤3)判断 Lipschitz 系数与 1 之间的关系,并选择 Lipschitz 系数值最小者作为最优特征被选择;

步骤4)根据最优特征选择确定传感器阵列的排布方案;

模块2具体步骤:

步骤1)将选定特征输入三层自组织神经网络进行特征拓扑排序;

步骤2)根据特征层拓扑排序及训练数据的实际 DOA 角度进行特征层标记,从而形成查询系统;

步骤3)未知信号特征向量进入查询系统进行最佳匹配节点判断;

步骤4)根据最佳匹配节点的 1-邻域计算权值,根据估价公式给出 DOA 估计结果。

3 仿真实验及结果分析

3.1 基于非扩张映射的模型选择

为了验证本文方法的有效性,进行水下声源探测仿真实验。设声源频率为 $f = 2$ kHz, 声波在水下传播速度为 $c = 1500$ m/s, 传感器阵列由 4 个传感器阵元组成, 每两个相邻阵元之间的距离为 $\Delta_i = 0.375$ m 即波长一半。传感器阵元的位置排布分别选择圆形、L型、直线型, 及折线形。如图 4 所示, 其中的折线阵为特别的随机阵元排布方式, 相邻阵元间距保持为波长的一半, 规定相邻阵元连线之间的夹角为钝角, 即阵元位置的满足在圆周切线的右侧依次排布, 本实验中传感器的位置排布具体如表 1 所示。

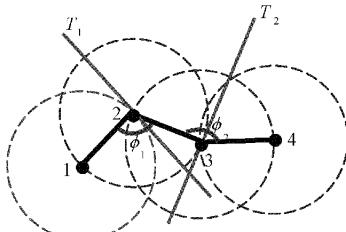


图4 折线阵阵元排布

表1 4种传感器阵列阵元排布位置

类型	1	2	3	4
环型	(0.306, 2, 0)	(0, 0, 306, 2)	(-0.306, 2, 0)	(0, -0.306, 2)
L型	(0, 0.75)	(0, 0.375)	(0.375, 0)	(0.75, 0)
折线	(0, 0)	(0.3, 0.225)	(0.5, 0.092, 2)	(0.6, 0.269, 2)
直线	(0, 0)	(0.375, 0)	(0.75, 0)	(1.125, 0)

取均匀排布于 $[30 \text{ m}, 50 \text{ m}] \times [30 \text{ m}, 50 \text{ m}] \in R^2$ 的矩形区域内的点为仿真信号源位置作为训练集信号源(如图 5 中所示),以 1 为间隔,由式(6)可计算出每个声源位置点的方形邻域内(图 5)的各点处的 R 值,进一步得到

$R_{\max}(x, y)$ 值,其中 $R^p(x, y)$ 的计算方式由理论中的上确界转变为离散点的最大比值。

$$R_{\max}(x, y) = \max_{\substack{0.01 \leq \Delta x \leq 0.5 \\ 0.01 \leq \Delta y \leq 0.5}} R(x, y, \Delta x, \Delta y),$$

$$(x, y) \in [30, 50] \times [30, 50] \quad (11)$$

其中, $\Delta x, \Delta y$ 的步长取为 0.01 m。

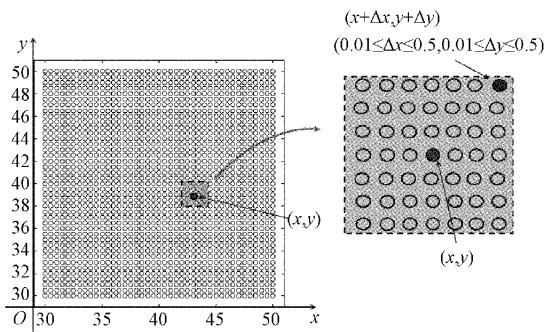


图 5 训练集信源位置排布

不同传感器阵列类型的 $R_{\max}(x, y)$ 分布如图 6 所示, 从左到右, 由上及下的顺序依次为均匀线阵、环型阵列、折线形阵列及 L 型阵列。可以看出, 除 L 型阵列外, 其他 3 种阵列的 $R_{\max}(x, y)$ 值基本集中在(0,1)区间内。

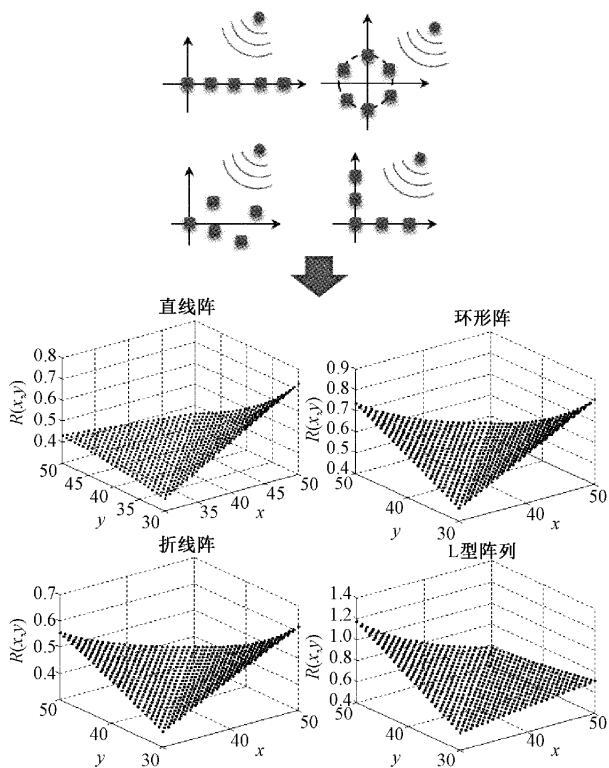


图 6 4 种阵列排布下 $R_{\max}(x, y)$ 值分布情况

从表 2 中对 4 种阵列 $R_{\max}(x, y)$ 统计值中可以看出, 折线形阵列的 $R_{\max}(x, y)$ 值的均值较小且均方差最小, 说明该传感器阵列对应 TDOA 特征的映射为非扩张映射, 且映射的 Lipschitz 系数最小, 在保持距离差向量与波达方向角之间的拓扑映射关系上也应最为稳定。

为测试基于 4 种传感器阵列下的 TDOA 特征利用 SOM 三层神经网络进行 DOA 估计的效果, 选取矩形区域

表 2 4 种传感器阵列 $R_{\max}(x, y)$ 统计情况

类型	均值	标准差	最大值	最小值
环型	0.737 9	0.001 6	0.806 0	0.465 0
L 型	1.160 3	0.005 8	1.175 0	0.573 1
折线	0.561 2	0.001 0	0.620 4	0.362 4
直线	0.553 6	0.010 5	0.730 6	0.362 2

内均匀分布的 0.5 m 间隔点作为仿真信源的位置, 得出四种阵列排布下的距离差向量 r , 分别作为 SOM 三层神经网络的输入向量进行网络训练, 以实际 DOA 值作为网络节点的标注。如图 7 所示, 每个节点的激活情况对应于相似程度最高的 r 向量, 同时按前述 DOA 输出方式赋予每个网络节点 DOA 值。为方便对比, 4 种阵列下的训练数据集规模及 SOM 特征层节点数排布均采取一致, 节点数均设定为 40×40 , 训练次数 1 000 次, DOA 估计式中取 $a = 0.9$ 。

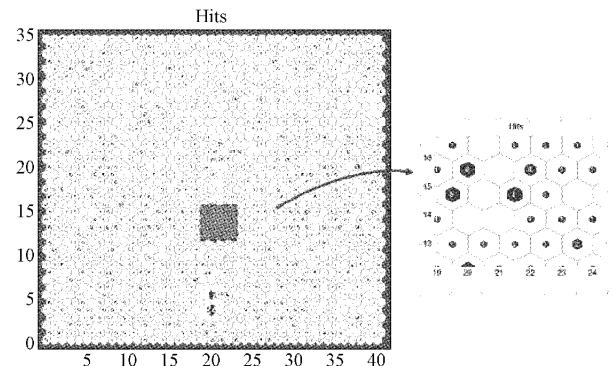


图 7 训练后 SOM 特征层节点激活示意图

网络训练结束后, 测试信号选取直线形位置均匀分布的仿真信源, 且信源位置并不在训练集信号之列。如图 8 所示, 图 8(a)~(d) 分别为折线阵、环型阵、L 型阵及直线阵列下的 DOA 估计过程。其中密布的黑色 ‘o’ 点为用于训练的仿真信源位置分布, 蓝色三角形点测试信源真实, 红色方形点为估计 DOA 时所对应最佳 r 向量匹配信源。本文所研究的 DOA 估计原理所保障的是 DOA 估计的准确性, 但从位置的匹配中也可以一定程度体现不同阵列的估计效果的差异, 可见折线阵(图 8(a))表现更为稳定。

4 种阵列下相同测试集时的 DOA 估计误差如图 9 所示, 从中可以看出在误差数量级上折线阵与 L 型阵列似乎相当, 均在 10^{-3} 级别, 精度良好。从图 10 的误差统计分析中可以看出折线阵下的 DOA 估计误差均值及方差均为最小, 因此估计效果更加稳定。

3.2 SOM 网络参数设置对系统性能的影响

神经网络参数的设置对网格的性能有着重要的影响, 因此本文对网络训练数据的间隔设置和网络结构的设置进行了多次实验。如表 3 所示, 前 3 组实验为在网络节点数固定在 50×50 , 训练数据间隔分别采取 0.25、0.5、0.75

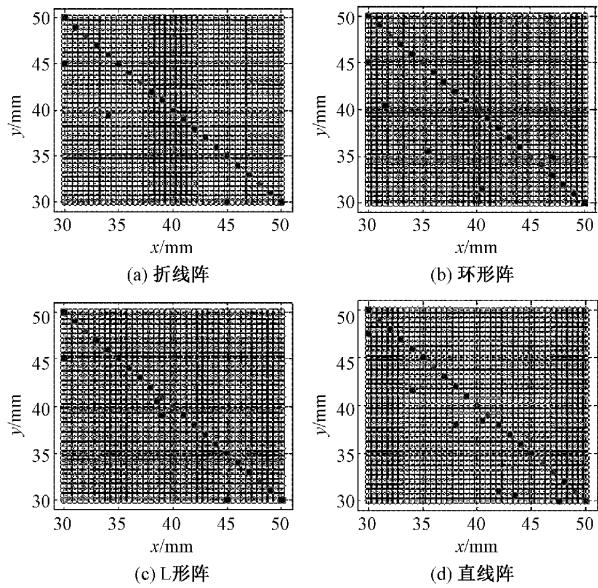


图 8 4 种阵列下测试数据激活节点所对应训练集中信源位置情况

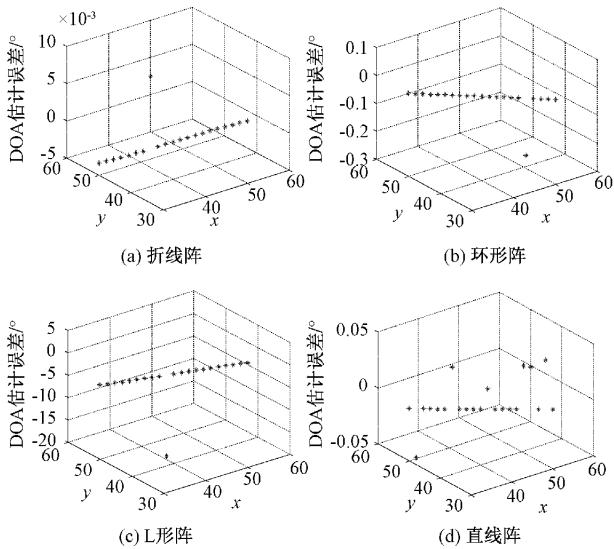


图 9 4 种阵列 40×40 神经元排布直线点测试误差

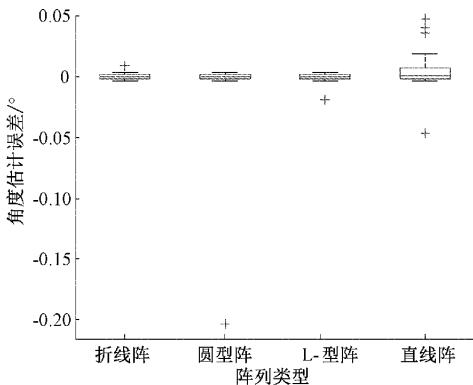


图 10 4 种阵列直线点测试误差统计分析

3 种设置的情况下,测试数据采用相同的 21 个不在网格上的仿真信号,从测试结果的均值和方差数据中可以看到并非训练数据越密集效果越好,其原因是由于训练数据越密集,会使得近似角度的训练点增加,造成对应的估计点处的加权因素过多,从而影响 DOA 估计效果,而作为较为合适的 0.5 间隔与 50×50 的网络节点设置则更为匹配。

表 3 折线阵下 SOM 网络参数下 DOA 估计效果

训练数据间隔及 网络节点设置	误差绝对值 均值/(°)	误差方差
0.25 间隔, 50×50	0.014 8	6.36×10^{-4}
0.5 间隔, 50×50	0.005 4	9.92×10^{-6}
0.75 间隔, 50×50	0.288 1	0.272 1
0.5 间隔, 41×41	0.009 6	2.18×10^{-4}
0.5 间隔, 45×45	0.005 6	9.70×10^{-6}
0.5 间隔, 48×48	0.005 4	9.92×10^{-6}
0.5 间隔, 35×35	0.010 6	2.16×10^{-4}
0.5 间隔, 38×38	0.010 6	2.16×10^{-4}
0.5 间隔, 30×30	0.024 9	0.002 8
0.5 间隔, 30×40	0.018 7	0.001 8
0.5 间隔, 50×40	0.007 5	1.19×10^{-4}

第 4 组~第 11 组实验中采取的是相同的 0.5 间隔的训练数据,数据量为 41×41,此种情况下对网络节点设置进行的 8 组实验。实验节点设置分别围绕与 41×41 相近的正方形设置和矩形两类设置进行,实验结果表明,当节点数设置较训练数据数量相近且稍多的方形设置情况下,DOA 估计的效果均表现更优。

3.3 带高斯噪声情况

由于本文所讨论的 DOA 估计方法是基于距离差特征层面所进行的,对特征层面添加高斯噪声的影响与带有去噪过程的方法不具有直接的可比性,但也可从一定的程度上对本文方法受噪声影响的鲁棒性进行评估。如图 11 所示,将本文方法(折线阵)与 MUSIC、Root-MUSIC、ESPRIT、RBF 同时对信号进行对比,信号波达方向为 30°,噪声水平从信噪比 0 dB 变化到 20 dB。DOA 估计结果如图 11 所示,虽然本文方法的噪声直接加载于特征向量上,

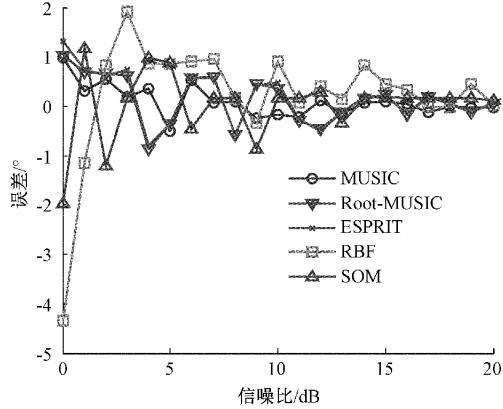


图 11 与几种常见 DOA 估计方法误差对比

但误差所受影响是在可接受的范围之内,在实际应用中,特征的提取一般是在对原始信号进行消噪后所进行的,即特征向量的含噪水平会大大降低,因此估计效果会更佳。

4 结 论

本文通过建立具有三层结构的 SOM 自组织神经网络模型,利用其对水下声波特征 TDOA 向量的自组织拓扑排序,得到 DOA 估计值的拓扑排序,通过 $R^p(x, y)$ 判断传感器阵列模型是否符合非扩张映射,给出基于 $R^p(x, y)$ 的 DOA 估计准则,最后通过仿真实验以及对比常用的 DOA 估计方法,对该模型的性能进行了评价。从实验结果可以看出,本文所提出的方法揭示了 TDOA 特征向量与 DOA 数值之间的内在联系,并在无需拟合其具体映射关系的前提下,利用他们之间的拓扑关系进行 DOA 的估计,该方法具有可以事先训练的优势,并且具有良好的有效性和稳定性。本文仅对不同阵列排布下的 TDOA 特征进行了非扩张映射性能的对比,对于更多种方法进行的不同类别的其他特征的非扩张性的研究,及相应特征下基于 $R^p(x, y)$ 进行 DOA 估计的性能仍待进一步研究。

参考文献

- [1] MENG F X, LI Z T, YU X T, et al. Quantum algorithm for MUSIC-based DOA estimation in hybrid MIMO systems [J]. Quantum Science and Technology, 2022, 7 (2), DOI: 10.1088/2058-9565/ac44dd.
- [2] LI X, ZHANG W. DOA Estimation Using Virtual ESPRIT with Successive Baselines and Coprime Baselines[J]. Circuits Syst Signal Process, 2021(40): 2065-2075.
- [3] CHEN J, GUAN S, TONG Y, et al. Two-dimensional direction of arrival estimation for improved archimedean spiral array with MUSIC algorithm[J]. IEEE Access, 2018(6): 49740-49745.
- [4] ZHOU C, ZHOU J. Direction-of-arrival estimation with coarray ESPRIT for coprime array[J]. Sensors, 2017, 17(8), DOI: 10.3390/s17081779.
- [5] ZHANG H, BI G, CAI Y, et al. DOA estimation of closely-spaced and spectrally-overlapped sources using a STFT-based MUSIC algorithm[J]. Digital Signal Processing, 2016(52): 25-34.
- [6] 李蜀丰,徐永绍,刘秉政,等.基于改进 MUSIC 的声源定位方法[J].电子测量与仪器学报,2021,35(8): 212-219.
- [7] FENG G Y, LIU S, JUN W, et al. Real-valued root-MUSIC for DOA estimation with reduced-dimension EVD/SVD computation [J]. Signal Processing, 2018(152): 1-12.
- [8] CUI K, WU W, HUANG J, et al. DOA estimation of LFM signals based on STFT and multiple invariance ESPRIT[J]. AEU-International Journal of Electronics and Communications, 2017(77): 10-17.
- [9] KIM S, OH D, LEE J. Joint DFT-ESPRIT estimation for TOA and DOA in vehicle FMCW radars [J]. IEEE Antennas and Wireless Propagation Letters, 2015 (14): 1710-1713.
- [10] LIN J C. Time-frequency multi-invariance ESPRIT for DOA estimation [J]. IEEE Antennas and Wireless Propagation Letters, 2016: 770-773.
- [11] LIU A, LI F, LI B, et al. Spatial polarimetric time-frequency distribution based DOA estimation: combining ESPRIT with MUSIC [J]. EURASIP Journal on Wireless Communications and Networking, 2018(1), DOI:10.1186/s13638-018-1058-9.
- [12] VIJAY M S, LAXMAN B U. ANN Based Hybrid RSSI-TDOA DOA Estimation and Beamforming[J]. Soft Computing for Security Applications, 2021(1397): 263-284.
- [13] AGATONOVIC M, STANKOVIC Z, DONCOV N, et al. Application of artificial neural networks for efficient high-resolution 2D DOA estimation[J]. Radio Engineering, 2012, 21(4): 1038-1045.
- [14] 姚建丽,胡红萍,白艳萍,等.应用 SAPSO-BP 神经网络的 DOA 估计方法[J].重庆理工大学学报(自然科学版),2018,(5) 1674-8425.
- [15] 王鹏,张楠,郭亚强,等.基于果蝇算法优化广义回归神经网络的矢量水听器的 DOA 估计[J].数学的实践与认识,2017, 47(13): 150-155.
- [16] 白黄琴,胡红萍,白艳萍,等.优化的 BP 神经网络在矢量水听器 DOA 估计的研究[J].现代电子技术,2019, 42(23): 31-34.
- [17] SUN F Y, TIAN Y B, REN Z L. DOA estimation with support vector machine based on hybrid kernel [J]. Telecommunication Engineering, 2016(56): 302-307.
- [18] WANG P, WANG P, FAN E. Neural network optimization method and its application in information processing [J]. Mathematical Problems in Engineering, 2021, DOI:10.1155/2021/6665703.
- [19] CHARKrabarty, SOUMITRO, HABETS A P. Multi-speaker DOA estimation using deep convolutional networks trained with noise signals[J]. IEEE Journal of Selected Topics in Signal Processing, 2019, 13(1): 8-21.
- [20] LIU Y, CHEN H, WANG B. DOA estimation based on CNN for underwater acoustic array[J]. Applied Acoustics, 2021(172), DOI: 10.1016/j.apacoust.2020.107594.

- [21] TAN X H, HU H P, CHENG R, et al. Direction of arrival estimation based on DDOA and self-organizing map [J]. Mathematical Problems in Engineering, 2015, DOI: 10.1155/2015/231307.
- [22] 谭秀辉. 自组织神经网络在信息处理中的应用研究[D]. 太原: 中北大学, 2015: 52-63.
- [23] 李元实, 王智, 鲍明, 等. 基于无线声阵列传感器网络的实时多目标跟踪平台设计及实验[J]. 仪器仪表学报,

2012, 33(1): 146-154.

作者简介

谭秀辉, 讲师, 博士, 主要从事机器学习算法及应用方面的研究。

E-mail: tanxiuhui@nuc.edu.cn

白艳萍, 教授, 博导, 博士, 主要从事机器学习算法及应用方面的研究。

E-mail: baiyp@nuc.edu.cn