



(12) 发明专利

(10) 授权公告号 CN 112801065 B

(45) 授权公告日 2021.06.25

(21) 申请号 202110387388.5

(22) 申请日 2021.04.12

(65) 同一申请的已公布的文献号  
申请公布号 CN 112801065 A

(43) 申请公布日 2021.05.14

(73) 专利权人 中国空气动力研究与发展中心计算空气动力研究所  
地址 621052 四川省绵阳市涪城区二环路南段6号

(72) 发明人 杨阳 刘林岩 赵杨 曹东 王海波 卢德勇

(74) 专利代理机构 成都九鼎天元知识产权代理有限公司 51214  
代理人 孙杰

(51) Int.Cl.  
G06K 9/00 (2006.01)  
G06K 9/62 (2006.01)  
G06N 3/08 (2006.01)

(56) 对比文件  
CN 111198374 A, 2020.05.26

US 2002055913 A1, 2002.05.09

CN 111951611 A, 2020.11.17

CN 109856639 A, 2019.06.07

CN 111505649 A, 2020.08.07

CN 111562584 A, 2020.08.21

CN 109782290 A, 2019.05.21

CN 110187335 A, 2019.08.30

CN 110542904 A, 2019.12.06

CN 1389808 A, 2003.01.08

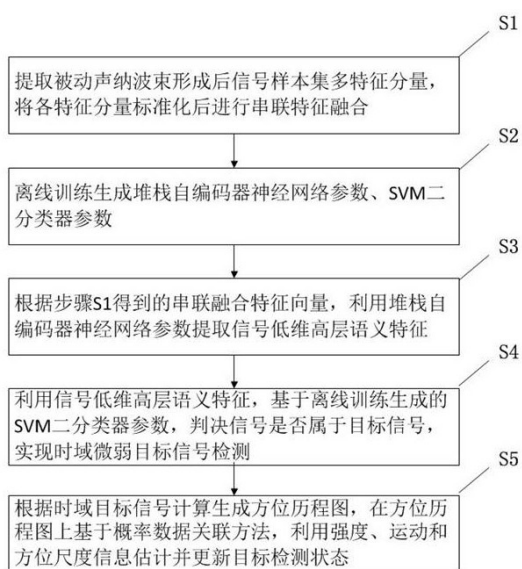
熊正大. 基于GPF和数据关联理论的被动声呐多目标跟踪技术.《中国优秀硕士学位论文全文数据库 工程科技 II 辑》.2020, (第02期), 任宇飞 等. 能量值和方位信息结合的粒子滤波算法.《哈尔滨工程大学学报》.2017, 第38卷 (第7期), Wei YI 等. Particle filtering based track-before-detect method for passive array sonar systems.《Signal Processing》.2019, 第165卷

审查员 高婕

权利要求书5页 说明书12页 附图9页

(54) 发明名称  
一种基于时空多特征信息的被动声纳目标探测方法及装置

(57) 摘要  
本发明公开了一种基于时空多特征信息的被动声纳目标探测方法及装置,该方法包括以下步骤:S1,多特征串联融合;S2,特征提取与分类器模块离线训练;S3,语义特征提取;S4,信号时域检测;S5,信号空域检测。本发明解决了现有技术存在的仅基于单一信号特征探测所导致的被动声纳弱目标提取困难、探测准确率低甚至探测失效等问题。



1. 一种基于时空多特征信息的被动声纳目标探测方法,其特征在于,包括以下步骤:

S1,提取被动声纳波束形成后信号样本集多特征分量,将各特征分量标准化后进行串联特征融合;

S2,离线训练生成堆栈自编码器神经网络参数、SVM二分类器参数;

S3,根据步骤S1得到的串联融合特征向量,利用步骤S2得到的堆栈自编码器神经网络参数提取信号低维高层语义特征;

S4,利用步骤S3得到的信号低维高层语义特征,基于步骤S2得到的SVM二分类器参数,判决信号是否属于目标信号,实现时域微弱目标信号检测;

S5,根据步骤S4得到的时域目标信号计算生成方位历程图,在方位历程图上基于概率数据关联方法,利用强度、运动和方位尺度信息估计并更新目标检测状态;

所述步骤S1包括以下步骤:

S11,分别提取波束形成后信号目标段和噪声段的多维度表征的多特征信息,提取的多特征信息包括时域波形特征、频域能量聚点特征、时频图像Renyi熵特征、Mel倒谱特征和混沌特征的两种及以上;

S12,计算各特征向量的均值和标准差,对特征向量进行标准化;

S13,将各特征向量前后串联进行特征融合;

所述步骤S5包括以下步骤:

S51,令某时刻k方位历程图的测量集合为:

$$\mathbf{z}(k) = \{\mathbf{z}_i(k), \eta_i(k), \lambda_i(k)\}_{i=1}^{m_k},$$

其中,  $m_k$  是时域检测处理后跟踪窗内目标测量数,  $\mathbf{z}_i(k)$  是第  $i$  个测量的运动信息测量值,  $\eta_i(k)$  是相应的强度信息测量值,  $\lambda_i(k)$  是相应的目标方位尺度测量值;

设  $\mathbf{Z}^k$  为截至到  $k$  时刻的所有有效测量集合:

$$\mathbf{Z}^k = \{\mathbf{z}(j)\}_{j=1}^k;$$

定义  $k$  时刻联合事件:

$$\theta_i(k) = \{\mathbf{z}_i(k), \eta_i(k), \lambda_i(k) \text{ 是来源于目标的量测}\}, i = 1, \dots, m_k,$$

$$\theta_0(k) = \{k \text{ 时刻所有量测都不来源于目标}\},$$

则概率数据关联滤波中各事件的条件概率为:

$$\begin{aligned} \beta_i &= p\{\theta_i(k) | \mathbf{Z}^k\} \\ &= p\{\theta_i(k) | \mathbf{z}(k), \eta(k), \lambda(k), m_k, \mathbf{Z}^{k-1}\} \\ &= \frac{p\{\mathbf{z}(k), \eta(k), \lambda(k) | \theta_i(k), m_k, \mathbf{Z}^{k-1}\} p\{\theta_i(k) | m_k, \mathbf{Z}^{k-1}\}}{p\{\mathbf{z}(k), \eta(k), \lambda(k)\}} \end{aligned}$$

由于强度、运动和方位尺度特征相互独立,故有:

$$p\{\mathbf{z}(k), \eta(k), \lambda(k)\} = p\{\mathbf{z}(k)\} p\{\eta(k)\} p\{\lambda(k)\}$$

$$p\{\mathbf{z}_i(k), \eta_i(k), \lambda_i(k) | \theta_i(k), m_k, \mathbf{Z}^{k-1}\} =$$

$$p\{z_i(k)|\theta_i(k), m_k, Z^{k-1}\} p\{\eta_i(k)|\theta_i(k), m_k, Z^{k-1}\}$$

$$p\{\lambda_i(k)|\theta_i(k), m_k, Z^{k-1}\}$$

S52, 分别假设目标信号的强度、运动和方位尺度特征服从以预测值为均值的高斯正态分布, 且噪声强度、运动和方位尺度特征是独立、等概率分布的, 得到目标和噪声的概率分布函数

$$p\{z_i(k)|\theta_i(k), m_k, Z^{k-1}\}, p\{\eta_i(k)|\theta_i(k), m_k, Z^{k-1}\} \text{ 和 } p\{\lambda_i(k)|\theta_i(k), m_k, Z^{k-1}\};$$

S53, 假设各测量为正确测量的先验概率相同, 得到概率分布函数

$$p\{\theta_i(k)|m_k, Z^{k-1}\};$$

S54, 由步骤S52、S53得到的概率分布函数计算得到多特征融合的加权系数 $\beta_i$ ;

S55, 由全概率公式更新k时刻目标强度、运动和方位尺度特征的状态值为:

$$\eta(k|k) = \sum_{i=0}^{m_k} \beta_i \eta_i(k|k)$$

$$Z(k|k) = \sum_{i=0}^{m_k} \beta_i Z_i(k|k) \circ$$

$$\lambda(k|k) = \sum_{i=0}^{m_k} \beta_i \lambda_i(k|k)$$

2. 根据权利要求1所述的一种基于时空多特征信息的被动声纳目标探测方法, 其特征在于, 所述步骤S11包括以下步骤:

S111, 分别计算提取信号时域均值、峰值、均方根、峭度因子、裕度指数、偏度指数;

S112, 将步骤S111中各指标串联构成时域波形特征。

3. 根据权利要求1所述的一种基于时空多特征信息的被动声纳目标探测方法, 其特征在于, 所述步骤S11包括以下步骤:

S113, 计算信号 $x(n)$ 的功率谱 $s(\omega)$ ;

S114, 给定取值宽度 $d$ , 利用滑窗在功率谱序列 $s(\omega)$ 上定步长移动, 计算各频点 $\omega_0$ 处信号功率 $P(\omega_0, d)$ , 并求取信号功率的平均值 $P_a$ 和最大值 $P_m$ , 计算公式如下:

$$P(\omega_0, d) = \sum_{\omega=\omega_0-d}^{\omega_0+d} s(\omega)$$

$$P_a = \text{mean}\{P(\omega_0, d)\}$$

$$P_m = \text{max}\{P(\omega_0, d)\}$$

其中,  $\omega_0$ 为功率谱 $s(\omega)$ 上的频率点;

S115, 给定 $\lambda$ 水平值, 得到信号功率谱 $s(\omega)$ 的 $\lambda$ 水平能量聚点; 计算公式如下:

$$P(\omega_0, d) \geq (1 - f(\lambda))P_a + f(\lambda)P_m$$

其中 $f(\lambda)$ 是变量 $\lambda$ 在 $[0, 1] \rightarrow [0, 1]$ 区间的单增函数;

S116, 根据得到的 $p$ 个 $\lambda$ 水平能量聚点处信号能量, 建立频率域 $p$ 阶特征向量, 其中 $p$ 为正整数且 $p \geq 1$ 。

4. 根据权利要求1所述的一种基于时空多特征信息的被动声纳目标探测方法, 其特征在于, 所述步骤S11包括以下步骤:

S117, 计算信号 $x(n)$ 的改进B分布, 得到二维时频图像;

S118, 根据二维时频图像的亮度等级表达灰度值, 将时频图转化为灰度图, 进行灰度归一化和中值滤波;

S119, 提取信号多阶灰度图Renyi熵特征。

5. 根据权利要求1所述的一种基于时空多特征信息的被动声纳目标探测方法, 其特征在于, 所述步骤S11包括以下步骤:

S120, 将时域分帧信号 $x(n)$ 经过 $N$ 点的离散傅里叶变换, 并对得到的频谱 $X(k)$ 取模平方, 得到信号的功率谱;

S121, 将Mel频域按人耳敏感程度分为 $M$ 个Mel滤波器, 采用的滤波器为三角滤波器, 中心频率为 $f(m)$ ,  $m=1, 2, \dots, M$ , 将信号功率谱通过Mel滤波器组得到Mel频谱, 并取Mel频谱的对数能量 $s(m)$ :

$$S(m) = \ln \left[ \sum_{k=1}^N |X(k)|^2 H_m(k) \right], m = 1, 2, \dots, M,$$

其中, $N$ 为正整数, $M$ 为正整数且 $M \geq 2$ ,  $m$ 为Mel频谱的对数能量序号,  $H_m(k)$ 为第 $m$ 个滤波器的频谱;

S122, 对数频谱经过离散余弦变换DCT后得到Mel频谱倒谱系数MFCC, 作为表征被动声纳信号的一种特征 $c(n)$ :

$$c(n) = \sum_{m=1}^M S(m) \cos \left( n(m - 0.5) \frac{\pi}{M} \right), (1 \leq n \leq m).$$

6. 根据权利要求1所述的一种基于时空多特征信息的被动声纳目标探测方法, 其特征在于, 所述步骤S11包括以下步骤:

S123, 将相空间中两个无限接近的点 $\beta_{n1}$ 和 $\beta_{n2}$ 间的距离表示为 $||\beta_{n1} - \beta_{n2}|| = \delta_0 \leq 1$ , 在一段时间后, 起始于这两点的两个轨迹之间的距离为 $\delta_{\Delta n} = ||\beta_{n1+\Delta n} - \beta_{n2+\Delta n}||$ , 最大Lyapunov指数 $\lambda$ 可表示为:

$$\delta_{\Delta n} = \delta_0 e^{\lambda \Delta n},$$

其中 $\delta_{\Delta n} \leq 1$ ,  $\Delta n \geq 1$ ,  $n1, n2$ 为时间采样序号;

S124, 对接收信号进行相空间重构, 对给定的距离 $\varepsilon$ , 计算关联积分

$C(\varepsilon)$ , 并通过求解 $\ln(C(\varepsilon))$ 对 $\ln(\varepsilon)$ 的线性区域的斜率, 得到时间序列的关联维数 $D$ ,

$$d(\varepsilon) = \frac{\partial \ln C(\varepsilon)}{\partial \ln \varepsilon},$$

$$D = \lim_{\varepsilon \rightarrow 0} d(\varepsilon),$$



其中,  $d(\epsilon)$  为计算过程中的中间量。

7. 一种基于时空多特征信息的被动声纳目标探测装置, 其特征在于, 包括特征融合模块、离线训练模块、语义特征提取模块、信号时域检测模块和信号空域检测模块, 其中:

特征融合模块, 用于提取被动声纳波束形成后信号样本集多特征分量, 将各特征分量标准化后进行串联特征融合;

离线训练模块, 利用信号样本串联融合特征向量, 离线训练生成堆栈自编码器神经网络参数和SVM二分类器参数;

语义特征提取模块, 根据信号样本集串联融合特征向量, 利用堆栈自编码器神经网络参数提取信号低维高层语义特征;

信号时域检测模块, 用于利用信号低维高层语义特征, 基于SVM二分类器参数, 判决信号是否属于目标信号, 实现时域微弱目标信号检测;

信号空域检测模块, 用于计算生成方位历程图, 在方位历程图上基于概率数据关联方法, 利用强度、运动和方位尺度信息估计并更新目标检测状态;

特征融合模块具体能用以执行以下步骤:

S11, 分别提取波束形成后信号目标段和噪声段的多维度表征的多特征信息, 提取的多特征信息包括时域波形特征、频域能量聚点特征、时频图像Renyi熵特征、Mel倒谱特征和混沌特征的两种及以上;

S12, 计算各特征向量的均值和标准差, 对特征向量进行标准化;

S13, 将各特征向量前后串联进行特征融合;

信号空域检测模块具体能用以执行以下步骤:

S51, 令某时刻  $k$  方位历程图的测量集合为:

$$\mathbf{z}(k) = \{\mathbf{z}_i(k), \eta_i(k), \lambda_i(k)\}_{i=1}^{m_k},$$

其中,  $m_k$  是时域检测处理后跟踪窗内目标测量数,  $\mathbf{z}_i(k)$  是第  $i$  个测量的运动信息测量值,  $\eta_i(k)$  是相应的强度信息测量值,  $\lambda_i(k)$  是相应的目标方位尺度测量值;

设  $Z^k$  为截至到  $k$  时刻的所有有效测量集合:

$$\mathbf{Z}^k = \{\mathbf{z}(j)\}_{j=1}^k;$$

定义  $k$  时刻联合事件:

$\theta_i(k) = \{\mathbf{z}_i(k), \eta_i(k), \lambda_i(k) \text{ 是来源于目标的量测}\}, i = 1, \dots, m_k,$

$\theta_0(k) = \{k \text{ 时刻所有量测都不来源于目标}\},$

则概率数据关联滤波中各事件的条件概率为:

$$\begin{aligned} \beta_i &= p\{\theta_i(k) | \mathbf{Z}^k\} \\ &= p\{\theta_i(k) | \mathbf{z}(k), \eta(k), \lambda(k), m_k, \mathbf{Z}^{k-1}\} \\ &= \frac{p\{\mathbf{z}(k), \eta(k), \lambda(k) | \theta_i(k), m_k, \mathbf{Z}^{k-1}\} p\{\theta_i(k) | m_k, \mathbf{Z}^{k-1}\}}{p\{\mathbf{z}(k), \eta(k), \lambda(k)\}} \end{aligned}$$

由于强度、运动和方位尺度特征相互独立, 故有:

$$p\{\mathbf{z}(k), \eta(k), \lambda(k)\} = p\{\mathbf{z}(k)\} p\{\eta(k)\} p\{\lambda(k)\}$$

$$p\{\mathbf{z}_i(k), \eta_i(k), \lambda_i(k) | \theta_i(k), m_k, \mathbf{Z}^{k-1}\} =$$

$$p\{\mathbf{z}_i(k) | \theta_i(k), m_k, \mathbf{Z}^{k-1}\} p\{\eta_i(k) | \theta_i(k), m_k, \mathbf{Z}^{k-1}\}$$

$$p\{\lambda_i(k) | \theta_i(k), m_k, \mathbf{Z}^{k-1}\}$$

S52, 分别假设目标信号的强度、运动和方位尺度特征服从以预测值为均值的高斯正态分布, 且噪声强度、运动和方位尺度特征是独立、等概率分布的, 得到目标和噪声的概率分布函数

$$p\{\mathbf{z}_i(k) | \theta_i(k), m_k, \mathbf{Z}^{k-1}\}, p\{\eta_i(k) | \theta_i(k), m_k, \mathbf{Z}^{k-1}\} \text{ 和 } p\{\lambda_i(k) | \theta_i(k), m_k, \mathbf{Z}^{k-1}\};$$

S53, 假设各测量为正确测量的先验概率相同, 得到概率分布函数

$$p\{\theta_i(k) | m_k, \mathbf{Z}^{k-1}\};$$

S54, 由步骤S52、S53得到的概率分布函数计算得到多特征融合的加权系数 $\beta_i$ ;

S55, 由全概率公式更新k时刻目标强度、运动和方位尺度特征的状态值为:

$$\eta(k|k) = \sum_{i=0}^{m_k} \beta_i \eta_i(k|k)$$

$$\mathbf{Z}(k|k) = \sum_{i=0}^{m_k} \beta_i \mathbf{Z}_i(k|k) \circ$$

$$\lambda(k|k) = \sum_{i=0}^{m_k} \beta_i \lambda_i(k|k)$$

8. 根据权利要求7所述的一种基于时空多特征信息的被动声纳目标探测装置, 其特征在于, 所述离线训练模块包括:

特征训练集获取单元, 用于获取被动声纳波束形成后信号串联融合特征训练集, 所述训练集中包含目标子集、噪声子集及其标签信息;

初始化单元, 用于对堆栈自编码器神经网络参数和基于SVM的二分类器参数进行随机初始化;

参数更新单元, 根据所述串联融合特征训练集及其标签信息, 对所述堆栈自编码器神经网络参数和基于SVM的二分类器参数进行训练更新。

## 一种基于时空多特征信息的被动声纳目标探测方法及装置

### 技术领域

[0001] 本发明涉及水声信号处理技术领域,具体是一种基于时空多特征信息的被动声纳目标探测方法及装置。

### 背景技术

[0002] 声波是在水中衰减最小、传播距离最远的信号形式,是目前唯一能进行水下远程探测、通讯的能量形式。利用声波在水中传播能量所发明的声纳仍是迄今为止最有效的水下目标探测工具,广泛用于对水下目标的探测、跟踪、定位和分类。以噪声检测为手段的被动声纳由于本身不发射信号,具有隐蔽自身存在及意图的优势。目标舰艇低频辐射噪声是被动声纳的主要信息来源,但是目标辐射噪声随距离传播其能量十分微弱。此外,被动声纳接收的信号中还包含海洋背景噪声、本舰自噪声,这些信号受海洋环境时空变化影响,在传播过程中又存在各种畸变,其规律极为复杂。因此,被动声纳的目标探测多工作在低信噪比情况下。

[0003] 当前,被动声纳目标探测技术主要分为两类,一类为基于时域信息的检测技术,它通过对系统直接采集的时间采样序列进行变换域处理,提取信号特征参数实现目标探测;另一类为基于空域信息的检测技术,这类技术通过对被动声纳阵列接收的信号计算得到的方位历程图进行处理,从而估计噪声门限,再将各次观测的声强数据与噪声门限进行比较得到信号检测结果。

[0004] 近年来,从水下目标角度出发,通过研究目标信号在产生、传播与接收过程的特征,并利用目标特征进行高增益处理,以提高对目标信号探测性能成为水声目标探测的研究热点之一。大量目标的固有特征、非线性、非高斯特征等得到研究与应用,一定程度提高了水声探测装备的工作能力。然而,这些方法大多仍然基于单一信号特征的使用,在实际复杂海洋环境条件下,单一特征往往会出现起伏、弱化、被干扰、乃至消失的情况,从而造成弱目标难以提取,导致被动声纳检测率不高甚至无法有效地检测出目标。

[0005] 本发明将基于时域信息和空域信息的检测手段相结合,通过对目标信号与噪声的差异化特征进行分析提取与融合处理,可提升被动声纳对微弱目标的探测能力。

### 发明内容

[0006] 为克服现有技术的不足,本发明提供了一种基于时空多特征信息的被动声纳目标探测方法及装置,解决现有技术存在的仅基于单一信号特征探测导致的被动声纳弱目标难以提取、探测准确率低甚至探测失效等问题。

[0007] 本发明解决上述问题所采用的技术方案是:

[0008] 一种基于时空多特征信息的被动声纳目标探测方法,包括以下步骤:

[0009] S1,提取被动声纳波束形成后信号样本集多特征分量,将各特征分量标准化后进行串联特征融合;

[0010] S2,离线训练生成堆栈自编码器神经网络参数、SVM二分类器参数;

[0011] S3,根据步骤S1得到的串联融合特征向量,利用步骤S2得到的堆栈自编码器神经网络参数提取信号低维高层语义特征;

[0012] S4,利用步骤S3得到的信号低维高层语义特征,基于步骤S2得到的SVM二分类器参数,判决信号是否属于目标信号,实现时域微弱目标信号检测;

[0013] S5,根据步骤S4得到的时域目标信号计算生成方位历程图,在方位历程图上基于概率数据关联方法,利用强度、运动和方位尺度信息估计并更新目标检测状态。

[0014] 本发明将基于时域信息和空域信息的检测手段相结合,通过对目标信号与噪声的差异化特征进行分析提取与融合处理,可最大限度地发掘被动声纳系统的潜力,提高其远距离搜索探测微弱目标的能力。

[0015] 作为一种优选的技术方案,所述步骤S1包括以下步骤:

[0016] S11,分别提取波束形成后信号目标段和噪声段的多维度表征的多特征信息,提取的多特征信息包括时域波形特征、频域能量聚点特征、时频图像Renyi熵特征、Mel倒谱特征和混沌特征的两种及以上;

[0017] S12,计算各特征向量的均值和标准差,对特征向量进行标准化;

[0018] S13,将各特征向量前后串联进行特征融合。

[0019] 以上步骤实现了对波束形成后信号目标段和噪声段的多维度表征的多特征信息的串联特征融合。

[0020] 作为一种优选的技术方案,所述步骤S11包括以下步骤:

[0021] S111,分别计算提取信号时域均值、峰值、均方根、峭度因子、裕度指数、偏度指数;

[0022] S112,将步骤S111中各指标串联构成时域波形特征。

[0023] 以上步骤完成了对时域波形特征的提取的功能,提取波束形成后信号集目标段和噪声段时域波形特征。

[0024] 作为一种优选的技术方案,所述步骤S11包括以下步骤:

[0025] S113,计算信号 $x(n)$ 的功率谱 $s(\omega)$ ;

[0026] S114,给定取值宽度 $d$ ,利用滑窗在功率谱序列 $s(\omega)$ 上定步长移动,计算各频点 $\omega_0$ 处信号功率 $P(\omega_0, d)$ ,并求取信号功率的平均值 $P_a$ 和最大值 $P_m$ ,计算公式如下:

$$P(\omega_0, d) = \sum_{\omega=\omega_0-d}^{\omega_0+d} s(\omega)$$

[0027]

$$P_a = \text{mean}\{P(\omega_0, d)\}$$

$$P_m = \max\{P(\omega_0, d)\}$$

[0028] 其中, $\omega_0$ 为功率谱 $s(\omega)$ 上的频率点;

[0029] S115,给定 $\lambda$ 水平值,得到信号功率谱 $s(\omega)$ 的 $\lambda$ 水平能量聚点;计算公式如下:

$$P(\omega_0, d) \geq (1 - f(\lambda))P_a + f(\lambda)P_m$$

[0031] 其中 $f(\lambda)$ 是变量 $\lambda$ 在 $[0, 1] \rightarrow [0, 1]$ 区间的单增函数;



[0032] S116,根据得到的p个 $\lambda$ 水平能量聚点处信号能量,建立频率域p阶特征向量,其中p为正整数且 $p \geq 1$ 。

[0033] 以上步骤完成了对频域能量聚点特征的提取的功能,提取波束形成后信号集目标段和噪声段频域能量聚点特征。

[0034] 作为一种优选的技术方案,所述步骤S11包括以下步骤:

[0035] S117,计算信号 $x(n)$ 的改进B分布,得到二维时频图像;

[0036] S118,根据二维时频图像的亮度等级表达灰度值,将时频图转化为灰度图,进行灰度归一化和中值滤波;

[0037] S119,提取信号多阶灰度图Renyi熵特征。

[0038] 以上步骤完成了对时频图像的Renyi熵特征的提取的功能,对二维时频图像进行预处理,提取预处理后时频图像的Renyi熵特征。

[0039] 作为一种优选的技术方案,所述步骤S11包括以下步骤:

[0040] S120,将时域分帧信号 $x(n)$ 经过N点的离散傅里叶变换,并对得到的频谱 $X(k)$ 取模平方,得到信号的功率谱;

[0041] S121,将Mel频域按人耳敏感程度分为M个Mel滤波器,采用的滤波器为三角滤波器,中心频率为 $f(m)$ , $m=1,2,\dots,M$ ,将信号功率谱通过Mel滤波器组得到Mel频谱,并取Mel频谱的对数能量 $s(m)$ :

$$[0042] \quad S(m) = \ln \left[ \sum_{k=1}^N |X(k)|^2 H_m(k) \right], m = 1, 2, \dots, M,$$

[0043] 其中,N为正整数,M为正整数且 $M \geq 2$ ,m为Mel频谱的对数能量序号, $H_m(k)$ 为第m个滤波器的频谱;

[0044] S122,对数频谱经过离散余弦变换DCT后得到Mel频谱倒谱系数MFCC,作为表征被动声纳信号的一种特征 $c(n)$ :

$$[0045] \quad c(n) = \sum_{m=1}^M S(m) \cos \left( n(m - 0.5) \frac{\pi}{M} \right), (1 \leq n \leq m).$$

[0046] 以上步骤完成了对信号倒谱特征的提取的功能,对波束形成后信号进行分帧处理后,提取信号倒谱特征。

[0047] 作为一种优选的技术方案,所述步骤S11包括以下步骤:

[0048] S123,将相空间中两个无限接近的点 $\beta_{n1}$ 和 $\beta_{n2}$ 间的距离表示为 $||\beta_{n1} - \beta_{n2}|| = \delta_0 \leq 1$ ,在一段时间后,起始于这两点的两个轨迹之间的距离为 $\delta_{\Delta n} = ||\beta_{n1+\Delta n} - \beta_{n2+\Delta n}||$ ,最大Lyapunov指数 $\lambda$ 可表示为:

$$[0049] \quad \delta_{\Delta n} = \delta_0 e^{\lambda \Delta n},$$

[0050] 其中 $\delta_{\Delta n} \leq 1$ , $\Delta n \geq 1$ , $n1, n2$ 为时间采样序号;

[0051] S124,对接收信号进行相空间重构,对给定的距离 $\epsilon$ ,计算关联积分

[0052]  $C(\epsilon)$ ,并通过求解 $\ln(C(\epsilon))$ 对 $\ln(\epsilon)$ 的线性区域的斜率,得到时间序列的关联维数D,

$$[0053] \quad d(\varepsilon) = \frac{\partial \ln C(\varepsilon)}{\partial \ln \varepsilon},$$

$$D = \lim_{\varepsilon \rightarrow 0} d(\varepsilon),$$

[0054] 其中,  $d(\varepsilon)$  为计算过程中的中间量。

[0055] 对波束形成后信号分别计算最大Lyapunov指数和关联维, 建立混沌特征。以上是建立2阶混沌特征的具体过程。

[0056] 作为一种优选的技术方案, 所述步骤S5包括以下步骤:

[0057] S51, 令某时刻  $k$  方位历程图的测量集合为:

$$[0058] \quad \mathbf{z}(k) = \{\mathbf{z}_i(k), \eta_i(k), \lambda_i(k)\}_{i=1}^{m_k},$$

[0059] 其中,  $m_k$  是时域检测处理后跟踪窗内目标测量数,  $\mathbf{z}_i(k)$  是第  $i$  个测量的运动信息测量值,  $\eta_i(k)$  是相应的强度信息测量值,  $\lambda_i(k)$  是相应的目标方位尺度测量值;

[0060] 设  $\mathbf{Z}^k$  为截至到  $k$  时刻的所有有效测量集合:

$$[0061] \quad \mathbf{Z}^k = \{\mathbf{z}(j)\}_{j=1}^k;$$

[0062] 定义  $k$  时刻联合事件:

$$[0063] \quad \theta_i(k) = \{\mathbf{z}_i(k), \eta_i(k), \lambda_i(k) \text{ 是来源于目标的量测}\}, i = 1, \dots, m_k,$$

$$\theta_0(k) = \{k \text{ 时刻所有量测都不来源于目标}\},$$

[0064] 则概率数据关联滤波中各事件的条件概率为:

$$[0065] \quad \beta_i = p\{\theta_i(k) | \mathbf{Z}^k\}$$

$$= p\{\theta_i(k) | \mathbf{z}(k), \eta(k), \lambda(k), m_k, \mathbf{Z}^{k-1}\}$$

$$= \frac{p\{\mathbf{z}(k), \eta(k), \lambda(k) | \theta_i(k), m_k, \mathbf{Z}^{k-1}\} p\{\theta_i(k) | m_k, \mathbf{Z}^{k-1}\}}{p\{\mathbf{z}(k), \eta(k), \lambda(k)\}}$$

[0066] 由于强度、运动和方位尺度特征相互独立, 故有:

$$[0067] \quad p\{\mathbf{z}(k), \eta(k), \lambda(k)\} = p\{\mathbf{z}(k)\} p\{\eta(k)\} p\{\lambda(k)\}$$

$$[0068] \quad p\{\mathbf{z}_i(k), \eta_i(k), \lambda_i(k) | \theta_i(k), m_k, \mathbf{Z}^{k-1}\} =$$

$$p\{\mathbf{z}_i(k) | \theta_i(k), m_k, \mathbf{Z}^{k-1}\} p\{\eta_i(k) | \theta_i(k), m_k, \mathbf{Z}^{k-1}\}$$

$$[0069] \quad p\{\lambda_i(k) | \theta_i(k), m_k, \mathbf{Z}^{k-1}\}$$

[0070] S52, 分别假设目标信号的强度、运动和方位尺度特征服从以预测值为均值的高斯正态分布, 且噪声强度、运动和方位尺度特征是独立、等概率分布的, 得到目标和噪声的概率分布函数

$$[0071] \quad p\{\mathbf{z}_i(k) | \theta_i(k), m_k, \mathbf{Z}^{k-1}\}, p\{\eta_i(k) | \theta_i(k), m_k, \mathbf{Z}^{k-1}\} \text{ 和 } p\{\lambda_i(k) | \theta_i(k), m_k, \mathbf{Z}^{k-1}\};$$

[0072] S53, 假设各测量为正确测量的先验概率相同, 得到概率分布函数

[0073]  $p\{\theta_i(k)|m_k, \mathbf{Z}^{k-1}\};$

[0074] S54,由步骤S52、S53得到的概率分布函数计算得到多特征融合的加权系数 $\beta_i$ ;

[0075] S55,由全概率公式更新k时刻目标强度、运动和方位尺度特征的状态值为:

$$\eta(k|k) = \sum_{i=0}^{m_k} \beta_i \eta_i(k|k)$$

[0076]  $\mathbf{Z}(k|k) = \sum_{i=0}^{m_k} \beta_i \mathbf{Z}_i(k|k)$   
 $\lambda(k|k) = \sum_{i=0}^{m_k} \beta_i \lambda_i(k|k)$

[0077] 以上步骤在方位历程图生成后实现了:在方位历程图上基于概率数据关联方法,更新各时刻目标强度、运动和方位尺度特征的状态值,然后可以利用卡尔曼滤波器预测下一时刻目标状态,并在跟踪窗内持续检测和跟踪目标,抑制虚警。

[0078] 一种基于时空多特征信息的被动声纳目标探测装置,包括特征融合模块、离线训练模块、语义特征提取模块、信号时域检测模块和信号空域检测模块,其中:

[0079] 特征融合模块,用于提取被动声纳波束形成后信号样本集多特征分量,将各特征分量标准化后进行串联特征融合;

[0080] 离线训练模块,利用信号样本串联融合特征向量,离线训练生成堆栈自编码器神经网络参数和SVM二分类器参数;

[0081] 语义特征提取模块,根据信号样本集串联融合特征向量,利用堆栈自编码器神经网络参数提取信号低维高层语义特征;

[0082] 信号时域检测模块,用于利用信号低维高层语义特征,基于SVM二分类器参数,判决信号是否属于目标信号,实现时域微弱目标信号检测;

[0083] 信号空域检测模块,用于计算生成方位历程图,在方位历程图上基于概率数据关联方法,利用强度、运动和方位尺度信息估计并更新目标检测状态。

[0084] 本发明利用以上模块将基于时域信息和空域信息的检测手段相结合,通过对目标信号与噪声的差异化特征进行分析提取与融合处理,提升了被动声纳对微弱目标的探测能力。

[0085] 作为一种优选的技术方案,所述离线训练模块包括:特征训练集获取单元,用于获取被动声纳波束形成后信号串联融合特征训练集,所述训练集中包含目标子集、噪声子集及其标签信息;

[0086] 初始化单元,用于对堆栈自编码器神经网络参数和基于SVM的二分类器参数进行随机初始化;

[0087] 参数更新单元,根据所述串联融合特征训练集及其标签信息,对所述堆栈自编码器神经网络参数和基于SVM的二分类器参数进行训练更新。

[0088] 以上单元用于离线训练生成堆栈自编码器神经网络参数和SVM二分类器参数,对所述堆栈自编码器神经网络参数和SVM二分类器参数进行学习更新。初始化的对象包括各神经元权系数、偏置系数等。

[0089] 本发明相比于现有技术,具有以下有益效果:

[0090] (1) 本发明将基于时域信息和空域信息的检测手段相结合,通过对目标信号与噪

声的差异化特征进行分析提取与融合处理,可最大限度地发掘被动声纳系统的潜力,提高其远距离搜索探测微弱目标的能力。

[0091] (2)本发明利用S11分别提取波束形成后信号目标段和噪声段的多特征信息,完成了提取两种及以上多特征信息的功能;

[0092] (3)本发明利用S111、S112,完成了提取时域波形特征信息的功能;

[0093] (4)本发明利用S113、S114、S115、S116,完成了提取频域能量聚点特征信息的功能;

[0094] (5)本发明利用S117、S118、S119,完成了提取时频图像Renyi熵特征信息的功能;

[0095] (6)本发明利用S120、S121、S122,完成了提取Mel倒谱特征信息的功能;

[0096] (7)本发明利用S123、S124完成了提取混沌特征信息的功能;

[0097] (8)本发明利用S51、S52、S53、S54、S55在方位历程图生成后实现了在方位历程图上基于概率数据关联方法,更新时刻目标强度、运动和方位尺度特征的状态值,然后可以利用卡尔曼滤波器预测下一时刻目标状态,并在跟踪窗内持续检测和跟踪目标,抑制虚警的功能。

## 附图说明

[0098] 图1为本发明所述方法的流程图;

[0099] 图2为本发明所述的堆栈自编码器神经网络结构示意图;

[0100] 图3为本发明所述的信号高层语义特征提取模型结构示意图;

[0101] 图4为本发明所述的装置示意图;

[0102] 图5为本发明实施例中装置原理框图;

[0103] 图6、图7为本发明提供的基于仿真数据的原始方位历程和检测结果对比图;图6、图7横坐标为目标方位角(单位为分),纵坐标为时间(单位为秒);其中,图6为原始方位历程图,图7为目标方位角随时间变化的检测结果图;

[0104] 图8、图9为本发明提供的基于实测数据的原始方位历程和检测结果对比图;图8、图9横坐标为目标方位角(单位为度),纵坐标为时间(单位为秒);

[0105] 其中,图8为原始方位历程图,图9为将检测结果叠加回原方位历程图结果。

## 具体实施方式

[0106] 下面结合实施例及附图,对本发明作进一步的详细说明,但本发明的实施方式不限于此。

[0107] 实施例1

[0108] 如图1至图9所示,一种基于时空多特征信息的被动声纳目标探测方法,包括以下步骤:

[0109] S1,提取被动声纳波束形成后信号样本集多特征分量,将各特征分量标准化后进行串联特征融合;

[0110] S2,离线训练生成堆栈自编码器神经网络参数、SVM二分类器参数;

[0111] S3,根据步骤S1得到的串联融合特征向量,利用步骤S2得到的堆栈自编码器神经网络参数提取信号低维高层语义特征;

[0112] S4,利用步骤S3得到的信号低维高层语义特征,基于步骤S2得到的SVM二分类器参数,判决信号是否属于目标信号,实现时域微弱目标信号检测;

[0113] S5,根据步骤S4得到的时域目标信号计算生成方位历程图,在方位历程图上基于概率数据关联方法,利用强度、运动和方位尺度信息估计并更新目标检测状态。

[0114] 本发明将基于时域信息和空域信息的检测手段相结合,通过对目标信号与噪声的差异化特征进行分析提取与融合处理,可最大限度地发掘被动声纳系统的潜力,提高其远距离搜索探测微弱目标的能力。在本发明实施例中,所述堆栈自编码器神经网络是预先通过多个训练样本数据基于BP算法训练生成的,具有良好的信号高层语义特征提取能力。

[0115] 作为本发明的一个优选实施例,所述通过多个训练样本数据基于BP算法训练生成堆栈自编码器神经网络的步骤为:

[0116] (a)获取波束形成后信号串联融合特征训练集,所述训练集中包含目标子集、噪声子集及其标签信息;

[0117] (b)对堆栈自编码器神经网络模型参数进行随机初始化;

[0118] (c)基于自编码器神经网络自监督机制并根据所述串联融合特征训练集,对所述自编码器网络参数进行更新,实现利用低维高层语义特征对输入特征向量的重构,直至满足预设收敛条件;

[0119] 栈式自编码器神经网络结构可分为编码器和解码器,在对输入样本进行学习时,其训练目标是根据目标表达对输入样本进行重构,因此训练时把目标输出设置为输入信号自身。通过最小化输入样本和复原样本之间的误差来优化网络参数,各编码器神经元的输出值则是通过神经网络加工处理后得到的信号不同层次的抽象特征。

[0120] 栈式自编码器神经网络训练样本输入信号为 $x$ ,输出信号为 $y$ ,使用反向传播BP算法对神经网络中的权值进行不断迭代调整和更新,使得 $y$ 能尽可能接近 $x$ 。一般情况下, $y$ 不是输入变量 $x$ 的精确重构,而是尽可能从概率分布上逼近 $x$ ,因此自编码器神经网络的目标函数可表示为对下式重构误差的优化:

[0121]  $\min(J(x,y))$

[0122] 其中 $J$ 为具体的代价函数,可选择交叉熵等经典代价函数,也可根据具体情况自定义代价函数。

[0123] (d)当堆栈自编码神经网络训练完成后,只保留编码器,得到实现深度抽象特征提取的神经网络结构,其输出向量为信号低维高层语义特征。

[0124] 作为一种优选的技术方案,所述步骤S1包括以下步骤:

[0125] S11,分别提取波束形成后信号目标段和噪声段的多维度表征的多特征信息,提取的多特征信息包括时域波形特征、频域能量聚点特征、时频图像Renyi熵特征、Mel倒谱特征和混沌特征的两种及以上;

[0126] S12,计算各特征向量的均值和标准差,对特征向量进行标准化;

[0127] S13,将各特征向量前后串联进行特征融合。

[0128] 以上步骤实现了对波束形成后信号目标段和噪声段的多维度表征的多特征信息的串联特征融合。

[0129] 作为一种优选的技术方案,所述步骤S11包括以下步骤:

[0130] S111,分别计算提取信号时域均值、峰值、均方根、峭度因子、裕度指数、偏度指数;



[0131] S112,将步骤S111中各指标串联构成时域波形特征。

[0132] 以上步骤完成了对时域波形特征的提取的功能,提取波束形成后信号集目标段和噪声段时域波形特征。

[0133] 作为一种优选的技术方案,所述步骤S11包括以下步骤:

[0134] S113,计算信号 $x(n)$ 的功率谱 $s(\omega)$ ;

[0135] S114,给定取值宽度 $d$ ,利用滑窗在功率谱序列 $s(\omega)$ 上定步长移动,计算各频点 $\omega_0$ 处信号功率 $P(\omega_0, d)$ ,并求取信号功率的平均值 $P_a$ 和最大值 $P_m$ ,计算公式如下:

$$P(\omega_0, d) = \sum_{\omega=\omega_0-d}^{\omega_0+d} s(\omega)$$

[0136]

$$P_a = \text{mean}\{P(\omega_0, d)\}$$

$$P_m = \text{max}\{P(\omega_0, d)\}$$

[0137] 其中, $\omega_0$ 为功率谱 $s(\omega)$ 上的频率点;

[0138] S115,给定 $\lambda$ 水平值,得到信号功率谱 $s(\omega)$ 的 $\lambda$ 水平能量聚点;计算公式如下:

$$P(\omega_0, d) \geq (1 - f(\lambda))P_a + f(\lambda)P_m$$

[0140] 其中 $f(\lambda)$ 是变量 $\lambda$ 在 $[0, 1] \rightarrow [0, 1]$ 区间的单增函数;作为优选,本发明中取

$$f(\lambda) = 2\lambda^2$$

[0142] S116,根据得到的 $p$ 个 $\lambda$ 水平能量聚点处信号能量,建立频率域 $p$ 阶特征向量,其中 $p$ 为正整数且 $p \geq 1$ 。

[0143] 以上步骤完成了对频域能量聚点特征的提取的功能,提取波束形成后信号集目标段和噪声段频域能量聚点特征。

[0144] 作为一种优选的技术方案,所述步骤S5包括以下步骤:

[0145] S117,计算信号 $x(n)$ 的改进B分布,得到二维时频图像;

[0146] S118,根据二维时频图像的亮度等级表达灰度值,将时频图转化为灰度图,进行灰度归一化和中值滤波;

[0147] S119,提取信号多阶灰度图Renyi熵特征。

[0148] 本实施例中选提取信号3阶、5阶、7阶、9阶、11阶、13阶灰度图Renyi熵特征。

[0149] 以上步骤完成了对时频图像的Renyi熵特征的提取的功能,对二维时频图像进行预处理,提取预处理后时频图像的Renyi熵特征。

[0150] 作为一种优选的技术方案,所述步骤S11包括以下步骤:

[0151] S120,将时域分帧信号 $x(n)$ 经过 $N$ 点的离散傅里叶变换,并对得到的频谱 $X(k)$ 取模平方,得到信号的功率谱;

[0152] S121,将Mel频域按人耳敏感程度分为 $M$ 个Mel滤波器,采用的滤波器为三角滤波器,中心频率为 $f(m)$ , $m=1, 2, \dots, M$ ,将信号功率谱通过Mel滤波器组得到Mel频谱,并取Mel

频谱的对数能量 $s(m)$ ：

$$[0153] \quad S(m) = \ln \left[ \sum_{k=1}^N |X(k)|^2 H_m(k) \right], m = 1, 2, \dots, M,$$

[0154] 其中, $N$ 为正整数, $M$ 为正整数且 $M \geq 2$ , $m$ 为Mel频谱的对数能量序号, $H_m(k)$ 为第 $m$ 个滤波器的频谱;

[0155] S122,对数频谱经过离散余弦变换DCT后得到Mel频谱倒谱系数MFCC,作为表征被动声纳信号的一种特征 $c(n)$ ：

$$[0156] \quad c(n) = \sum_{m=1}^M S(m) \cos \left( n(m - 0.5) \frac{\pi}{M} \right), (1 \leq n \leq m).$$

[0157] 以上步骤完成了对信号倒谱特征的提取的功能,对波束形成后信号进行分帧处理后,提取信号倒谱特征。

[0158] 作为一种优选的技术方案,所述步骤S11包括以下步骤:

[0159] S123,将相空间中两个无限接近的点 $\beta_{n1}$ 和 $\beta_{n2}$ 间的距离表示为 $||\beta_{n1} - \beta_{n2}|| = \delta_0 \leq 1$ ,在一段时间后,起始于这两点的两个轨迹之间的距离为 $\delta_{\Delta n} = ||\beta_{n1+\Delta n} - \beta_{n2+\Delta n}||$ ,最大Lyapunov指数 $\lambda$ 可表示为:

$$[0160] \quad \delta_{\Delta n} = \delta_0 e^{\lambda \Delta n},$$

[0161] 其中 $\delta_{\Delta n} \leq 1$ ,  $\Delta n \geq 1$ ,  $n1, n2$ 为时间采样序号;

[0162] S124,对接收信号进行相空间重构,对给定的距离 $\epsilon$ ,计算关联积分

[0163]  $C(\epsilon)$ ,并通过求解 $\ln(C(\epsilon))$ 对 $\ln(\epsilon)$ 的线性区域的斜率,得到时间序列的关联维数 $D$ ,

$$[0164] \quad d(\epsilon) = \frac{\partial \ln C(\epsilon)}{\partial \ln \epsilon},$$

$$D = \lim_{\epsilon \rightarrow 0} d(\epsilon),$$

[0165] 其中, $d(\epsilon)$ 为计算过程中的中间量。

[0166] 对波束形成后信号分别计算最大Lyapunov指数和关联维,建立混沌特征。以上是建立2阶混沌特征的具体过程。

[0167] 作为一种优选的技术方案,所述步骤S5包括以下步骤:

[0168] S51,令某时刻 $k$ 方位历程图的测量集合为:

$$[0169] \quad \mathbf{z}(k) = \{ \mathbf{z}_i(k), \eta_i(k), \lambda_i(k) \}_{i=1}^{m_k},$$

[0170] 其中, $m_k$ 是时域检测处理后跟踪窗内目标测量数, $\mathbf{z}_i(k)$ 是第 $i$ 个测量的运动信息测量值, $\eta_i(k)$ 是相应的强度信息测量值, $\lambda_i(k)$ 是相应的目标方位尺度测量值;

[0171] 设 $Z^k$ 为截至到 $k$ 时刻的所有有效测量集合:

$$[0172] \quad \mathbf{Z}^k = \{ \mathbf{z}(j) \}_{j=1}^k;$$

[0173] 定义 $k$ 时刻联合事件:

$$[0174] \quad \theta_i(k) = \{ \mathbf{z}_i(k), \eta_i(k), \lambda_i(k) \text{ 是来源于目标的量测} \}, i = 1, \dots, m_k,$$

$$\theta_0(k) = \{ k \text{ 时刻所有量测都不来源于目标} \},$$

[0175] 则概率数据关联滤波中各事件的条件概率为:

$$\begin{aligned} \beta_i &= p\{\theta_i(k)|Z^k\} \\ &= p\{\theta_i(k)|z(k), \eta(k), \lambda(k), m_k, Z^{k-1}\} \\ [0176] &= \frac{p\{z(k), \eta(k), \lambda(k)|\theta_i(k), m_k, Z^{k-1}\} p\{\theta_i(k)|m_k, Z^{k-1}\}}{p\{z(k), \eta(k), \lambda(k)\}} \end{aligned}$$

[0177] 由于强度、运动和方位尺度特征相互独立,故有:

$$[0178] \quad p\{z(k), \eta(k), \lambda(k)\} = p\{z(k)\}p\{\eta(k)\}p\{\lambda(k)\}$$

$$[0179] \quad p\{z_i(k), \eta_i(k), \lambda_i(k)|\theta_i(k), m_k, Z^{k-1}\} =$$

$$p\{z_i(k)|\theta_i(k), m_k, Z^{k-1}\} p\{\eta_i(k)|\theta_i(k), m_k, Z^{k-1}\}$$

$$[0180] \quad p\{\lambda_i(k)|\theta_i(k), m_k, Z^{k-1}\}$$

[0181] S52, 分别假设目标信号的强度、运动和方位尺度特征服从以预测值为均值的高斯正态分布,且噪声强度、运动和方位尺度特征是独立、等概率分布的,得到目标和噪声的概率分布函数

$$[0182] \quad p\{z_i(k)|\theta_i(k), m_k, Z^{k-1}\}, p\{\eta_i(k)|\theta_i(k), m_k, Z^{k-1}\} \text{和} p\{\lambda_i(k)|\theta_i(k), m_k, Z^{k-1}\};$$

[0183] S53, 假设各测量为正确测量的先验概率相同,得到概率分布函数

$$[0184] \quad p\{\theta_i(k)|m_k, Z^{k-1}\};$$

[0185] S54, 由步骤S52、S53得到的概率分布函数计算得到多特征融合的加权系数 $\beta_i$ ;

[0186] S55, 由全概率公式更新k时刻目标强度、运动和方位尺度特征的状态值为:

$$\eta(k|k) = \sum_{i=0}^{m_k} \beta_i \eta_i(k|k)$$

$$[0187] \quad Z(k|k) = \sum_{i=0}^{m_k} \beta_i Z_i(k|k)$$

$$\lambda(k|k) = \sum_{i=0}^{m_k} \beta_i \lambda_i(k|k)$$

[0188] 以上步骤在方位历程图生成后实现了:在方位历程图上基于概率数据关联方法,更新时刻目标强度、运动和方位尺度特征的状态值,然后可以利用卡尔曼滤波器预测下一时刻目标状态,并在跟踪窗内持续检测和跟踪目标,抑制虚警。

[0189] 实施例2

[0190] 如图1至图9所示,一种基于时空多特征信息的被动声纳目标探测装置,包括特征融合模块、离线训练模块、语义特征提取模块、信号时域检测模块和信号空域检测模块,其中:

[0191] 特征融合模块,用于提取被动声纳波束形成后信号样本集多特征分量,将各特征分量标准化后进行串联特征融合;

[0192] 离线训练模块,利用信号样本串联融合特征向量,离线训练生成堆栈自编码器神

神经网络参数和SVM二分类器参数；

[0193] 语义特征提取模块,根据信号样本集串联融合特征向量,利用堆栈自编码器神经网络参数提取信号低维高层语义特征;信号时域检测模块,用于利用信号低维高层语义特征,基于SVM二分类器参数,判决信号是否属于目标信号,实现时域微弱目标信号检测;

[0194] 信号空域检测模块,用于计算生成方位历程图,在方位历程图上基于概率数据关联方法,利用强度、运动和方位尺度信息估计并更新目标检测状态。

[0195] 本发明利用以上模块将基于时域信息和空域信息的检测手段相结合,通过对目标信号与噪声的差异化特征进行分析提取与融合处理,可最大限度地发掘被动声纳系统的潜力,提高其远距离搜索探测微弱目标的能力。

[0196] 作为进一步优选,离线训练模块用于将特征融合模块输入的串联融合特征向量集划分为目标子集和噪声子集,对各子集中样本标注标签信息,并将串联融合特征向量集及标签信息进行UDP数据包打包并上传至上位机,用于训练生成堆栈自编码器神经网络和SVM二分类器神经网络参数;信号时域检测模块,用于接收上位机下发的网络和分类器模型参数,基于训练生成的堆栈自编码器及SVM模型,对输入目标信号进行二分类判决,实现微弱目标的时域探测;信号空域检测模块,用于计算生成方位历程图,利用概率数据关联方法,基于强度、运动和方位尺度信息进一步更新时域检测结果,抑制虚警,得到最终的检测结果。

[0197] 作为一种优选的技术方案,所述离线训练模块包括:

[0198] 特征训练集获取单元,用于获取被动声纳波束形成后信号串联融合特征训练集,所述训练集中包含目标子集、噪声子集及其标签信息;

[0199] 初始化单元,用于对堆栈自编码器神经网络参数和基于SVM的二分类器参数进行随机初始化;

[0200] 参数更新单元,根据所述串联融合特征训练集及其标签信息,对所述堆栈自编码器网络参数和基于SVM的二分类器参数进行训练更新。

[0201] 以上单元用于离线训练生成堆栈自编码器神经网络参数和SVM二分类器参数,对所述堆栈自编码器网络参数和SVM二分类器参数进行学习更新。初始化的对象包括各神经元权系数、偏置系数等。

[0202] 作为进一步优选,特征训练集获取单元接收经UDP包发送的被动声纳波束形成后信号串联融合特征训练集,所述训练集中包含多个目标段和噪声段训练样本,对训练样本人工标注标签信息;初始化单元对堆栈自编码器及SVM二分类器模型参数进行随机初始化;参数更新单元基于上位机GPU,利用串联融合特征训练集对所述堆栈自编码器网络参数进行调整,实现利用低维高层语义特征对输入特征向量的重构,直至满足预设收敛条件;在自编码器顶层编码层添加SVM二分类器,利用标签信息对分类参数进行微调,直至满足收敛条件。此还包含了生成SVM二分类器参数的具体单元。

[0203] 作为进一步优选,特征训练集获取单元包含至少一片FPGA处理芯片,所述FPGA处理芯片采用Xilinx Zynq7100芯片,包含PS和PL两部分,其中PS部分进行网络通信控制等;PL部分负责实现信号多特征分量提取、特征标准化、串联特征融合等操作。

[0204] 作为进一步优选,信号时域检测模块包含至少一片Nor Flash片外存储芯片和一片FPGA芯片;所述Nor Flash片外存储芯片为Micron N25Q0128A13ES芯片,用于存储上位机

下发的堆栈自编码器网络和SVM分类器参数;所述FPGA芯片采用Xilinx XC7VX690T芯片,可实现网络接口控制及接收上位机下发的控制指令;在运行时加载特征提取模块发送的目标信号串联融合特征及所述Nor Flash片外存储芯片保存的网络、分类器参数,通过网络前向运算,实现对输入信号的判决检测。

[0205] 在本发明实施例中,所述堆栈自编码器网络和SVM分类器是预先通过大量的样本训练数据基于BP算法训练生成的,具有良好的高层语义特征提取能力和信号噪声判决分类能力;

[0206] 作为进一步优选,信号空域检测模块包含至少一片DSP芯片,所述DSP芯片为TMS320C6657芯片,在运行时计算生成方位历程图,根据目标和噪声运动、强度和方位尺度三特征的差异性,推导跟踪窗内时域各检测结果的多特征融合概率,估计并更新目标检测状态,抑制虚警,得到最终的检测结果。

[0207] 实施例3

[0208] 如图1至图9所示,结合实施例1、实施例2,本实施例结合数据处理试验对比对本发明应用效果做具体描述:

[0209] 参见图6,为针对被动声纳模拟信号数据进行的仿真试验。根据参数设置,目标从83km运动到194km,由于海洋噪声较强,整个场景幅度起伏较大。且随着距离增加,目标辐射噪声减弱,感兴趣目标航迹逐渐淹没在噪声中。由图7可见,本发明方法能在整个时间历程内保证对目标航迹清晰地检出,且虚警较少。

[0210] 结合图7,为某外场试验实录数据处理结果。由图8可知,该数据中除了感兴趣目标外,在波束2和5处还存在其它较强目标,并且背景噪声较强,使得整个接收信号的强度起伏较大。由于强噪声干扰及目标距离较远,目标航迹基本不可见,通过人眼对其进行辨识难度很大。由图9可见,采用本发明方法处理后,可对有效检测出感兴趣弱目标,在整个时间历程内该目标航迹均十分明晰。

[0211] 如上所述,可较好地实现本发明。

[0212] 以上所述,仅是本发明的较佳实施例而已,并非对本发明作任何形式上的限制,依据本发明的技术实质,在本发明的精神和原则之内,对以上实施例所作的任何简单的修改、等同替换与改进等,均仍属于本发明技术方案的保护范围之内。



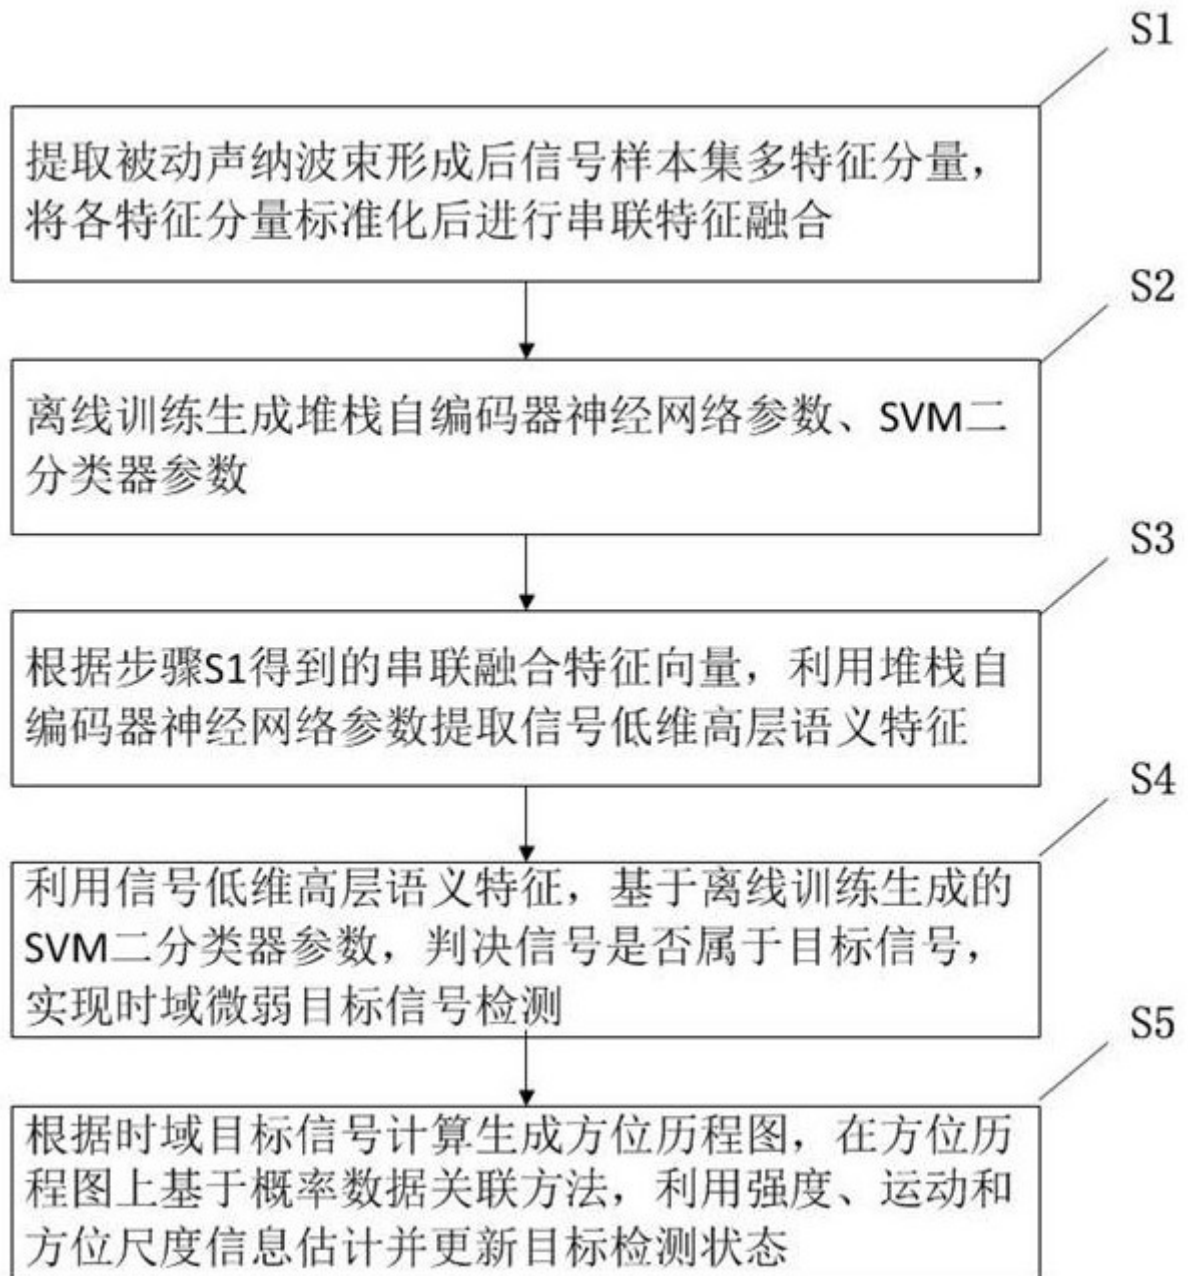


图1




图2

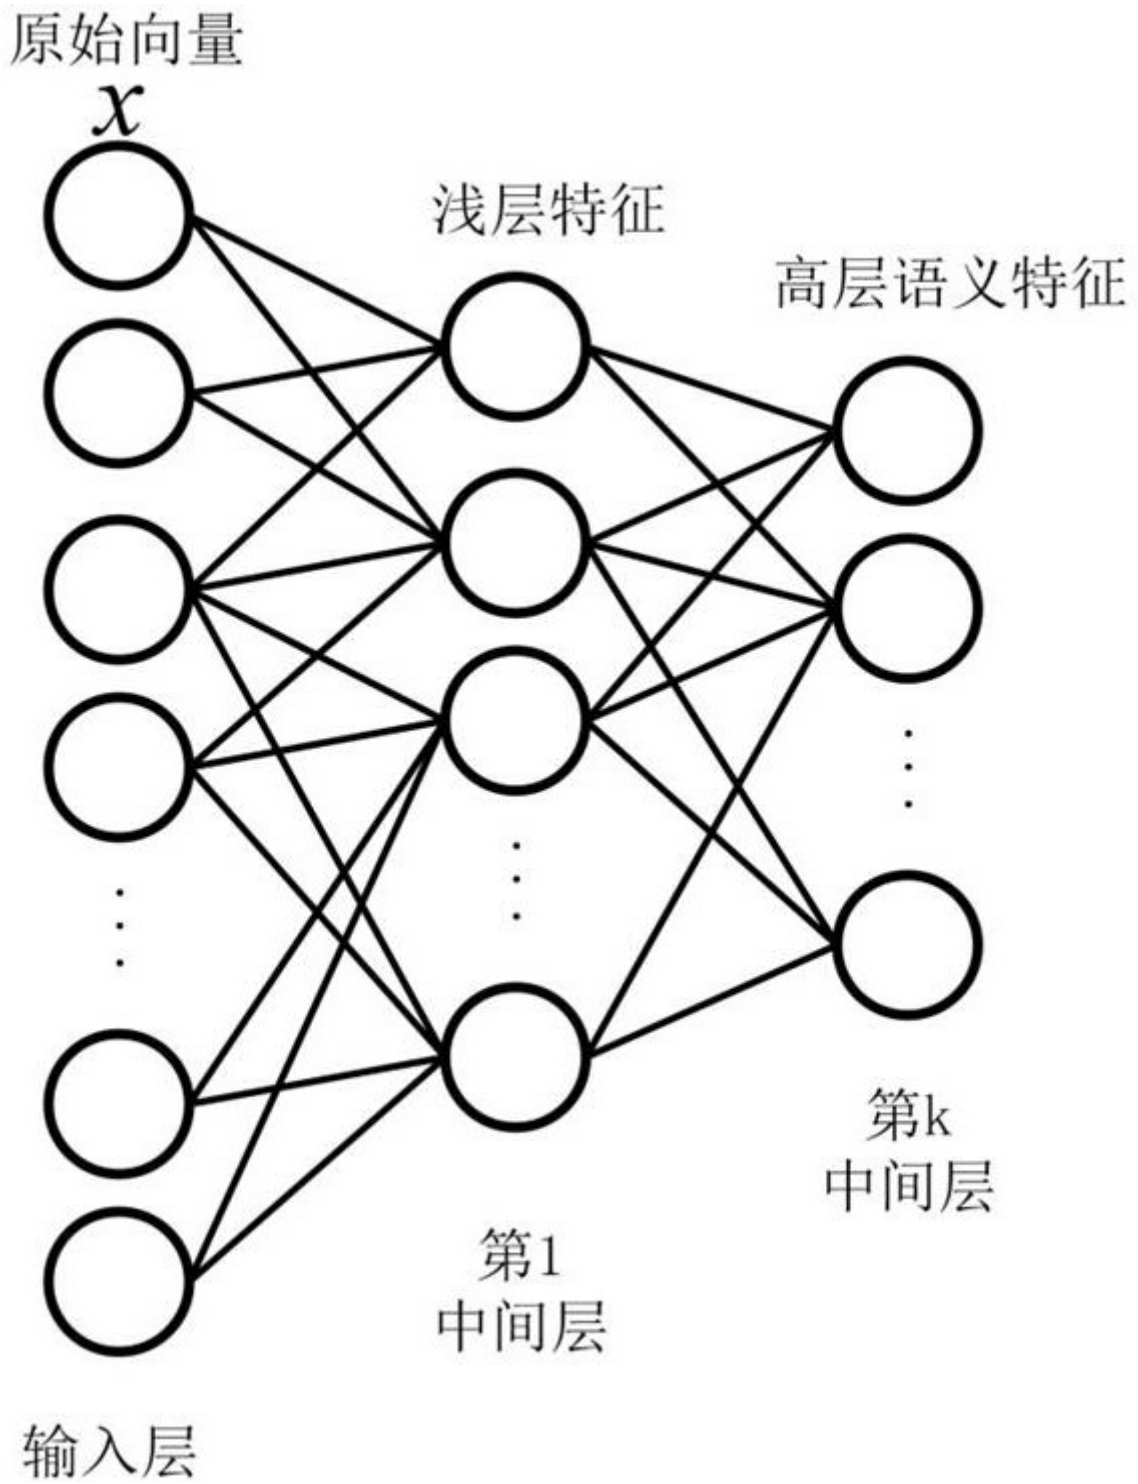


图3




图4

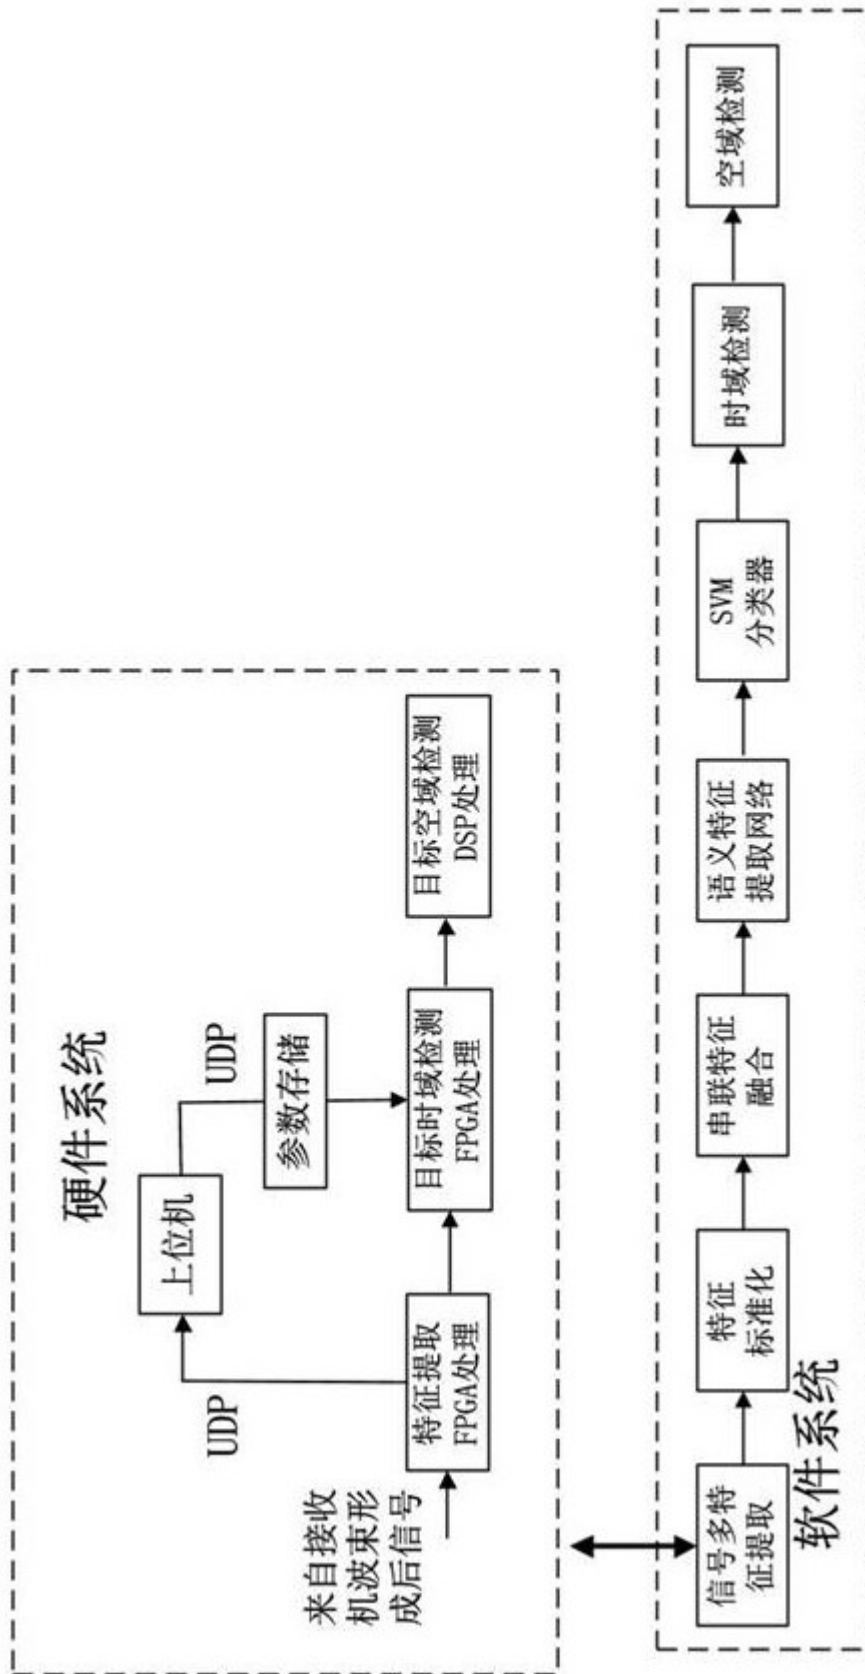


图5






图6




图7




图8




图9