

基于前馈神经网络的 非合作 PCMA 信号盲分离算法

郭一鸣¹, 彭 华¹, 杨 勇²

(1. 解放军信息工程大学信息工程学院, 河南郑州 450002; 2. 61886 部队, 北京 100084)

摘 要: 针对非合作接收 PCMA 混合信号盲分离中高复杂度束缚, 提出一种基于前馈神经网络的分离算法, 通过搭建神经网络分离平台, 规避传统的发送符号遍历思想, 实现 PCMA 混合信号低复杂度高性能盲分离. 仿真实验表明, 神经网络能够极大挖掘信号内在信息, 针对 QPSK 调制 PCMA 混合信号, 在信噪比 7dB 时误比特率达到 10^{-3} 数量级, 并伴随着较 PSP 分离算法算术平方根级别的复杂度降低.

关键词: 神经网络; 非合作; 成对载波多址复用; 盲分离

中图分类号: TN911.7 **文献标识码:** A **文章编号:** 0372-2112 (2019)02-0302-06

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2019.02.007

Blind Separation Algorithm for Non-cooperative PCMA Signal Based on Feedforward Neural Network

GUO Yi-ming¹, PENG Hua¹, YANG Yong²

(1. PLA Information Engineering University, Zhengzhou, Henan 450002, China; 2. 61886 Troops of PLA, Beijing 100084, China)

Abstract: Aiming at the high complexity in blind separation of PCMA mixed signals with non-cooperative reception, the separation algorithm based on feedforward neural network is proposed. By setting up a neural network separation platform and avoiding the traditional idea of maximum a posteriori probability, the blind separation algorithm with low complexity and high performance can be realized. Simulation results show that the neural network can greatly exploit the intrinsic information of the signal, and 10^{-3} orders of bit error rate performance is achieved with 7 dB of signal-to-noise ratio to QPSK modulated PCMA signals, accompanied by the declining complexity of the arithmetic square root level compared with the PSP algorithm.

Key words: neural network; non-cooperative; Paired Carrier Multiple Access (PCMA); blind separation

1 引言

成对载波多址复用 (Paired Carrier Multiple Access, PCMA) 是一种用于提高卫星通信容量的技术, 目前已得到广泛的应用^[1], 其非合作接收混合信号盲分离只能利用单通道两路数字同频混合信号盲分离方法来实现^[2,3].

针对 PCMA 信号单通道接收的特点, 历经了基于自干扰信号波形重构抵消算法^[4,5]、基于独立分量分析算法^[6]等传统分离算法的研究, 此类算法存在需要先分离后解调且解调性能受分离误差影响的缺点. 当前主流算法有粒子滤波算法与逐留存路径处理 (Per-Survivor Processing, PSP) 算法及其改进算法^[7-11], 此类算法利用联合信道参数估计和序列检测的思想实现分离, 计算

量较大, 复杂度随调制阶数呈指数增长, 因此当前实际接收 PCMA 信号盲分离课题处于瓶颈, 关键问题是如何突破高复杂度束缚.

BP (back propagation) 前馈神经网络是一种多层前馈神经网络^[12-14]. 神经网络在分离混合信号过程中不存在信号分量遍历检测, 仅在最优路径度量处理过程中存在单路信号符号遍历, 相较于传统 PSP 算法两路信号符号遍历具有复杂度指数级下降优势, 因此可以有效突破高复杂度束缚.

2 信号模型

PCMA 系统中, 地面站接收到两个 MPSK 或 QAM 混合而成的调制信号, 将接收信号按符号速率采样, 如式(1)

$$y_k = h_1 e^{j(2\pi f_1 k T_s + \theta_1)} x_{1,k} + h_2 e^{j(2\pi f_2 k T_s + \theta_2)} x_{2,k} + v_k \quad (1)$$

其中, v_k 为高斯白噪声, 方差 σ^2 ; $x_{1,k}$ 和 $x_{2,k}$ 分别为两路信号分量调制波形, T_s 为符号周期. 假设两路信号的调制方式相同, 且两路信号相互统计独立, 则 $x_{i,k}$ 可以表示为

$$x_{i,k} = \sum_{m=-L_c}^{L_c} a_{i,m} g_i(kT_s - mT_s + \tau_i) \quad (2)$$

其中 h_i , f_i , θ_i 和 τ_i ($i = 1, 2$) 分别是第 i 路信号分量幅度、频偏、载波初始相位和定时偏差; $a_{1,k}$ 和 $a_{2,k}$ ($k = 0, 1, \dots$) 分别为两路发送信号序列, 其取值与调制方式有关; $g_i(\cdot)$ 是等效的信道脉冲响应, 包括成型滤波器、信道滤波器以及匹配滤波器等, 滤波器持续的有效区间为 $[-L_c T_s, L_c T_s]$. 定义 $\mathbf{G}_{i,k} = \{h_i e^{j(2\pi f_i k T_s + \theta_i)} g_i(kT_s + L_c T_s + \tau_i; kT_s - L_c T_s + \tau_i)\}$, $\mathbf{a}_{i,k} = \{a_{i,k-L_c}, a_{i,k-L_c+1}, \dots, a_{i,k+L_c}\}$, 则接收信号可写为式(3)

$$y_k = \mathbf{G}_{1,k}^T \mathbf{a}_{1,k} + \mathbf{G}_{2,k}^T \mathbf{a}_{2,k} + v_k \quad (3)$$

PCMA 信号盲分离即在仅获取接收序列 $\{y_k, k=0,$

$1, \dots\}$ 的前提下成功解调得到发送信息 $a_{i,k}$.

3 基于前馈神经网络分离算法

如图 1 所示, 分离算法包含三个模块, 分别是预处理模块, 神经网络分离模块与最优路径判决模块. 预处理模块实现参数估计, 利用频偏估计结果去除第一路信号分量频偏生成辅助信号, 通过第二路信号分量发送符号遍历重构去频偏得到特征辅助信号, 其目的是将辅助信号中第二路频偏项消除, 将其作为神经网络分离模块的输入数据; 神经网络分离模块负责训练神经网络, 训练出当前参数条件下两路发送信号分量与接收混合信号间映射关系, 并且接收预处理模块提供的特征辅助信号, 得到与实际接收 PCMA 混合信号对应的发送端两路信号分量信息; 最优路径判决模块对神经网络输出数据进行逐路径追踪, 作为神经网络分离模块的辅助模块, 根据最优路径度量判决两路信号分量发送信息.

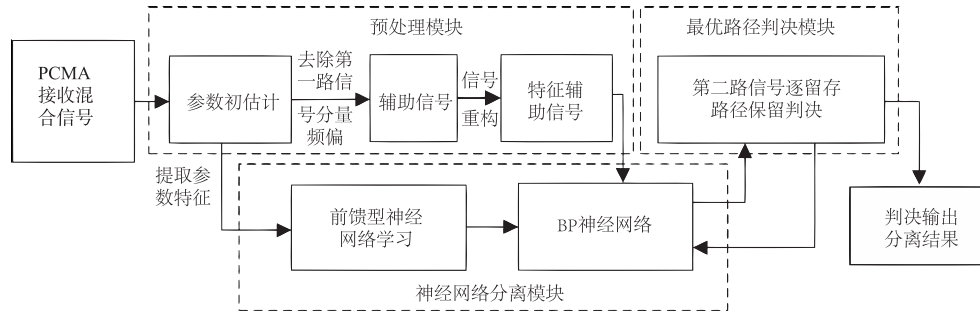


图1 本文算法流程图

3.1 预处理模块

针对 PCMA 接收混合信号进行功率归一化与参数估计^[15-20], 得到两路信号分量 h_i , f_i , θ_i 和 τ_i ($i = 1, 2$) 等信息. 去除第一路频偏得到辅助信号 z_k

$$\begin{aligned} z_k &= y_k e^{-j2\pi f_1 k T_s} \\ &= h_1 e^{j\theta_1} x_{1,k} + h_2 e^{j[2\pi(f_2 - f_1)k T_s + \theta_2]} x_{2,k} + v_k e^{-j2\pi f_1 k T_s} \end{aligned} \quad (4)$$

在得到 z_k 的同时, 将 h_i , θ_i 和 τ_i ($i = 1, 2$) 等信息带入神经网络分离模块参与神经网络训练过程, 具体处理过程将在神经网络盲分离模块中详细介绍.

预处理模块主要作用是得到特征辅助信号 \tilde{z}_k , 即神经网络模块输入信号, 其是由 z_k 对第二路发送符号分量遍历得到的一组信号, 以期得到去除 z_k 中 $(f_2 - f_1)$ 影响的特征辅助信号. 由预处理模块指导生成的神经网络可实现当前 PCMA 信号参数 (h_i , θ_i 和 τ_i) 下混合信号的分离, 但由式(4)可见, 辅助信号 z_k 中还存在 $(f_2 - f_1)$ 影响, 需要对 z_k 进行处理得到特征辅助信号 \tilde{z}_k

$$\tilde{z}_k = z_k + h_2 (1 - e^{j[2\pi(f_2 - f_1)k T_s + \theta_2]}) \tilde{x}_{2,k} \quad (5)$$

其中 $\tilde{x}_{2,k}$ 为第二路信号输入, 特征辅助信号 \tilde{z}_k 仅受第二

路发送符号 $a_{2,k} = \{a_{2,k-L_c}, a_{2,k-L_c+1}, \dots, a_{2,k+L_c}\}$ 的影响, 则特征辅助信号 \tilde{z}_k 存在 M^{2L_c+1} 种可能取值, 记为 \tilde{z}_k^p ($p = 1, 2, \dots, M^{2L_c+1}$), 针对假设的 \tilde{z}_k^p 分别进行倍数 N 过采样接收, 则 \tilde{z}_k^p 第 k 个采样点为

$$\tilde{z}_{k,n}^p = z_{k,n} + h_2 (1 - e^{j[2\pi(f_2 - f_1)k T_s n/N + \theta_2]}) \tilde{x}_{2,k,n}^p \quad (6)$$

其中 $n = 1, 2, \dots, N$. 将其功率归一化后作为神经网络模块输入.

3.2 神经网络分离模块

神经网络分离模块首先利用预处理模块提取的参数 (h_i , θ_i 和 τ_i) 用于训练神经网络, 具体过程如下: 由信号模型可知, 接收信号 y_k 对应滤波器窗长内发送符号 $\mathbf{a}_{i,k} = \{a_{i,k-L_c}, \dots, a_{i,k+L_c}\}$, 则每个接收混合信号符号存在 $M^{2(2L_c+1)}$ 种可能取值, 记为 Y^m ($m = 1, 2, \dots, M^{2(2L_c+1)}$), 将 $\mathbf{a}_{i,k}$ 依据滤波器采样中心抽头位置 $a_{i,k}$ 划分为 M^2 种情况 $\mathbf{a}_{i,k}^q$ ($q = 1, \dots, M^2$). 针对 Y^m 分别采用过采样倍数 N 接收, 记为 Y_n^m ($n = 1, 2, \dots, N$), 将其功率归一化后作为输入端输入. 输出端定义为 M^2 维冲击向量矩阵 \mathbf{V} , 分别对应 $\mathbf{a}_{i,k}^q$ ($q = 1, \dots, M^2$), 以期实现接收混合信号的有效分

类判决.

定义神经网络输入输出后,利用复数值神经网络批处理梯度算法实现神经网络训练过程. BP 神经网络主要包括信号前向传递与误差反向传播两个过程. 在前向传递中,输入信号从输入层经隐含层逐层处理,直至输出层. 每一层的神经元状态只影响下一层的神经元状态. 如果输出层得不到期望输出,则转入反向传播,根据预测误差调整网络权值和阈值,从而使得神经网络预测输出不断接近期望输出. BP 神经网络拓扑结构如图 2 所示.




图2 BP神经网络拓扑结构图

如图 2 所示,本文构建一个具有 N 个输入节点, L 层隐含层和 M^2 个输出节点的多层复数值神经网络,每层隐含层分别含有 $p_i (i=1,2,\dots,L)$ 个隐节点. 记连接第 $j-1$ 层与第 j 层隐含层间权值矩阵为 $\{W_j = W_{j,R} + iW_{j,I}, 1 < j \leq L\}$, W_1 与 W_{L+1} 分别表示输入层与第 1 层隐含层、第 L 层隐含层与输出层间权值矩阵. 给定输入信号 $Y^m = Y_R^m + iY_I^m = (Y_1^m, Y_2^m, \dots, Y_N^m)$, 第一层隐含层输入为

$$I_1 = I_{1,R} + iI_{1,I} = W_1 Y^m + B_1 \quad (7)$$

其中 $B_1 = B_{1,R} + iB_{1,I}$ 为阈值矩阵. 第一层隐含层输出为

$$Q_1 = Q_{1,R} + iQ_{1,I} = f(I_{1,R}) + if(I_{1,I}) \quad (8)$$

其中 $f(\cdot)$ 为隐含层传递函数,本文选取 Sigmoid 函数,

即 $f(x) = \frac{1}{1 + e^{-x}}$. 同理可得第 l 层隐含层 ($1 < l \leq L$) 输入与输出分别为

$$I_l = I_{l,R} + iI_{l,I} = W_l Q_{l-1} + B_l \quad (9)$$

$$Q_l = Q_{l,R} + iQ_{l,I} = f(I_{l,R}) + if(I_{l,I}) \quad (10)$$

最终输出端输入与输出分别为

$$I_{L+1} = I_{L+1,R} + iI_{L+1,I} = W_{L+1} Q_L + B_{L+1} \quad (11)$$

$$Q_{L+1} = Q_{L+1,R} + iQ_{L+1,I} = g(I_{L+1,R}) + ig(I_{L+1,I}) \quad (12)$$

其中 $g(\cdot)$ 为线性实值函数. 假设网络提供的训练样本集为 $\{Y, V\}$, 分别代表输入与期望输出,则批处理梯度算法的复数值神经网络的误差函数为

$$\begin{aligned} E(W, B) &= \frac{1}{2} (Q_{L+1} - V) (Q_{L+1} - V)^* \\ &= \frac{1}{2} [(Q_{L+1,R} - V_R)^2 + (Q_{L+1,I} - V_I)^2] \end{aligned} \quad (13)$$

其中 $W = \{W_1, W_2, \dots, W_{L+1}\}$, $B = \{B_1, \dots, B_{L+1}\}$.

定义 $E_R(t) = \frac{1}{2} [t - V_R]^2$, $E_I(t) = \frac{1}{2} [t - V_I]^2$, 则

式(13)可改写为

$$E(W, B) = E_R(Q_{L+1,R}) + E_I(Q_{L+1,I}) \quad (14)$$

神经网络训练目的即寻找最优权值矩阵 \bar{W} 及阈值 \bar{B} , 使得 $E(\bar{W}, \bar{B}) = \min E(W, B)$. 利用梯度算法更新权值 W 与阈值 B 过程为 $W_i = W_i - \eta \frac{\partial E(W, B)}{\partial W_i}$, $B_i = B_i$

$-\eta \frac{\partial E(W, B)}{\partial B_i}$.

其中 η 为学习速率. 更新权值后返回式(7), 进行第 2 次迭代训练, 直至达到神经网络训练最大迭代次数, 训练过程结束, 此时得到最优权值矩阵 \bar{W} 及阈值 \bar{B} . 利用复数值神经网络批处理梯度算法, 将最优权值矩阵 \bar{W} 及阈值 \bar{B} 赋予 BP 神经网络, 即可完成神经网络训练过程. 将过采样 N 倍接收的特征辅助信号 $\tilde{z}_{k,n}^p (n=1, 2, \dots, N)$ 作为神经网络输入 $Y_n^m (n=1, 2, \dots, N)$, 由式(6)可知, 接收信号第 k 个采样点位置的第 p 个特征辅助信号符号将对应输出 $Q_{k,L+1}^p (p=1, 2, \dots, M^{2L+1})$, 将输出代入最优路径判决模块实现最终分离.

3.3 最优路径判决模块

3.2 节基于神经网络算法分离当前时刻发送符号时, 仅考虑滤波器窗长内符号影响, 而最优路径判决模块将当前时刻最佳采样位置符号前后 L_c 个符号考虑在内, 通过最小路径度量确定当前时刻最佳采样位置符号, 相当于增加了判决约束条件, 因此提升了分离准确性. 假设 \tilde{z}_{k+1}^p 对应的 $k+1$ 时刻第二路信号分量信道状态与输入符号分别为 $s_{k+1}^p = (a_{2,k-L_c+1;k+L_c}^p)$ 和 $\phi_{k+L_c}^p = (a_{2,k+L_c+1}^p)$, 记 $s_k^p (\hat{p}=1, 2, \dots, M)$ 为 $k+1$ 时刻输入符号 $\phi_{k+L_c}^p$ 时能达到 s_{k+1}^p 的所有 k 时刻状态, 定义 \tilde{z}_{k+1}^p 的路径度量为

$$\lambda_{k+1}^p = \min_p \{ \lambda_k^p | s_k^p \rightarrow s_{k+1}^p \} + \min_r \{ Q_{k+1,L+1}^p - V_r \} \quad (15)$$

其中 $p=1, 2, \dots, M^{2L+1}$, $r=1, 2, \dots, M^2$. 神经网络特点是对于有着相同特征的输入会产生相同分类判决结果, 因此式(6)中与发送信号 $x_{2,k}$ 相同的 $\tilde{x}_{2,k}^p$ 产生的特征辅助信号状态拥有当前接收符号位置最小的度量值, 判决 K 时刻最小度量 $\min \{ \lambda_{k+1} \}$, 回溯即可判决出接收信号每个采样时刻发送符号对 $A_{j,0}^q (q=1, \dots, M^2)$, 进而判决出两路发送符号, 实现分离过程.

4 复杂度分析

基于神经网络 PCMA 分离算法复杂度主要集中在神经网络分离模块中的神经网络训练过程, 对于有着 L 个隐含层, 每个隐含层分别具有 $Q_l (l=1, \dots, L)$ 个神经元的神经网络, 迭代次数 ℓ_{\max} 时神经网络训练前向计算过程共需要实数加法与乘法次数均为 $2N\ell_{\max} M^{2L+2} Q$, 其

中 $\tilde{Q} = NQ_1 + Q_1Q_2 + \dots + Q_{L-1}Q_L + Q_LM^2$; 误差反向传递过程需要实数加法与乘法次数分别为 $2\ell_{\max}M^{L_c+2}(9\tilde{Q} - 8Q_{L-1}Q_L - 8Q_LM^2)$ 与 $4\ell_{\max}M^{L_c+2}(9\tilde{Q} - 8Q_{L-1}Q_L - 9Q_LM^2)$, 分别定义为 Num_1 和 Num_2 . 完成神经网络训练过程后, 对于拥有相同参数条件下的 PCMA 混合信号盲分离, 每分离一对发送符号算法计算量为一次神经网络前向计算与一次单路信号遍历重构, 其中一次神经网络前向计算需要实数加法与乘法次数均为 $2\tilde{Q}$ 量级, 一次单路信号重构需实数加法与乘法次数均为 $4NM^{2L_c+1}(2L_c+1)$ 量级, 定义 $Num = (2L_c+1)$. 综上所述各算法分离 K 对发送符号所需复杂度如表 1.

表 1 算法复杂度分析

| 复杂度 | 训练过程 | | 分离过程 |
|------------------------|--|--|--|
| | 实数加法次数 | 实数乘法次数 | 实数加(乘)法次数 |
| 本文算法 | $2N\ell_{\max}M^{L_c+2} \cdot \tilde{Q} + Num_1$ | $2N\ell_{\max}M^{L_c+2} \cdot \tilde{Q} + Num_2$ | $2\tilde{Q} + 4KNM^{2L_c+1}N_{um}$ |
| PSP 算法 ^[15] | | | $8KNM^{2(2L_c+1)}N_{um}$ |
| 粒子滤波算法 ^[15] | | | $8KNB_sM^2(1 - M^{2(D+1)}) \cdot N_{um}/(1 - M^2)$ |

表 1 中 B_s 是粒子滤波算法中的粒子数(一般取 $B_s = 200$), D 是平滑长度(一般取 $D = 2$)^[17].

表 1 中有两点值得注意, 一是神经网络训练过程在处理相同参数条件下的 PCMA 混合信号盲分离过程中仅进行一次, 即网络训练过程复杂度对于 PCMA 混合信号盲分离过程是恒定数值, 并不随分离符号增多而增加, 因此可将此阶段复杂度控制在一个有限范围. 第二点值得注意的是对于已训练好的神经网络, 相较于传统 PSP 算法需遍历两路发送符号重构信号的过程, 本文算法仅需遍历一路发送符号用于重构信号, 因此伴随着复杂度的指数级下降. 综上所述, 本文算法较传统算法具有明显的低复杂度优势.

5 仿真与分析

5.1 神经网络参数选取分析

神经网络训练过程实际上是一个逐步减小网络实际输出与期望输出间误差的过程. 神经网络参数选取目前理论上还没有一个明确的规定, 在具体设计时需要靠经验法, 本文参考“*The Ohio State University DNN-toolbox*”^[20] 参数设置, 结合研究对象通过实验仿真, 验证出适合于归一化功率 PCMA 混合信号盲分离的神经网络参数, 设置如下: 隐含层数量 $L = 3$, 每层隐含层包含神经元数目依据经验公式设置为 $Q_l = N + M$. 学习速率 η 在神经网络训练初期选择较大权值变化量, 随着网络误差值减小而逐渐选择较小权值变化量, 取值区间为 $(0.001, 0.0002)$.

值得注意的是, 当参数选取能够实现算法收敛后, 即迭代次数足够大使得式(14)中批处理梯度算法复数神经网络误差函数收敛, 则算法性能将有保证, 也就是说, 即使参数没有达到最优设置, 也足够能保证算法性能在可接受范围内. 本文参数设置条件下已可保证算法收敛, 满足实际分离要求.

5.2 算法仿真

针对 QPSK 调制 PCMA 信号盲分离进行算法仿真, 仿真条件设置为: 等效的信道脉冲响应采用滚降系数为 0.35 的平方根升余弦脉冲, 拖尾长度 $L_c = 3$, 相偏 θ_1 和 θ_2 在 $[-\pi, \pi]$ 内随机选取, 时延 τ_1 和 τ_2 在 $[-T_s/2, T_s/2]$ 内随机选取, 采样频率 $f_s = 32 \cdot f_d$ (f_d 为符号速率, 即 $N = 32$). 蒙特卡罗实验次数 $M = 100$. 算法性能统一用误比特率(bit error ratio, BER)来衡量.

5.2.1 本文算法性能

图 3 为本文算法分离 PCMA 混合信号误比特率随信噪比(signal noise ratio, SNR)变化曲线, 其中 P-method 表示不采用最优路径判决模块辅助而直接判决输出结果, I-method 表示采用最优路径判决模块辅助算法, $\Delta f/f_d$ ($\Delta f = |f_1 - f_2|$) 表示两路信号分量频偏差(相对于符号速率). 由图 3 可知, 信噪比 10dB 时 I-method 分离 BER 较 P-method 下降约 1 个数量级, 而在信噪比 12dB 时下降约 2 个数量级, 这是由于最优路径判决模块充分地利用了盲分离模块输出信息与信号本身调制信息, 将判决标准由单个采样点的度量改进为一条路径多个采样点联合度量所致, 也从一个侧面反映本文分离结构设计合理性. SNR 在 9dB 以上时, I-method 算法 BER 较 $N = 8$ 时的 PSP 算法降低 1 个数量级, 同时较 $N = 4$ 时的 PSP 算法降低 2 个数量级以上, 然而由于 I-method 算法仅重构一路发送信号分量, 因此图 3 条件下 I-method 算法神经网络分离过程复杂度分别为 $N = 8$ 和 $N = 4$ 时 PSP 算法复杂度的约 $\frac{1}{16}$ 和 $\frac{1}{8}$, 可见本文算法大大降低了算法复杂度.




图 3 本文算法分离性能分析

由图3还可以看到,相较于传统算法^[10,11]本文算法性能对频偏误差不敏感,这是由于预处理模块的特征辅助信号有效地消除了频偏对混合信号的影响,如式(5)所示,因此本文适合于实际接收中存在频偏的PCMA混合信号盲分离场合。

5.2.2 算法性能影响因素分析

图4给出接收信号过采样倍数 N 对本文算法分离BER影响曲线。由图4可见随着接收过采样倍数增加,算法BER逐渐减小,若SNR在9dB以上, $N=24$ 时算法BER较 $N=16$ 时降低约1个数量级,而较 $N=8$ 时降低约2个数量级。这是由于过采样倍数增加使得神经网络输入端输入特征信息增加,神经网络训练与分离过程所利用信号先验信息更加充分,带来更好的分离性能。同时可见相对于PSP算法中 $N \geq 2$ 后算法性能差距并不是很明显^[10,11],本文算法受 N 影响较大,这是因为本文算法性能依赖于神经网络的构造,而神经网络训练过程中的输入信息量仅与 N 有关, N 提升一倍则对应着神经网络训练模块输入信息量提升一倍,因此本文基于前馈神经网络分离算法对 N 设置敏感。由图4还可以看到, N 大于24后算法性能随 N 进一步增大提升不明显,可视为已基本利用完全该信道参数信息构建神经网络。




图4 不同接收过采样倍数下分离BER

图5与图6分别给出两路信号分量幅度比与时延差($\Delta\tau = |\tau_1 - \tau_2|$)对本文算法分离BER影响曲线。可见随着两路信号分量幅度差以及时延差增大,算法BER逐渐减小。若SNR在9dB以上, $h_1/h_2 = 1:0.8$ 较 $h_1/h_2 = 1:0.9$ 时分离BER降低1个数量级以上,同时较 $h_1/h_2 = 1:1$ 时分离BER降低约2个数量级。类似的,若SNR在9dB以上,时延差 $\Delta\tau = 0.3$ 时算法BER较 $\Delta\tau = 0.2$ 时降低约0.5个数量级,而较 $\Delta\tau = 0.1$ 时降低约2个数量级。这主要是由于在神经网络训练过程中,大的信号分量幅度差异以及大的时延差异会增加信号分量间互异性,进而增加可分离性所致。

6 结论

本文突破传统遍历思想与最大似然准则束缚,从




图5 不同幅度比下分离BER




图6 不同时延差下分离BER

信号内在结构建模角度构造了基于BP神经网络PCMA信号盲分离模型,利用预处理模块指导神经网络批处理梯度算法训练过程,进而联合神经网络分离模块与最优路径判决模块实现PCMA信号有效分离,具有复杂度低且性能可靠的特点,适合高阶混合信号盲分离处理。值得注意的是,本文算法适用于处理恒参信道PCMA混合信号盲分离,而对于时变参数信道混合信号盲分离需要在神经网络训练过程中增加跟踪模块,实时微调权值系数来实现。

参考文献

- [1] Dankberg M. Paired carrier multiple access (PCMA) for satellite communication [A]. Pacific Telecommunications Conference [C]. Honolulu, Hawaii, 1998. 787 - 791.
- [2] Li F, Jafarkhani H. Interference cancellation and detection for more than two users [J]. International Journal of Engineering Research & Applications, 2014, 4(1): 901 - 910.
- [3] Wu C L, Liu Z, Wang X, et al. Single-channel blind source separation of co-frequency overlapped GMSK signals under constant-modulus constraints [J]. IEEE Commun Lett, 2016, 20(3): 486 - 489.
- [4] 付迪, 高勇. 非对称PCMA卫星信号的截获方法 [J]. 现代电子技术, 2007, 7(7): 28 - 30.
Fu D, Gao Y. Signal interception method for asymmetric PCMA satellite communication system [J]. Modern Electronic Technique, 2007, 7(7): 28 - 30. (in Chinese)

- [5] RuderMA, Lehmann A, Schober M R, et al. Single antenna interference cancellation for GSM/VAMOS/ EDGE using L_p -norm detection and decoding [J]. IEEE Transactions on Wireless Communications, 2015, 14(5): 2413 - 2425.
- [6] 万坚, 许华, 朱中梁. 基于独立分量分析的成对载波多址分离新算法[J]. 通信学报, 2006, 27(8): 41 - 44.
Wan J, Xu H, Zhu Z L. Separation algorithm of paired carrier multiple access based on independent component analysis [J]. Journal on Communications, 2006, 27(8): 41 - 44.
- [7] Liu K, Li H, Dai X, et al. Single channel blind separation of cofrequency MPSK signal [A]. Communication Internet and Information Technology [C]. USA, 2006. 42 - 46.
- [8] Tu S L, Chen S H, Zheng H, et al. Particle filtering based single-channel blind separation of co-frequency MPSK signals [A]. Proceedings of 2007 International Symposium on Intelligent Signal Processing and Communication Systems [C]. Xiamen, China, 2007. 582 - 585.
- [9] Tu S L, Chen S H, Zheng H, et al. On the performance of single-channel blind separation of two co-frequency MPSK signals [C]. 2007 IEEE Region 10 Conference TENCN, Penang, Malaysia, 2007. 1 - 4.
- [10] Tu S L, Zheng H, Gu N. Single-channel blind separation of two QPSK signals using per-survivor processing [C]. IEEE Asia Pacific Conference on Circuits and Systems, Macao, China, 2008. 473 - 476.
- [11] 杨勇, 张冬玲, 彭华, 等. 利用 Gibbs 采样的同频混合信号单通道盲分离[J]. 通信学报, 2015, 36(4): 156 - 162.
Yang Y, Zhang D L, Peng H, et al. Single-channel blind separation of co-frequency modulated signals based on Gibbs sampler [J]. Journal on Communications, 2015, 36(4): 156 - 162. (in Chinese)
- [12] Erkelens J, Hendriks R, Heusdens R, et al. Minimum mean-square error estimation of discrete Fourier coefficients with generalized gamma priors [J]. IEEE Trans Audio, Speech, Lang Process, 2007, 15(6): 1741 - 1752.
- [13] Hendriks R, Heusdens R, Jensen J. MMSE based noise PSD tracking with low complexity [A]. ICASSP [C]. Dallas, Texas, USA, 2010. 4266 - 4269.
- [14] Chen J, Wang Y, Wang D. A feature study for classification-based speech separation at very low signal-to-noise ratio [A]. ICASSP [C]. Florence, Italy, 2014. 39 - 43.
- [15] 廖灿辉, 周世东, 朱中梁. 基于最大似然的同频混合信号联合定时估计算法[J]. 系统工程与电子技术, 2010, 32(6): 1121 - 1124.
Liao C H, Zhou S D, Zhu Z L. ML-based joint timing estimation algorithm for co-frequency signals [J]. Systems Engineering and Electronics, 2010, 32(6): 1121 - 1124. (in Chinese)
- [16] 芮国胜, 徐彬, 张嵩. 单通道混合信号的幅度估计算法[J]. 通信学报, 2011, 32(12): 82 - 87.
Rui G S, Xu B, Zhang S. Amplitude estimation algorithm for single channel mixing signals [J]. Journal on Communications, 2011, 32(12): 82 - 87. (in Chinese)
- [17] 万坚, 涂世龙, 廖灿辉等. 通信混合信号盲分离理论与技术[M]. 北京: 国防工业出版社, 2012.
Wan J, Tu S L, Liao C H, et al. Theory and Technology on Blind Source Separation of Communication Signals [M]. Beijing: National Defense Industry Press, 2012. (in Chinese)
- [18] 杨勇, 张冬玲, 彭华, 等. 单通道高阶调制线性混合信号的频偏估计[J]. 电子学报, 2015, 43(1): 160 - 165.
Yang Y, Zhang D L, Peng H, et al. Frequency offset estimation in single-channel linear mixture of high-order modulated signals [J]. Acta Electronica Sinica, 2015, 43(1): 160 - 165. (in Chinese)
- [19] 魏雪娟, 等. PCMA 系统中干扰信号的频偏与时延联合估计[J]. 通信学报, 2017, 38(2): 173 - 182.
Wei X J, et al. Joint estimation of interference frequency offset and time delay in PCMA system [J]. Journal on Communications, 2017, 38(2): 173 - 182. (in Chinese)
- [20] Wang Yuxuan, Narayanan Arun, Wang Deliang. On training targets for supervised speech separation [J]. IEEE/ACM Trans Audio Speech Lang Process, 2014, 22(12): 1849 - 1858.

作者简介



郭一鸣 (通信作者) 男, 1990 年 10 月出生, 河北邢台人. 2012 年进入战略支援部队信息工程大学信息工程学院. 现为博士研究生, 研究方向为信号逆向分析.
E-mail: guoym28892@163.com



彭华 男, 1973 年 8 月出生, 江西萍乡人. 教授, 博士生导师. 主要研究方向为软件无线电、通信信号处理等.

杨勇 男, 1988 年 2 月出生, 云南大理人, 博士. 研究方向为航天信号分析处理.