

基于深度神经网络的线性回波抵消与不完全传递函数的凸重构

文 锁

(华池县职业中等专业学校, 甘肃 华池 745600)

摘要: 开发了一种在时频域中工作算法, 该算法假设只有在逼近信号不活跃的频率条件下, 才能估计出各自的传递函数; 该算法利用在混合信号上训练的神经网络来检测逼近信号的活动, 在未检测到任何活动频率情况下, 使用常规频域最小二乘法估计声波传递函数; 对于出现的传递函数 (ITF) 估计不完整问题, 该算法通过模糊时间域内 ITF 最稀疏表示来完成, 将软阈值函数应用于时间域, 由软阈值函数自适应完成, 同时使用过采样来提高精度。实验结果表明: 在活跃频率为 80% 时, 该算法比传统算法收敛速度快 50% 左右; 语音实验中, 改进 ADMM 算法耗时 0.125 s, 明显优于传统算法; 为语音传输业务中存在回声消除问题提供了新思路。

关键词: 线性回波; 回声消除; 神经网络; 软阈值

Linear Echo Cancellation and Convex Reconstruction of Incomplete Transfer Function Based on DNN

Wen Suo

(Huachi Vocational Secondary Professional School, Huachi 745600, China)

Abstract: An algorithm is developed in the time-frequency domain. It is assumed that the transfer function can be estimated only under the condition that the approximation signal is inactive. The algorithm uses a deep neural network trained on the mixed signal to detect the activity of the approximation signal, and the conventional frequency domain least squares method is used to estimate the acoustic wave transfer function without detecting any active frequencies. For the incomplete problem of the proposed transfer function (ITF) estimation, the algorithm is completed by the most sparse representation of the ITF in the fuzzy time domain. The soft threshold function is applied to the time domain, adaptively completed by the soft threshold function, and oversampling is used to improve the accuracy. The experimental results show that the algorithm converges by about 50% faster than the traditional algorithm when the active frequency is 80%. In the speech experiment, the improved ADMM algorithm takes 0.125 s, which is obviously superior to the traditional algorithm. It provides a new idea for the problem of echo cancellation in voice transmission services.

Keywords: linear echo; echo cancellation; deep neural network; soft threshold

0 引言

在语音通信、数据通信等领域中, 都不同程度地存在回波问题, 回波的存在影响了通信质量, 严重时会使通信系统不能正常工作^[1]。因此, 必须采取有效措施来抑制回波, 消除其影响。回波消除是通常采用的基本方法, 其基本思想是估计回波路径的特征参数, 产生一个模拟的回波路径, 得出模拟回波信号, 从接收信号中减去该信号, 实现回波消除^[2]。但是, 在逼近信号 (语音) 活跃的情况下, 使用线性回波消除方法来消除回波是比较困难的。

然而, 根据现有研究现状, 对于稀疏脉冲响应在时间频率域中的修正, 还没有相关的研究工作。因此, 在时频域中研究稀疏脉冲响应的修正, 在许多应用中具有很好的研究意义^[3]。本文提出了适用于频域痉挛脉冲响应的 LMS 方法。当标签信号处于激活状态时, 基于 LMS 的算法的性

能会下降。因此, 将该算法与语音活动检测 (VAD) 结合使用, 当目标信号激活时, LMS 的自适应停止^[4]。另一种解决方案采用盲源分离方法, 旨在跟踪目标信号活动在期间 $H(n)$ 的变化。

在本文中结合了两种观点: 一种观点是使用一个在混合信号上训练的神经网络 (DNN) 来执行一个与频率相关的 VAD; 另一种观点是, 在与 $H(n)$ 相关的频域中, 只有在目标信号不活跃的频率箱中才能观测到传输。因此, 本文采用基于 DNN 的 VAD, 它决定了目标信号 (语音) 占主导地位的频率。然后, 将 LMS 应用于只受干扰的频率, 由此得到不完全传递函数 (ITF), ITF 是使用基于凸重构的方法完成。从而实现基于神经网络的线性回波消除, 得到基于凸重构的不完全传递函数。

1 方法论

为了解决回波消除 (AEC) 的问题, 可将该问题表述为传声器 $x(n)$ 上的信号传播时, 对噪声参考信号 $r(n)$ 与干扰 (噪声) 源与传声器之间的声脉冲响应 $h(n)$ 的估计, $s(n)$ 可以通过观察得到^[5]。当目标源 (通常是说话

收稿日期: 2019-09-18; 修回日期: 2019-10-14。

作者简介: 文 锁 (1965-), 男, 甘肃华池人, 大学本科, 高级教师, 主要从事数学与大数据方向的教学及应用。

人) 处于活动状态时, 在间隔期间估计是较困难, 模型在时间域中, 描述为式 (1):

$$x(n) = \underbrace{s(n)}_{\text{目标信号}} + \underbrace{\{r * h\}}_{\text{回波}}(n) \quad (1)$$

式中, $*$ 表示卷积。获得了 $h(n)$ 的估计值, 即模拟回波信号, 就可以从接收信号中减去该信号, 实现回波消除。增强型麦克风信号如式 (2)、式 (3) 所示:

$$\hat{s}(n) = x(n) - \{r * \hat{h}\}(n) \quad (2)$$

$$\hat{s}(n) = s(n) + \{r * (h - \hat{h})\}(n) \quad (3)$$

在上式中, 干扰源和麦克风可以改变位置。必须对问题进行自适应处理。为此, 在时间域或频率域中应用自适应最小均方算法 (LMS)。由于该算法结构简单, 性能稳定, 计算复杂度低, 在回声消除领域被广泛应用^[6]。但是当信号相关性较大时, LMS 算法的收敛性很差。文献 [7] 中提出了对稀疏脉冲响应的线性矩阵进行时域修正的方法, 如比例归一化线性矩阵 (PNLMS)。PNLMS 算法采用不同的步长与估计的滤波系数成比例, 具有很快的初始收敛速度。此外, 也出现了许多对 PNLMS 的改进, 如改进的 PNLMS (IPNLMS) 或重新加权零校正 PNLMS (RA-PNLMS)^[8], IPNLMS 用于提高 PNLMS 算法在非稀疏回声路径下的性能。

最小均方 (LMS) 适用于这些问题, 需要估计脉冲响应的地方^[9]。这种计算的理想条件是目标信号 s 无效, 然后准确估计脉冲响应。

可以最小化均方误差区间 $n=n_1, \dots, n_2$ 。 $J_n(h)$ 标准均值可以如式 (4) 最小化:

$$J_n(h) = \frac{1}{n_1 - n_2 + 1} \sum_{n_1}^{n_2} e[n]^2 \quad (4)$$

其中: e 是所需输出信号 s 与实际输出信号 \hat{s} 之间的误差, 三者之间关系如式 (5):

$$e[n] = s[n] - \hat{s}[n] \quad (5)$$

梯度 $\Delta J_n(h)$ 可以表示为式 (6), 其中 W_n, b_n 分别用式 (7)、(8) 表示:

$$\Delta J_n(h) = -2b_n + 2W_n h \quad (6)$$

$$W_n = \frac{1}{n_1 - n_2 + 1} \sum_{n_1}^{n_2} r_n r_n^T \quad (7)$$

$$b_n = \frac{1}{n_1 - n_2 + 1} \sum_{n_1}^{n_2} r_n x(n) \quad (8)$$

令 $\Delta J_n(h)$ 等于零, 则存在 W_n 的逆矩阵, 得到式 (9):

$$\hat{h} = W_n^{-1} b_n \quad (9)$$

AEC 问题的时频域 (FDLMS) 中的 LMS 可表示为式 (10):

$$\min_H \|X_{n,\gamma} - H_{n,\gamma} R_{n,\gamma}\|_2^2 \quad (10)$$

其中: $X_{n,\gamma}$ 与 $R_{n,\gamma}$ 分别是短时傅里叶变换 (STFT) 中的混合信号和参考信号。下标 n 表示帧号, γ 表示频率仓。表达式 (10) 中定义的 LMS 的解可以通过如下计算参考信号和混合信号之间的相互关联来完成, 如式 (11):

$$C_{n,\gamma}^{XR} = \frac{1}{n_1 - n_2 + 1} \sum_{n_1}^{n_2} R_{n,\gamma} X_{n,\gamma} \quad (11)$$

间隔 n 和频率仓 γ 上的参考信号的自相关系数由下式给出:

$$C_{n,\gamma}^{RR} = \frac{1}{n_1 - n_2 + 1} \sum_{n_1}^{n_2} R_{n,\gamma} R_{n,\gamma} \quad (12)$$

环境的传递函数由式 (13) 给出:

$$\hat{H}_{n,\gamma} = \frac{C_{n,\gamma}^{XR}}{C_{n,\gamma}^{RR}} \quad (13)$$

然而, 自适应间隔越短, 连续数据变化越大。如果块太短, 则 W 接近单数。为此, 提出了自适应 LMS 算法。自适应 LMS 的目的是用于脉冲响应估计, 使第 n 帧中的实际误差最小化。

\hat{H} 初始化为零, $X_{n,\gamma}$ 在帧 n 和频率 γ 处的误差可用式 (14) 计算:

$$E_{n,\gamma} = X_{n,\gamma} - R_{n,\gamma} \hat{H}_{n-1,\gamma} \quad (14)$$

改进自适应传递函数为式 (15):

$$\hat{H}_{n,\gamma} = \hat{H}_{n-1,\gamma} + \mu \frac{R_{n,\gamma} R_{n,\gamma}^T}{R_{n,\gamma} R_{n,\gamma}^T + \epsilon} \quad (15)$$

其中: ϵ 是小的正常数, 以避免被零除。式 (15) 是估计 \hat{H}_n 的快速方法, 但在目标信号 s 不活跃的频率下失败。基于以上考虑, 提出了自适应频域 LMS 的改进算法。

改进算法方法依赖于基于 DNN 的语音活动检测器 (VAD), 该检测器可以在每个频率检测混合信号中的语音活动^[10]。此信息命名存储在集合 O 中 (以 1 和 0 的形式表示)。该方法的思想是估计一个不完全传递函数 ($\hat{H}_{n,\gamma}$), 仅可获得频率 $\gamma \in O$ 。然后, 计算不完全传递函数在时间域中的最稀疏表示^[11]。式 (15) 仅适用于 $\gamma \in O$, 并解决式 (16) 提出的问题。

$$\hat{H}_n = \arg \min_H \|X_n - H_n \odot R_n\|_2^2 + a \|F^{-1} H_n\|_{l_1} \quad (16)$$

其中: H_n 在集合 O 中的指数 H , F 是离散傅立叶变换的矩阵矢量, $\|\cdot\|_{l_1}$ 表示 l_1 常数, \odot 表示按元素划分, μ 是控制解稀疏度的正参数。提出利用逼近算法求解式 (16)。

1.1 最大算子

逼近算法是解决凸问题的有力工具^[12], 如式 (16) 所示。提出了 2 种基于逼近算法的改进型。算法的投影算子定义为式 (17)。

$$\text{prox}_{\lambda f}(x) = \arg \min_u (f(u) + (1/2\lambda) \|u - x\|_2^2) \quad (17)$$

对于给定的点 x , 找到其最优的点 $u = \text{prox}_{\lambda f}(x)$, 使得 $f(x) + (1/2\lambda) \|u - x\|_2^2$ 最小。其中 $f(x)$ 函数为闭函数, 也是适当的凸函数。 $\lambda > 0$ 是小数位运算符号。公式的右边是强凸的, 并不是每一个点都是凸的, 所以它对于每一个点都有一个唯一的极小值。

1.2 最大梯度法

为了制定逼近梯度法, 需要考虑以下分裂问题:

$$\min_x f(x) + g(x) \quad (18)$$

其中: $f(x)$ 函数和 $g(x)$ 函数是闭函数, $f(x)$ 函数适当的凸函数且可微, $f(x)$ 是凸函数但在某些地方不可微。式 (18) 的逼近梯度法的一次迭代如式 (19):

$$x = \text{prox}_{\mu g}(x - u \nabla f(x)) \quad (19)$$

其中: $\mu > 0$ 是步长参数。将 $f(x) = \|X_n - H_n R_n\|_2^2$ 和

$g(x) = a \|F^{-1}H\|_1$, 可以解决式 (16)。 $x - u \nabla f(x)$ 等于式 (15), 范数的逼近算子定义如下:

$$\text{Soft}_\lambda(x) = \begin{cases} x - \lambda & x > \lambda \\ 0 & |x| \leq \lambda \\ x + \lambda & x < -\lambda \end{cases} \quad (20)$$

其中: 参数 λ 与式 (15) 中的 a 紧密相关。对式 (16) 的逼近梯度算法的改进后如式 (21) 所示:

$$\begin{aligned} \bar{H}_n &= \hat{H}_{n-1} + u(R_n E_n / (R_n R_n + \epsilon)) \\ \hat{H}_n &= F \text{Soft}_\lambda(F^{-1} \bar{H}_n) \end{aligned} \quad (21)$$

综上, 本文提出的梯度算法过程如下算法 1 所示:

Algorithm 1: Proposed gradient based method

Input: $X, R, O = \{r_1, \dots, r_{|o|}\}, \mu, \rho, \lambda, \epsilon$

Output: \hat{S}

initialize: $H \leftarrow 0, H_{\text{old}} \leftarrow 0$

for $n=1$ to N do

$E_{n,o} = X_{n,o} - R_{n,o} H_{\text{old}}$

$$H = H_{\text{old}} + \mu \left(\frac{R_{n,o}^\dagger E_{n,o}}{R_{n,o}^\dagger R_{n,o} + \epsilon} \right)$$

$$\hat{H} = F \text{Soft}_\lambda(F^{-1} H)$$

$$\hat{S}_n = X_n - \hat{H} \odot R_n$$

$$H_{\text{old}} = \hat{H}$$

end

1.3 乘子变换方向法

交替方向乘法器 (ADMM) 是求解凸问题的一种快速而鲁棒的方法^[13]。为了构造 ADMM, 需要将式 (18) 中定义的拆分问题重新表述如式 (22) 所示:

$$\min_x f(x) + g(x) \text{ s.t. } x - z = 0 \quad (22)$$

其中: $f(x)$ 函数和 $g(x)$ 函数是闭函数, $f(x)$ 函数适当的凸函数且可微, $g(x)$ 是凸函数但在某些地方不可微。公式 (22) 的增广拉格朗日如下:

$$L_\rho(x, z, u) = f(x) + g(z) + u^T(x - z) + (\rho/2) \|x - z\|_2^2 \quad (23)$$

其中: u 是与等式约束相关联的双可用性, ρ 是一个正参数。ADMM 可以用式 (23) 中固定 z 值改变 x 来表示最小值, 反之亦然。因此, ADMM 的改进顺序如下:

$$\begin{aligned} x &= \text{prox}_{u_f}(z - u) \\ z &= \text{prox}_{\lambda_g}(x + u) \\ u &= u + \rho(x - z) \end{aligned} \quad (24)$$

其中: 双变量 u 具有运行等式约束误差和的作用。为了使用 ADMM 解决 LASSO 问题, 可定义 $f(x) = \|X_n - H_o R_n\|_2^2$ 和 $g(z) = a \|F^{-1}H\|_1$, 式 (24) 的第一个逼近算子对应于表达式 (15), 而第二个逼近算子是软阈值函数式 (20)。最后, ADMM 算法求解的改进规则表示为如下形式:

$$\begin{aligned} \bar{H}_n &= \hat{H}_{n-1} + u(R_n E_n / (R_n R_n + \epsilon)) - U_{n-1} \\ \hat{H}_n &= F \text{Soft}_\lambda(F^{-1}(\bar{H}_n + U_{n-1})) \\ U_n &= U_{n-1} + \rho(\bar{H}_n - \hat{H}_n) \end{aligned} \quad (25)$$

其中: $\mu > 0$ 为阶梯尺寸参数, $\lambda > 0$ 控制解的稀疏度, ρ 为 0.95。

综上, 本文提出的乘子变换方向法的算法过程如下算

法 2 所示:

Algorithm 2 Proposed ADMM based method

Input: $X, R, O = \{r_1, \dots, r_{|o|}\}, \mu, \rho, \lambda, \epsilon$

Output: \hat{S}

initialize: $H \leftarrow 0, H_{\text{old}} \leftarrow 0, U \leftarrow 0, U_{\text{old}} \leftarrow 0$

for $n=1$ to N do

$$E_{n,o} = X_{n,o} - R_{n,o} (H_{\text{old}} - U)$$

$$H = H_{\text{old}} + \mu \left(\frac{R_{n,o}^\dagger E_{n,o}}{R_{n,o}^\dagger R_{n,o} + \epsilon} - U \right)$$

$$\hat{H} = F \text{Soft}_\lambda(F^{-1} (H + U))$$

$$U = U_{\text{old}} + \rho(H - \hat{H})$$

$$\hat{S}_n = X_n - \hat{H} \odot R_n$$

$$H_{\text{old}} = \hat{H}$$

end

2 结果与讨论

2.1 频域语音活动检测

功率谱密度是一种概率统计方法, 是对随机变量均方值的量度^[14]。因此, 对于频域语音活动检测, 一个有效的方法是根据混合信号的功率谱密度 (PSD) 来检测最活跃的频率^[15]。选择最活跃频率的分位数, 如果所选频率的百分比设置为 100%, 则占用整个带宽。如果将其设置为其他值 (如 40%), 那么整个带宽中只有不到一半的频率箱是最活跃的。

深度神经网络 (DNN), 是一种判别模型^[16]。即已知变量 x , 通过判别模型可以推算出 y ; 深度指的是一系列连续的表示层, 通过这些层可以对数据进行高层次的抽象, 其具备至少一个隐藏层; 可以使用反向传播算法进行训练, 使用梯度下降求解神经元之间的权重^[17]。因此, 采用深度神经网络 (DNN) 对信号噪声比 (SNR) 大于 5 dB 的频谱仓进行估计。汉明窗计算分析信号谱图, 相关信号信息见表 1。训练数据包括 70 h 中央人民广播电台的主持人讲话和中国古典演奏音乐样本 (混合样本的全球信噪比在 -5 ~ 10 db 之间变化)。编制输出标签 (信噪比小于 5 db 为 0, 其余为 1), 计算输入数据的零均值和单位方差归一化统计。

改进的 DNN 由输入层 (2 049 个神经元)、2 个隐藏层 (4 000 和 3 000 个神经元的宽度) 和输出层 (2 049 个神经元) 组成。层间的激活函数采用 ReLU; 输出层包含 Sigmoid 激活函数。优化标准为 MSE, 批量为 1 024 个样品, 倾斜率为 0.015。

2.2 仿真结果

在 AEC 环境下评估所提出算法性能的仿真结果。在实验中, 模拟了目标信号 $s(n)$, 其来源是一个连续的女性语音作为逼近, 而 $r(n)$ 是音乐或白噪声, 代表远端信号。具体实验信号配置如表 1 所示。

表 1 信号基本信息

参数	值
信号长度/s	15
采样频率/kHz	16
STFT 长度	4 096
STFT 漂移	2 048
SNR/dB	0

脉冲响应由房间尺寸为 5 m×4 m×6 m 的房间脉冲响应 (RIR) 发生器生成。源位置设置为 [2, 2.5, 2] m, 麦克风位于 [2, 3.5, 2] m。每个生成的脉冲响应的长度 $h(n)$ 为 4 096 个样本。脉冲响应稀疏产生, 因此其他参数设置如表 2 所示。

表 2 脉冲响应参数设置

参数	值
β	0.2
麦克风类型	全向
维度	3
麦克风方位	$[\pi/20]$

第一个实验使用 4 个语音进行, 第二个实验是对 20 种语言和音乐的混合进行评估, 两个实验的结果均在混合物上取平均值。我们将提出的算法与其他已知算法 (IPNLMS 和 FDLMS) 的收敛速度进行了比较。通过归一化偏差测量收敛速度, 其定义如下:

$$\eta(n) = \frac{\| \hat{h}(n) - h(n) \|_2^2}{\| h(n) \|_2^2} \quad (26)$$

其中: n 是帧索引。在实验中, 通过将第 60 帧处估计的脉冲响应归零来模拟脉冲响应的变化。

2.2.1 白高斯噪声实验

白高斯噪声, 幅度分布服从高斯分布, 功率谱密度服从均匀分布, 即任意时刻的噪声值都是随机的, 在时间轴的某点上, 噪声孤立, 不受前后点噪声幅值影响^[18]。图 1 展示了白高斯噪声的功率分布情况, 从图中可以看出其功率谱密度服从均匀分布, 符合上述实验需求。




图 1 白高斯噪声功率谱

同时, 对白高斯噪声下的 LMS 进行测试, 观察算法迭代次数对结果的影响。

从图 2 中可以看出, 随着算法迭代次数的增加, 均方误差 (MSE) 递减, 表示算法估计值与真值之差平方的期望值。这说明高迭代计算中, LMS 算法的学习效果更好。因此, 后续试验设置迭代次数为 600, 以保证实验精确性。

基于白高斯噪声对多种算法进行比较, 算法比较的详细设置如表 3 所示。本实验进行了 3 种变体, 表 3 为白噪声实验中的算法设置。

在每种变体中, 考虑了不同百分比的活跃频率值, 即 40%、60% 和 80%, 其中 IPNLMS 算法使用 100%。




图 2 白高斯噪声下的 LMS

表 3 白噪声实验中的算法设置

参数	改进 ADMM	改进 Grad	FDLMS	IPNLMS
μ	0.09	0.09	0.09	0.09
β	0.7	0.7	—	—
ρ	0.95	—	—	—
ϵ	1×10^{-9}	1×10^{-9}	1×10^{-12}	1×10^{-9}

其中 40% 的频率箱用于 FDLMS 和改进算法, 图 3 表明, IPNLMS 的收敛速度比所改进的方法快 40% 左右。在图 4 中, 当使用的频率箱数为 60% 时, 所改进算法收敛更快, 并且它们收敛到与 IPNLMS 相同的解; 在图 5 中展示了频率箱数为 80% 的收敛结果。通过实验可以得出, 在活跃频率为 80% 时, 本文算法取得较好的效果。




图 3 40%频率箱条件下不同算法收敛速度比较




图 4 60%频率箱条件下不同算法收敛速度比较

2.2.2 语音实验

对 20 种语言和音乐的混合语音信号进行实验, 详细实验设置如表 4 所示。




图 5 80%频率箱条件下不同算法收敛速度比较

表 4 音乐实验中的算法设置

参数	改进 ADMM	改进 Grad	FDLMS	IPNLMS
μ	0.035	0.035	0.09	0.01
β	0.9	0.9	—	—
ρ	0.95	—	—	—
ϵ	0.000 1	0.000 1	0.000 1	0.000 1




图 6 使用 DNN 的收敛速度

从图 6 中可知，因为 IPNLMS 无法估计存在串扰时的脉冲响应，因此获得最差的收敛性能。FDLMS 也会缓慢收敛，而且不能达到很好的精度。相比之下，本文提出的算法收敛速度快，且实现的精度高。

2.2.3 计算时间

表 5 显示了每个算法处理混合声音所花费的平均时间，值为两个实验的平均值。实验使用 Matlab 2016b 软件，在基于 Intel 核心 IS-4440 的 PC 机上进行。

表 5 不同算法的花费时间

改进 ADMM	改进 Grad	FDLMS	IPNLMS
0.125 1	0.079 3	1.992 2	23.403 0

3 结束语

本文基于深度神经网络的特性，提出了两种解决问题的新算法：一种基于逼近梯度法，另一种基于交替方向乘法器。同时，本文方法基于不完全自适应 LMS 和逼近算法的范数重构实现，用于解决线性回波消除问题。基于高斯

白噪声及多音源混合语音信号进行算法验证。结果表明，对于用于不完全传递函数估计的合适频段百分比，该方法比其他常用算法收敛速度更快；同时，本文所提出的方法所需的平均计算时间也比其他常用方法要短。为语音传输业务中存在回声消除问题提供了新思路。

参考文献：

- [1] 郭紫仕. 宽带通信系统回波抵消设计与实现 [D]. 天津: 天津大学, 2017.
- [2] 张保山, 周峰, 张琳, 等. 基于最优神经网络结构的故障诊断模型 [J/OL]. 兵器装备工程学报, 2019: 1-6.
- [3] 程冰. 基于卷积神经网络的自动标注技术的研究 [J]. 电子世界, 2019 (16): 124-126.
- [4] 李乐强. 音响系统回波抵消研究 [J]. 物联网技术, 2012, 2 (12): 47-49.
- [5] 林旭梅, 刘振东, 马士强, 等. 基于变步长 LMS 算法的交流阻抗测钢筋腐蚀 [J]. 测控技术, 2019, 38 (7): 93-96, 103.
- [6] 魏文亮, 茅玉龙. 一种基于 LMS 自适应滤波的互相关时延估计优化算法 [J]. 电子科技, 2020 (6): 1-7.
- [7] 全喜峰, 陈卫松, 钱隆彦, 等. 一种非线性变步长 LMS 自适应滤波算法 [J]. 无线电通信技术, 2019, 45 (4): 391-396.
- [8] 丁猛. 无延迟闭环子带自适应滤波器在声回波抵消中的应用 [A]. 中国声学设计与噪声振动控制网、中城科数智慧城市规划设计研究中心、声学工程学术委员会、北京国建信文化发展中心. 全国声学设计创新技术与文化建筑声学工程学术会议论文集 [C]. 2018: 6.
- [9] 马敏. 自适应声回波抵消算法在数字助听器中的研究 [D]. 哈尔滨: 哈尔滨工业大学, 2017.
- [10] 徐康. 一种多功能语音通信接口的设计与实现 [J]. 信息通信, 2017 (6): 66-67.
- [11] 张希龙. 基于 Android 平台的助听器系统设计和实现 [D]. 南京: 东南大学, 2017.
- [12] 周晨轶, 冯宇, 徐亦白, 等. 基于增强多重注意力机制的深度神经网络的细粒度检测 [J]. 计算机与现代化, 2019 (9): 83-89.
- [13] 刘小蒙, 邵高平, 戚晓慧. 改进子带自适应滤波算法及其在回波抵消中的应用 [J]. 信号处理, 2016, 32 (8): 973-981.
- [14] 邹采荣, 梁瑞宇, 谢跃. 数字助听器语音处理算法研究进展与展望 [J]. 数据采集与处理, 2016, 31 (2): 242-251.
- [15] 杨栋. 回波抵消系统的参量阵预处理算法的设计与实现 [D]. 哈尔滨: 哈尔滨工程大学, 2016.
- [16] 刘庆刚. 语音引接倍增设备的设计与实现 [J]. 无线电工程, 2013, 43 (7): 5-7, 26.
- [17] 李会雅, 杨建坡, 尹永超, 等. 基于附加信号的回波抵消技术 [J]. 计算机应用, 2013, 33 (3): 631-634.
- [18] 樊海玮, 史双, 张博敏, 等. 基于 MLP 改进型深度神经网络学习资源推荐算法 [J]. 计算机应用研究, 2019, 37 (9): 1-5.