

## 改进 LMS 的光谱信号去噪算法

郑国梁, 朱红求\*, 李勇刚

中南大学自动化学院, 湖南长沙 410083

**摘要** 微型光谱仪在检测高浓度比背景下多种痕量重金属离子浓度时, 光谱吸收信号易受外部环境和内部电路的随机噪声干扰, 多种痕量重金属离子的光谱吸收信号微弱易被噪声所淹没, 严重影响了光谱定量分析结果的准确性和重复性, 需要对光谱吸收信号进行去噪预处理。然而, 大多数光谱去噪算法的一些关键细节参数的设置不仅需要通过反复的实验进行测试验证, 还取决于研究者的现有经验和待解决对象的特征。针对这些关键参数对滤波效果影响大、选择难的问题, 提出了一种基于 sigmoid 误差约束的改进型 LMS 自适应去噪算法。首先对标准 LMS 算法原理进行了分析, 并结合微型光谱仪的数据干扰情况对标准 LMS 算法的滤波器结构进行优化改进, 利用 sigmoid 函数具有误差约束的特性, 对标准 LMS 算法的误差计算模块进行优化改进, 降低算法对噪声敏感性; 然后针对改进后的最小均方误差损失函数是一个非凸函数, 提出了一种类交叉熵损失函数, 将非凸问题转化为一个凸优化问题, 在利用梯度下降法逐步最小化损失函数时, 保证了局部最优解也是全局最优解, 同时结合 Adam 算法来自适应地调整学习率因子, 保证了算法具有较快的收敛速度; 最后为了验证改进后的自适应去噪算法具有较强的去噪性能, 通过交叉验证进行实验验证。对四种金属离子混合溶液的实测光谱吸收信号, 添加不同信噪比的随机噪声后使用该改进的算法进行测试验证, 实验结果表明: 在处理信噪比低的吸收光谱信号过程中, 所提方法相对于标准 LMS 算法、SG 去噪算法、小波软阈值算法、小波硬阈值算法, 信噪比分别提高了 9.225%, 19.678%, 7.591% 和 12.042%; 均方误差分别降低了 59.647%, 63.070%, 53.600% 和 57.793%。该方法不仅能够有效地抑制强噪声, 还原了光谱信号中的一些重要真实细节特征, 而且也避免了关键细节参数需要依靠主观判断选择的问题, 为分析低信噪比下的光谱信号提供了一种新的解决思路。

**关键词** 微型光谱仪; 自适应去噪; 低信噪比; 类交叉熵; 凸优化

**中图分类号:** TH744 **文献标识码:** A **DOI:** 10.3964/j.issn.1000-0593(2020)02-0643-07

### 引言

微型光谱仪是一种利用光的色散原理研制出的光学仪器, 实现对物质浓度和成分的定量和定性分析, 具有检测精度高、速度快、非接触等优点<sup>[1]</sup>。在利用微型光谱仪对高浓度比背景下多种痕量重金属离子浓度的检测时, 由于离子之间化学特性相近, 导致不同离子之间的原始光谱信号存在一定的重叠<sup>[3]</sup>。然而, 多种痕量重金属离子的光谱信号幅值相对于高浓度锌的光谱信号幅值微小, 极易受到外部环境噪声(包括光源发射功率的不稳定而引起的照射光幅值的波动以及电源、地线带来的噪声)和内部电路引起的噪声(包括静电感应、电磁感应以及漏电流感应而仪器的噪声)的干扰<sup>[4]</sup>,

这些噪声种类多、来源广且随机性强, 给有效光谱信号的提取和高浓度比背景下多种痕量重金属离子浓度的检测带来了极大的困难。

如何有效的从信号中消除噪声, 针对具体的应用场景, 目前国内外学者已经进行了许多研究工作。文献[5]中利用 Savitzky-Golay (SG) 去噪算法对遥感领域中的高光谱数据进行降噪分析; 文献[6]作者设计了一个收缩因子, 能够正确区分高频系数中包含的噪声系数和信息系数。文献[7]提出了一种新的自适应阈值函数去噪法, 改进了传统的软硬阈值函数, 提升了去噪效果; 但其阈值函数较复杂, 不适用于工程实践。

基于梯度下降法发展起来的最小均方 (least mean square, LMS) 自适应滤波算法<sup>[8]</sup>是依据最小均方误差准则

收稿日期: 2019-02-28, 修订日期: 2019-06-17

基金项目: 国家自然科学基金重大项目(61890930-2)资助

作者简介: 郑国梁, 1991 年生, 中南大学自动化学院硕士研究生

e-mail: zg\_lcsu@163.com

\* 通讯联系人 e-mail: hqcsu@csu.edu.cn

来不断修正滤波器系数从而达到去噪目的的算法。该算法能够在无先验知识的条件下,通过与外部环境的接触不断修正模型参数从而提高对信号处理性能,在许多需要对信号进行滤波处理的领域上有着广泛的应用<sup>[9]</sup>。然而,标准 LMS 算法在对数据进行去噪处理过程中,存在着对噪声信号敏感、收敛速度慢、易出现过拟合的问题。因此,本工作提出了一种基于 sigmoid 误差约束的改进型 LMS 自适应去噪算法。首先对标准 LMS 算法原理进行分析,并结合微型光谱仪的数据干扰影响情况对标准 LMS 滤波器结构进行优化改进;利用 sigmoid 函数具有误差约束的特性,将误差计算模块进行优化改进;由于改进后的最小均方误差损失函数是一个非凸函数、求解过程容易陷入局部最优解的问题,为此,提出一种类交叉熵损失函数,将非凸函数转化为一个凸优化问题,保证了局部最优解也是全局最优解,同时结合 Adam 算法来自适应的调整学习率因子;结合实验数据利用交叉验证的方法选择最佳参数。最后,通过交叉验证的方法对所提方法进行实验验证。

## 1 LMS 算法原理及改进

### 1.1 标准 LMS 算法原理

LMS 算法是依据最小均方误差准则,采用梯度下降的方法来实现损失函数最小化的去噪算法。如图 1 所示,该算法结构主要由滤波器结构、误差计算模块、LMS 自适应滤波算法结构组成。滤波器结构如式(1)所示:

$$y(n) = W(n)^T X(n) \quad (1)$$

其中,  $X(n) = [x(n), x(n-1), \dots, x(n-L+1)]^T$ , 表示与  $n$  对应的自适应滤波器的输入信号矢量;  $y(n)$  表示  $n$  对应的滤波器输出信号;  $L$  代表该滤波器的阶数;  $W(n) = [\omega_0(n), \omega_1(n), \dots, \omega_{L-1}(n)]^T$ , 表示  $n$  状态下的自适应滤波器系数向量。

误差计算模块通常用式(2)进行表示:

$$e(n) = y(n) - s(n) \quad (2)$$




图 1 LMS 算法结构

Fig. 1 LMS algorithm structure

其中,  $s$  表示  $n$  对应的参考输入信号; LMS 自适应滤波算法结构是采用最小均方误差函数作为优化的目标函数。因此,可以用式(3)描述:

$$J(W) = \frac{1}{2}(e(n))^2 \quad (3)$$

其中,  $W = [\omega_0, \omega_1, \dots, \omega_{L-1}]$ 。将式(2)代入式(3),用式(4)进行描述:

$$J(W) = \frac{1}{2}(y(n) - s(n))^2 \quad (4)$$

利用梯度下降逐步最小化损失函数,标准 LMS 算法迭代方程可用式(5)描述:

$$W(n+1) = W(n) - \alpha \frac{dJ(W)}{dW} \quad (5)$$

其中,  $\frac{dJ(W)}{dW}$  表示对  $J(W)$  中的滤波器  $W$  权系数进行求导,  $\alpha$  表示学习率因子,对标准 LMS 算法的收敛速度和稳态误差影响显著,  $\alpha$  值过大,可能导致损失函数不收敛,出现震荡情况;  $\alpha$  值过小,则参数更新缓慢,导致损失函数收敛速度十分缓慢。

### 1.2 改进型 LMS 算法

由式(1)可知,标准 LMS 算法是根据前  $L$  个输入数据点来对当前数据点进行预测。微型光谱仪常采用的是电荷耦合器件(charge coupled device, CCD)作为感光组件,实现光信号转换为数字信号<sup>[11]</sup>。CCD 感光组件是通过一系列排列在一起的感光像元矩阵单元组成,如图 2 所示。当一束平行光照射至感光像元矩阵单元,所有的感光像元同时采集信号。若将所有的感光像元进行有序编号,图 2 中  $x(n-m)$  位置的感光像元受到的干扰不仅来自于  $A+$  方向的反射光、散射光、杂散光的干扰影响,同时也来自  $A-$  方向的干扰影响,而式(1)只能实现对  $A+$  方向的消噪。因此,对式(1)进行优化改进,用式(6)描述:

$$\overline{y(n)} = \overline{W(n)}^T \overline{X(n)} \quad (6)$$

其中,  $\overline{X(n)} = [x(n+m), x(n+m-1), \dots, x(n), \dots, x(n-m)]^T$ , 表示  $n$  位置对应自适应滤波器输入的信号矢量;  $\overline{W(n)} = [\omega_1(n), \omega_2(n), \dots, \omega_{2m+1}(n)]^T$ , 表示  $n$  位置状态下的滤波器系数向量;  $m = \left\lfloor \frac{L}{2} \right\rfloor$ , 表示改进型 LMS 滤波器阶数,  $\lfloor \cdot \rfloor$  表示向下取整,且  $L > 1$ 。

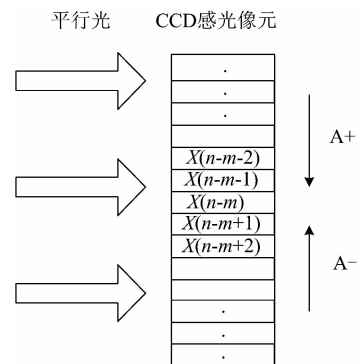


图 2 CCD 采光原理

Fig. 2 CCD lighting principle

利用式(2)计算误差的过程中,仅利用训练样本中的一个样本来进行误差计算,将导致对噪声信号比较敏感,且容易陷入局部最优解中,当噪声信号过大时,则计算得到的偏差非常大,利用式(5)进行权系数向量  $W$  迭代的过程中,权系数向量值变化剧烈,导致收敛时间变长,甚至让整个算法模型处于不收敛状态。为了避免该情况发生,采用小批量随机梯度下降法<sup>[12]</sup>更新迭代权系数向量  $W$ ,同时为了避免算

法对噪声信号的过度敏感性，用式(7)对式(2)进行改写：

$$\mu(n) = \frac{1}{1 + e^{-(y(n)-s(n))}} - 0.5 \quad (7)$$

利用 sigmoid 函数将噪声信号引起的偏差量约束到 -0.5 至 0.5 之间，如图 3 所示，在某种程度上减低了算法模型对噪声信号的敏感性，同时在进行权值更新迭代时，自适应滤波器的权系数向量权值变化不会处于震荡状态，有利于权值系数的快速收敛。




图 3 误差约束

Fig. 3 Error constraint

将式(7)代入由小批量随机梯度下降法建立起来的最小均方误差函数，用式(8)进行描述：

$$J(W) = \frac{1}{2k} \sum_{i=1}^k (\mu(n)^{(i)})^2 \quad (8)$$

其中， $k$  表示随机采样且用于模型训练的样本数量。利用参数辨识的过程中，式(8)是一个非凸函数，存在许多局部最优解<sup>[13]</sup>，避免局部最优解的干扰。将式(8)中的  $\mu(n)$  进行改进，用式(9)进行描述：

$$\text{Cost}(\mu(n)) = \begin{cases} \ln 0.5 - \ln(0.5 - \mu(n)) & \mu(n) \geq 0 \\ \ln 0.5 - \ln(\mu(n) + 0.5) & \mu(n) < 0 \end{cases} \quad (9)$$

将式(9)代入式(8)，然后用式(10)进行描述，将其称为类交叉熵损失函数。如图 4 所示，将式(8)中的非凸问题转换为了一个凸问题，在进行参数寻优的过程中，有效地保证局部最优解也是全局最优解。

$$J(W) = \frac{1}{2k} \sum_{i=1}^k ((\ln 0.5 - \ln(0.5 - \mu(n)^{(i)})) + (\ln 0.5 - \ln(\mu(n)^{(i)} + 0.5)))^2 \quad (10)$$

利用式(10)对样本数据进行模型迭代训练，若算法模型选择了更多的参数、更复杂的模型，则意味着算法对样本训练数据处理非常好 ( $J(W) \approx 0$ )。但是这样获得的模型丧失了一般性，从而导致在一个新给定的环境中处理未知样本数据的过程中存在处理效果差的情况。为了让模型具有较高的泛化能力和抗噪能力，通常采用正则化的方式对式(10)进行参数约束，用式(11)对式(10)进行进一步优化改写。

$$\overline{J(W)} = \frac{1}{2k} \sum_{i=1}^k ((\ln 0.5 - \ln(0.5 - \mu(n)^{(i)})) + (\ln 0.5 - \ln(\mu(n)^{(i)} + 0.5)))^2 + \frac{\lambda}{2k} \sum_{j=1}^{2m+1} w_j^2 \quad (11)$$

其中， $\lambda$  表示正则化系数。当  $\lambda$  值过大时，模型将处于欠拟合状态，当  $\lambda$  值过小时，模型将处于过拟合状态；当  $\lambda > 0$  时，能够保证最小化损失函数是一个强凸函数。将式(11)代入式(5)中进行更新迭代求解最优  $W_{\text{best}}$ ，但是式(5)中的学习率因子  $\alpha$  仍然为固定值，为了不让  $\alpha$  成为影响算法收敛速度的主要因素，需要采用合适的算法来实时调整学习率因子。




图 4 误差与损失函数之间的关系

(a):  $\mu(n) \geq 0$ ; (b):  $\mu(n) < 0$ ; (c):  $-0.5 \leq \mu(n) \leq 0.5$

Fig. 4 The relationship between error and loss function

(a):  $\mu(n) \geq 0$ ; (b):  $\mu(n) < 0$ ; (c):  $-0.5 \leq \mu(n) \leq 0.5$

### 1.3 优化求解

采用自适应矩估计 (adaptive moment estimation, Adam) 算法来实时调整对应的学习率因子  $\alpha$ 。Adam 算法<sup>[14]</sup>根据目标损失函数中每个参数的梯度的一阶矩估计和二阶矩估计动态调整针对每个参数的学习速率因子。其中，Adam 也是基于梯度下降的方法，每次迭代参数的学习步长都有一个确定的范围，不会因为很大的梯度而导致很大的学习步长，保证

参数的值比较稳定。具体程序流程图如图 5 所示。

根据图 5 的算法步骤求解出最优  $W$ ，但是算法中依然存在超参数滤波器阶数  $m$  和正则化系数  $\lambda$  的选择；采用交叉验证的方法找最佳超参数  $m_{\text{best}}$ ,  $\lambda_{\text{best}}$ 。首先，将样本按照比例为 70%，15% 和 15% 随机划分为训练集、验证集和测试集，其中训练样本用于训练模型，验证样本用于检验和评价训练样本获得的模型性能，并根据模型性能优劣来选择最优超参数  $m_{\text{best}}$ ,  $\lambda_{\text{best}}$ ；然后，利用已选择  $m_{\text{best}}$ ,  $\lambda_{\text{best}}$  并结合训练样本和验证样本来再次训练改进型 LMS 算法模型获得最优  $W_{\text{best}}$ ；最后，利用测试样本来测试获得的模型性能。采用信噪比 (signal noise ratio, SNR) 和均方误差 (mean squared error, MSE) 作为模型性能优劣的选择标准。

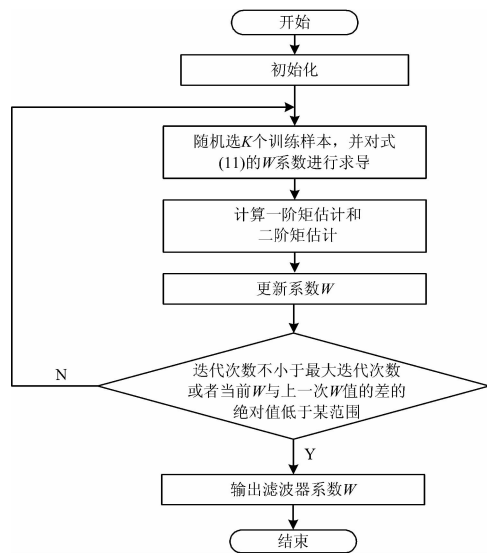


图 5 Adam 流程图

Fig. 5 Flow chart of Adam

## 2 实验结果与讨论

为了验证所提方法的可行性和正确性，选择厦门奥普天成有限公司生产型号为 ATP2000 的便携式微型光谱仪作实验，光源采用氙卤灯，比色皿选择石英比色皿。

### 2.1 数据获取

以锌湿法冶炼为背景，配置  $\text{Zn}^{2+}$ ,  $\text{Cu}^{2+}$ ,  $\text{Co}^{2+}$ ,  $\text{Ni}^{2+}$  浓度分别为  $16 \text{ g} \cdot \text{L}^{-1}$ ,  $1.4 \text{ mg} \cdot \text{L}^{-1}$ ,  $0.8 \text{ mg} \cdot \text{L}^{-1}$ ,  $0.3 \text{ mg} \cdot \text{L}^{-1}$  的混合标准溶液。微型光谱仪采样积分时间设定为 3 ms，采样积分间隔为 500 ms，在相同实验条件下将该浓度的光谱信号重复采集 4 000 次。图 6(a) 为其中一次采样获得的吸收光谱信号。图 6(b) 是根据中心极限定理统计获得的吸收光谱信号，在此作为参考吸收光谱信号。

### 2.2 仿真验证

为了验证方法的有效性和正确性，选择 MATLAB2016b 作为实验仿真平台。首先选择图 6(b) 中的标准参考吸收光谱信号进行仿真实验验证，选择 matlab 软件中函数名为 awgn 的函数，获取添加高斯白噪声后信噪比  $\text{SNR}=[8, 8.08, 8.16, \dots, 26]$  的仿真数据，单位为 dB，总样本量为 226。如图 7 为

信噪比为 16.32 dB 的光谱含噪仿真信号。为了让算法模型具有较强的实用性，在样本划分过程中，将含噪的仿真数据进行归一化处理，然后进行模型训练。对图 5 中初始化值进行以下设定：

$k=20$ ;  $\lambda=[0.001, 0.005, 0.01, 0.1, 1, 2, 3, 6, 9, 15, 20]$ ;  $m=[3, 5, \dots, 29]$ ; 最大迭代次数  $T_{\text{max}}=300$ 。

根据图 5 的程序步骤和交叉验证的方法对模型进行迭代求解，同时独立重复 100 次实验验证。

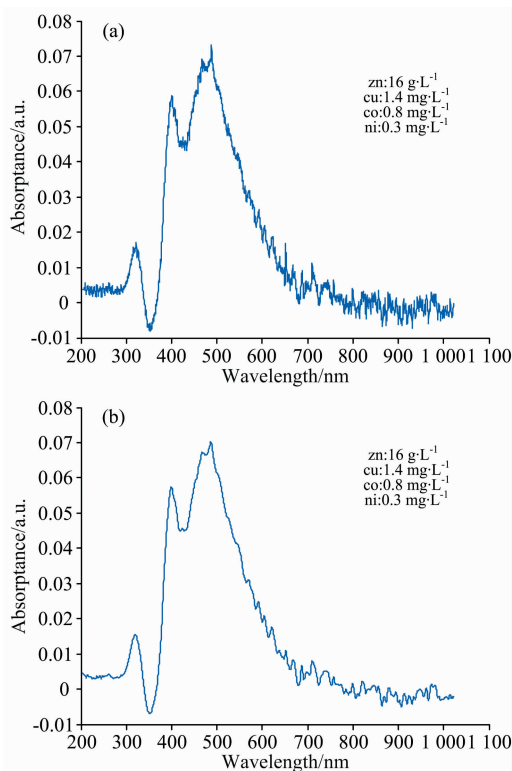


图 6 混合溶液的吸收光谱信号

(a): 实测光谱信号; (b): 参考光谱信号

Fig. 6 Absorption spectral signal of mixed solution

(a): Measured signal; (b): Reference signal

为了进一步验证本方法的降噪效果，选择标准 LMS 算法、小波硬阈值去噪算法、小波软阈值去噪算法、SG 去噪算法与本方法进行性能比较。其中标准 LMS 算法参数设定为： $\alpha=[0.0005, 0.0001, 5.0 \times 10^{-5}, 1.0 \times 10^{-5}, 5.0 \times 10^{-6}, 1.0 \times 10^{-6}, 5.0 \times 10^{-7}, 1.0 \times 10^{-7}]$ ;  $L=[3, 5, \dots, 30]$ ；选择连续性和对称性较好的“sym8”作为小波基函数，并进行 3 层分解；SG 滤波器窗口宽度选择 3，多项式拟合次数选择 1 次。

选择相同的测试集样本来评价这 5 种不同算法的性能，如图 8 所示的均方误差和信噪比这两项性能指标进行统计计算，本文所提出的改进型 LMS 算法相对于标准 LMS 算法、SG 去噪算法、小波软阈值、小波硬阈值去噪算法，信噪比分别提高了 9.225%，19.678%，7.591%，12.042%；均方误差分别降低了 59.647%，63.070%，53.600%，57.793%；有效地说明了本方法的正确性和可行性。




图 7 信噪比为 16.32 dB 的光谱含噪仿真信号  
 Fig. 7 Noisy spectrum simulation signal with a signal-to-noise ratio of 16.32 dB




图 9 改进 LMS 算法对仿真数据降噪效果  
 Fig. 9 The denoising results of the simulation data with the improved LMS algorithm

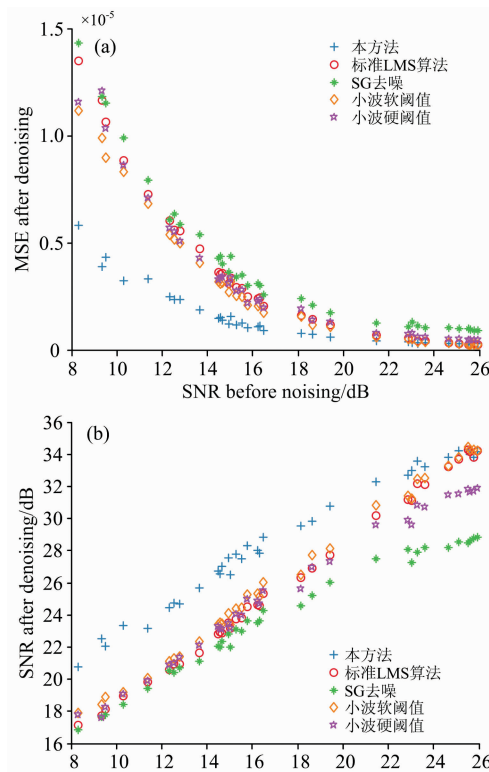


图 8 不同算法性能指标对比  
 (a): 去噪后的均方误差; (b): 去噪后的信噪比  
 Fig. 8 Comparison of performance indicators of different algorithms  
 (a): Mean square error after denoising;  
 (b): Signal-to-noise ratio after denoising

以图 7 中信噪比为 16.32 dB 的含噪仿真数据为例, 利用上述 5 种滤波去噪算法进行滤波处理, 去噪效果如图 9—图 13 所示; 观察虚线框中的去噪后的信号, 改进后的 LMS 滤波算法能够较为真实的还原了原始信号的数据特征, 其他 4 种方法进行去噪后仍然存在较大的毛刺, 在某种程度上影响着光谱分析精度。




图 10 SG 算法对仿真数据降噪效果  
 Fig. 10 The denoising results of the simulation data with the SG algorithm

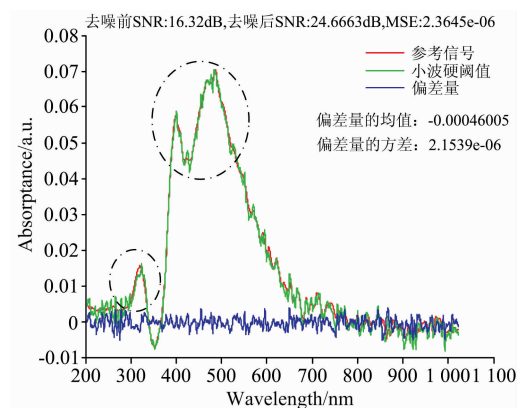


图 11 小波硬阈值算法对仿真数据降噪效果  
 Fig. 11 The denoising results of the simulation data with wavelet hard threshold algorithm

### 2.3 实测光谱信号验证

利用本方法对微型光谱仪实测吸光度光谱信号进行去噪处理, 去噪效果如图 14 所示, 改进型 LMS 算法有效的消除了强噪声的干扰, 同时也有有效的保留了高浓度比背景下多种



痕量重金属离子的原始吸收光谱信号特征。




图 12 小波软阈值算法对仿真数据降噪效果

Fig. 12 The denoising results of the simulation data with wavelet soft threshold algorithm

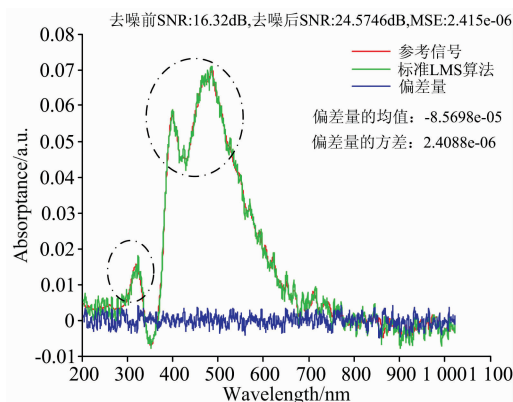


图 13 标准 LMS 算法对仿真数据降噪效果

Fig. 13 The denoising results of the simulation data with the normal LMS algorithm




图 14 改进 LMS 算法对实测光谱数据降噪效果

Fig. 14 The denoising results of the actually measured data with the improved LMS algorithm

### 3 结论

微型光谱仪检测高浓度比背景下多种痕量重金属离子浓度的光谱吸收信号存在噪声信号大的问题,通过对标准 LMS 算法原理和微型光谱仪的数据干扰影响情况进行了分析,提出了一种基于 sigmoid 误差约束的改进型 LMS 自适应去噪算法,有效降低了标准 LMS 算法对噪声的敏感性。针对改进后的最小均方误差损失函数是一个非凸函数的问题,本工作提出了一种交叉熵损失函数,将非凸问题转化为一个凸优化问题,并结合 Adam 算法来自适应的调整学习率因子,保证了算法具有较快的收敛速度。最后结合仿真实验和实测实验进行分析对比。其结果表明:对处理信噪比低的吸收光谱信号过程中,所提方法在信噪比和均方误差的性能指标均优于标准 LMS 算法、SG 去噪算法、小波软阈值算法、小波硬阈值算法,不仅有效去除无关噪声的影响,保留光谱信号中的一些重要真实细节特征,而且也避免了关键细节参数需要依靠主观判断选择的问题,为分析低信噪比下的光谱信号提供了一种新的解决思路。

### References

- [ 1 ] Li J, Li R, Zhao B, et al. Spectrochimica Acta Part A Molecular & Biomolecular Spectroscopy, 2018, 195: 191.
- [ 2 ] Wang K, Sun D W, Wei Q, et al. LWT, 2018, 96: 66.
- [ 3 ] ZHU Hong-qiu, GONG Juan, LI Yong-gang, et al(朱红求, 龚娟, 李勇刚, 等). Spectroscopy and Spectral Analysis(光谱学与光谱分析), 2017, 37(12): 3882.
- [ 4 ] Davenport J J, Jane H, Saffell J R, et al. Applied Optics, 2015, 54(27): 8135.
- [ 5 ] Ruffin C, King R L, Younan N H. GIScience & Remote Sensing, 2013, 45(1): 1.
- [ 6 ] WANG Feng, ZHAO Bai-ting, JIA Xiao-fen(王凤, 赵佰亭, 贾晓芬). Journal of Optoelectronics · Laser(光电子·激光), 2019, 8: 842.
- [ 7 ] LI Hong-yan, ZHOU Yun-long, TIAN Feng, et al(李红延, 周云龙, 田峰, 等). Chinese Journal of Scientific Instrument(仪器仪表学报), 2015, 36(10): 2200.
- [ 8 ] Narimani G, Martin P A, Taylor D P. IEEE Transactions on Communications, 2018, 66(4): 1675.
- [ 9 ] Padhi T, Chandra M, Kar A, et al. Applied Acoustics, 2019, 146: 355.
- [ 10 ] Lopes Pa C, Gerald Ja B, Piedade Mo S. Digital Signal Processing, 2017, 60: 75.
- [ 11 ] Huang C, Xia G, Jin S, et al. Optik-International Journal for Light and Electron Optics, 2018, 157: 693.
- [ 12 ] Qian Q, Jin R, Yi J, et al. Machine Learning, 2013, 99(3): 353.

[13] Elloumi S, Lambert A. *Optimization Methods and Software*, 2019, 34(1): 98.

[14] Kingma D P, Ba J L. *ADMA: A Method for Stochastic Optimization*. 2014, arXiv: 1412.6980[cs.LG].

## Spectral Signal Denoising Algorithm Based on Improved LMS

ZHENG Guo-liang, ZHU Hong-qiu\*, LI Yong-gang

School of Automation, Central South University, Changsha 410083, China

**Abstract** Under the high ratio of concentration, the spectral absorption signals detected by micro-spectrometer are easily disturbed by external environment and internal circuit noise. The spectral absorption signals of trace multi-metal ions are also weak and easily masked by noise, which seriously affects the accuracy and repeatability of the results of spectral quantitative analysis. Therefore, denoising of spectral absorption signal is required. However, the selection of some key detail parameters of most denoising algorithms not only needs to be tested and verified by repeated experiments, but also depends on the experience of the researchers' experience and the characteristics of the signals. In view of the problem that these key parameters have great influence on filtering and are difficult to select, an improved LMS adaptive denoising algorithm based on sigmoid error constraints is proposed in this paper. Firstly, the principle of standard LMS algorithm is analyzed, and the standard LMS filter structure is optimized and improved in combination with the data interference of the micro spectrometer. Meanwhile, due to the characteristics with error constraints, the sigmoid function is used to optimize the error calculation module, reducing the algorithm sensitivity of noise. Then, for the improved least mean square error loss function is a nonconvex function, this paper proposes a kind of cross-entropy loss function, which transforms the nonconvex problem into a convex optimization problem. When using the gradient descent method to gradually minimize the loss function, it ensures that the local optimal solution is also the global optimal solution. The Adam algorithm is also used to adaptively adjust the learning rate factor, which ensures the fast convergence speed of the algorithm. Finally, in order to verify that the improved adaptive denoising algorithm has strong denoising performance, the proposed method is verified by cross-validation. The measured spectral absorption signals of four kinds of multi-metal ion mixed are used to test the performance of the proposed denoising method. The experimental results show that when processing absorption spectrum signals with low signal-to-noise ratio (SNR), compared with the standard LMS algorithm, SG denoising algorithm, wavelet soft threshold algorithm and wavelet hard threshold algorithm, the SNR of the proposed method is increased by 9.225%, 19.678%, 7.591%, 12.042%, respectively, the mean square error of the proposed method is reduced by 59.647%, 63.070%, 53.600%, 57.793%. The proposed method can not only effectively remove the influence of irrelevant noise, but also retain some important detail features in the spectral signal, and avoid the subjective selection of parameters. In conclusion, it provides a new solution to analyze the spectral signal of low SNR.

**Keywords** Micro-spectrometer; Adaptive denoising; Low signal-to-noise ratio; Similar crossentropy; Convex optimization

(Received Feb. 28, 2019; accepted Jun. 17, 2019)

\* Corresponding author