

Blind Source Separation Algorithms Based on Nonnegative Matrix Factorization Using Different Learning Rates

Yijun Mao, Zhijin Zhao, Junna Shang

School of Communication Engineering, Hangzhou Dianzi University, Hangzhou Zhejiang
Email: hdumyj@126.com

Received: Sep. 27th, 2015; accepted: Oct. 19th, 2015; published: Oct. 26th, 2015

Copyright © 2015 by authors and Hans Publishers Inc.
This work is licensed under the Creative Commons Attribution International License (CC BY).
<http://creativecommons.org/licenses/by/4.0/>



Open Access

Abstract

The iterative multipliable update formulas are used in blind source separation algorithms based on non-negative matrix factorization (NMF). However, the methods to select the learning rates and affect algorithms' performance remain to be researched. This paper gives a derivation of different learning rates when selecting various iterative update formulas. A lot of computer simulations about these combinations are carried, and they show that a denominator of the effective iterative update formulas must contain information of the error function. In addition, its terms of denominator and numerator should be balanced.

Keywords

Non-Negative Matrix Factorization (NMF), Blind Source Separation (BSS), Learning Rates, Error Function

不同学习速率下NMF盲源分离算法

毛翊君, 赵知劲, 尚俊娜

杭州电子科技大学通信工程学院, 浙江 杭州
Email: hdumyj@126.com

收稿日期: 2015年9月27日; 录用日期: 2015年10月19日; 发布日期: 2015年10月26日

摘要

基于非负矩阵分解(NMF)的盲源分离算法采用乘性更新规则,但如何选择学习速率以及其对算法性能影响没有详细研究。对此,本文推导给出了选择不同学习速率时各种迭代更新公式,并对各种组合进行了大量计算机仿真实验,通过比较分析发现,有效的迭代更新公式的分母必须包含误差函数信息,分子分母的项数应尽可能平衡。

关键词

非负矩阵分解,盲分离,学习速率,误差函数

1. 引言

非负矩阵分解[1] [2] (Nonnegative Matrix Factorization, NMF)是盲源信号[3]分离主要理论工具之一,已引起学术界广泛关注和研究[4] [5]。为了保证分离唯一性和分离性能,需要在误差函数中添加各种约束条件[6]-[9],如:行列式约束、稀疏性约束、正交性约束等。为保证分解矩阵的非负性,一般采用乘性更新规则。由于施加了多种约束条件,利用自然梯度下降法时,可以选择多种不同的学习速率,如何选择合适的学习速率,现有文献没有给出说明。对此本文进行了理论推导和大量实验研究,为基于 NMF 盲源分离算法的深入研究提供了理论基础。

2. NMF 盲分离基本理论

令 $\mathbf{V} \in R^{m \times N}$ 表示采样信号矩阵, $\mathbf{W} \in R^{m \times n}$ 代表混合矩阵, $\mathbf{H} \in R^{n \times N}$ 代表源信号矩阵,且 $\mathbf{V} = \mathbf{W} \cdot \mathbf{H}$ 。盲源信号分离是指在源信号 \mathbf{H} 和混合过程 \mathbf{W} 未知的情况下,从观察到的多个混合信号 \mathbf{V} 中重建出源信号 \mathbf{H} 的方法。利用 NMF 进行盲源信号分离,就是要将 \mathbf{V} 分解成两个矩阵 \mathbf{W} 和 \mathbf{H} 的乘积,并使分解误差尽可能小,采用 2 范数衡量 NMF,其误差函数为 $D(\mathbf{W}, \mathbf{H}) = \frac{1}{2} \|\mathbf{V} - \mathbf{W}\mathbf{H}\|^2$ 。为了提高盲源分离算法性能,对误差函数施加行列式、稀疏性和正交性约束,设计 NMF 的优化目标函数如式(1)所示:

$$F(\mathbf{W}, \mathbf{H}) = \frac{1}{2} \|\mathbf{V} - \mathbf{W}\mathbf{H}\|^2 + \mu \text{vol}(\mathbf{W}) + \gamma J(\mathbf{H}) + \alpha K(\mathbf{H}) \quad (1)$$

$$\text{subject to } W_{ik}, H_{kj} > 0, \sum_i W_{ik} = 1, 1 \leq k \leq n$$

其中, $\text{vol}(\mathbf{W})$ 、 $J(\mathbf{H})$ 和 $K(\mathbf{H})$ 分别由式(2)、(3)和(4)给出; μ, γ, α 是平衡参数,为了保证 NMF 算法收敛,取比较小的正数。对于超定盲源分离,即 $m > n$ 情况,有

$$\text{vol}(\mathbf{W}) = \sqrt{\det(\mathbf{W}^T \mathbf{W})} \quad (2)$$

$$\min J(\mathbf{H}) = \|\mathbf{H}\|^0 = \sum_{i,j} |H_{ij}|^0 \quad (3)$$

$$\min K(\mathbf{H}) = \|\mathbf{H}\mathbf{H}^T - \mathbf{I}\| \quad (4)$$

利用自然梯度下降法,求矩阵 \mathbf{W} 和矩阵 \mathbf{H} 的更新规则分别如式(5)和(6)所示。

$$W_{ik} \leftarrow W_{ik} - \eta_w \frac{\partial F(\mathbf{W}, \mathbf{H})}{\partial W_{ik}} \quad (5)$$

$$\mathbf{H}_{kj} \leftarrow \mathbf{H}_{kj} - \eta_H \frac{\partial F(\mathbf{W}, \mathbf{H})}{\partial \mathbf{H}_{kj}} \quad (6)$$

目标函数 $F(\mathbf{W}, \mathbf{H})$ 对 \mathbf{W} 和 \mathbf{H} 的偏导分别如式(7)和(8)所示:

$$\frac{\partial F(\mathbf{W}, \mathbf{H})}{\partial \mathbf{W}_{ik}} = \left[-\mathbf{VH}^T + \mathbf{WHH}^T \right]_{ik} + \mu \det(\mathbf{W}^T \mathbf{W}) \left[\mathbf{W} (\mathbf{W}^T \mathbf{W})^{-1} \right]_{ik} \quad (7)$$

$$\frac{\partial F(\mathbf{W}, \mathbf{H})}{\partial \mathbf{H}_{kj}} = \left[-\mathbf{WV}^T + \mathbf{W}^T \mathbf{WH} \right]_{kj} + \gamma + 2\alpha \left[(\mathbf{HH}^T - \mathbf{I}) \mathbf{H} \right]_{kj} \quad (8)$$

3. 迭代更新公式

3.1. \mathbf{W} 迭代公式推导

由于非负矩阵分解要求得到的分解结果 \mathbf{W} 和 \mathbf{H} 是非负的, 所以采用乘性迭代更新公式。为了得到 \mathbf{W} 的乘性迭代更新公式, 由式(7)可见, 理论上可以选择三种不同的学习速率, 从而应该有三种不同的 \mathbf{W} 迭代更新公式。现以第一种学习速率选择为例, 具体推导如下。

\mathbf{W} 的第一种学习速率可选择为

$$\eta_w = \frac{\mathbf{W}_{ik}}{\left[\mathbf{WHH}^T \right]_{ik}} \quad (9)$$

将式(7)代入式(5)右边, 可得

$$\mathbf{W}_{ik} - \eta_w \frac{\partial F(\mathbf{W}, \mathbf{H})}{\partial \mathbf{W}_{ik}} = \mathbf{W}_{ik} - \eta_w \left[-\mathbf{VH}^T + \mathbf{WHH}^T \right]_{ik} - \eta_w \mu \det(\mathbf{W}^T \mathbf{W}) \left[\mathbf{W} (\mathbf{W}^T \mathbf{W})^{-1} \right]_{ik} \quad (10)$$

将式(12)代入上式可得

$$\mathbf{W}_{ik} - \eta_w \frac{\partial F(\mathbf{W}, \mathbf{H})}{\partial \mathbf{W}_{ik}} = \eta_w \left[\mathbf{VH}^T - \mu \det(\mathbf{W}^T \mathbf{W}) \mathbf{W} (\mathbf{W}^T \mathbf{W})^{-1} \right]_{ik} \quad (11)$$

因此可得关于 \mathbf{W} 的第一种迭代更新公式为:

$$\mathbf{W}_{ik} \leftarrow \mathbf{W}_{ik} \frac{\left[\mathbf{VH}^T \right]_{ik} - \mu \det(\mathbf{W}^T \mathbf{W}) \left[\mathbf{W} (\mathbf{W}^T \mathbf{W})^{-1} \right]_{ik}}{\left[\mathbf{WHH}^T \right]_{ik} + \varepsilon} \quad (12)$$

其中, ε 是一个很小的正数, 是为了防止分母为零。下文其他处不再说明。

\mathbf{W} 的第二种学习速率可选择为

$$\eta_w = \frac{\mathbf{W}_{ik}}{\mu \left[\det(\mathbf{W}^T \mathbf{W}) \mathbf{W} (\mathbf{W}^T \mathbf{W})^{-1} \right]_{ik}} \quad (13)$$

类似上述推导可得 \mathbf{W} 的第二种迭代更新公式为:

$$\mathbf{W}_{ik} \leftarrow \mathbf{W}_{ik} \frac{\left[\mathbf{VH}^T \right]_{ik} - \left[\mathbf{WHH}^T \right]_{ik}}{\mu \det(\mathbf{W}^T \mathbf{W}) \left[\mathbf{W} (\mathbf{W}^T \mathbf{W})^{-1} \right]_{ik} + \varepsilon} \quad (14)$$

\mathbf{W} 的第三种学习速率可选择为

$$\eta_w = \frac{\mathbf{W}_{ik}}{\left[\mathbf{W} \mathbf{H} \mathbf{H}^T \right]_{ik} + \mu \left[\det(\mathbf{W}^T \mathbf{W}) \mathbf{W} (\mathbf{W}^T \mathbf{W})^{-1} \right]_{ik}} \quad (15)$$

类似上述推导可得 \mathbf{W} 的第三种迭代更新公式为:

$$\mathbf{W}_{ik} \leftarrow \mathbf{W}_{ik} \frac{\left[\mathbf{V} \mathbf{H}^T \right]_{ik}}{\left[\mathbf{W} \mathbf{H} \mathbf{H}^T \right]_{ik} + \mu \left[\det(\mathbf{W}^T \mathbf{W}) \mathbf{W} (\mathbf{W}^T \mathbf{W})^{-1} \right]_{ik} + \varepsilon} \quad (16)$$

从式(12)、(14)和(16)可以发现, 式(12)和(16)分母中包含有误差函数信息项 $\mathbf{W}^T \mathbf{W} \mathbf{H}$, 可以有效实现对 \mathbf{W} 的更新。

3.2. \mathbf{H} 迭代公式推导

为了得到 \mathbf{H} 的乘性迭代更新公式, 由式(8)可见, 理论上 有 7 种不同的学习速率选择, 从而应该有 7 种不同的 \mathbf{H} 迭代更新公式。类似 \mathbf{W} 迭代更新公式推导, 分别可得 7 种不同的学习速率选择和 \mathbf{H} 迭代更新公式如下。

\mathbf{H} 的第一种学习速率选择为:

$$\eta_H = \frac{\mathbf{H}_{kj}}{\left[\mathbf{W}^T \mathbf{W} \mathbf{H} \right]_{kj}} \quad (17)$$

对应的 \mathbf{H} 第一种乘性迭代更新公式为:

$$\mathbf{H}_{kj} \leftarrow \mathbf{H}_{kj} \frac{\left[\mathbf{W}^T \mathbf{V} \right]_{kj} + \left[2\alpha \mathbf{H} \right]_{kj} - \gamma - \left[2\alpha \mathbf{H} \mathbf{H}^T \mathbf{H} \right]_{kj}}{\left[\mathbf{W}^T \mathbf{W} \mathbf{H} \right]_{kj} + \varepsilon} \quad (18)$$

\mathbf{H} 的第二种学习速率选择为:

$$\eta_H = \frac{\mathbf{H}_{kj}}{\gamma} \quad (19)$$

对应的 \mathbf{H} 第二种乘性迭代更新公式为:

$$\mathbf{H}_{kj} \leftarrow \mathbf{H}_{kj} \frac{\left[\mathbf{W}^T \mathbf{V} \right]_{kj} + \left[2\alpha \mathbf{H} \right]_{kj} - \left[\mathbf{W}^T \mathbf{W} \mathbf{H} \right]_{kj} - \left[2\alpha \mathbf{H} \mathbf{H}^T \mathbf{H} \right]_{kj}}{\gamma + \varepsilon} \quad (20)$$

\mathbf{H} 的第三种学习速率选择为:

$$\eta_H = \frac{\mathbf{H}_{kj}}{\left[2\alpha \mathbf{H} \mathbf{H}^T \mathbf{H} \right]_{kj}} \quad (21)$$

对应的 \mathbf{H} 的第三种乘性迭代更新公式为:

$$\mathbf{H}_{kj} \leftarrow \mathbf{H}_{kj} \frac{\left[\mathbf{W}^T \mathbf{V} \right]_{kj} + \left[2\alpha \mathbf{H} \right]_{kj} - \left[\mathbf{W}^T \mathbf{W} \mathbf{H} \right]_{kj} - \gamma}{\left[2\alpha \mathbf{H} \mathbf{H}^T \mathbf{H} \right]_{kj} + \varepsilon} \quad (22)$$

\mathbf{H} 的第四种学习速率选择为:

$$\eta_H = \frac{\mathbf{H}_{kj}}{\left[\mathbf{W}^T \mathbf{W} \mathbf{H} \right]_{kj} + \gamma} \quad (23)$$

对应的 \mathbf{H} 的第四种乘性迭代更新公式为:

$$\mathbf{H}_{kj} \leftarrow \mathbf{H}_{kj} \frac{[\mathbf{W}^T \mathbf{V}]_{kj} + [2\alpha \mathbf{H}]_{kj} - [2\alpha \mathbf{H} \mathbf{H}^T \mathbf{H}]_{kj}}{[\mathbf{W}^T \mathbf{W} \mathbf{H}]_{kj} + \gamma + \varepsilon} \quad (24)$$

\mathbf{H} 的第五种学习速率选择为:

$$\eta_H = \frac{\mathbf{H}_{kj}}{[\mathbf{W}^T \mathbf{W} \mathbf{H}]_{kj} + [2\alpha \mathbf{H} \mathbf{H}^T \mathbf{H}]_{kj}} \quad (25)$$

对应的 \mathbf{H} 的第五种乘性迭代更新公式为:

$$\mathbf{H}_{kj} \leftarrow \mathbf{H}_{kj} \frac{[\mathbf{W}^T \mathbf{V}]_{kj} + [2\alpha \mathbf{H}]_{kj} - \gamma}{[\mathbf{W}^T \mathbf{W} \mathbf{H}]_{kj} + [2\alpha \mathbf{H} \mathbf{H}^T \mathbf{H}]_{kj} + \varepsilon} \quad (26)$$

\mathbf{H} 的第六种学习速率选择为:

$$\eta_H = \frac{\mathbf{H}_{kj}}{\gamma + [2\alpha \mathbf{H} \mathbf{H}^T \mathbf{H}]_{kj}} \quad (27)$$

对应的 \mathbf{H} 的第六种乘性迭代更新公式为:

$$\mathbf{H}_{kj} \leftarrow \mathbf{H}_{kj} \frac{[\mathbf{W}^T \mathbf{V}]_{kj} + [2\alpha \mathbf{H}]_{kj} - [\mathbf{W}^T \mathbf{W} \mathbf{H}]_{kj}}{\gamma + [2\alpha \mathbf{H} \mathbf{H}^T \mathbf{H}]_{kj} + \varepsilon} \quad (28)$$

\mathbf{H} 的第七种学习速率选择为:

$$\eta_H = \frac{\mathbf{H}_{kj}}{[\mathbf{W}^T \mathbf{W} \mathbf{H}]_{kj} + \gamma + [2\alpha \mathbf{H} \mathbf{H}^T \mathbf{H}]_{kj}} \quad (29)$$

对应的 \mathbf{H} 第七种乘性迭代更新公式为:

$$\mathbf{H}_{kj} \leftarrow \mathbf{H}_{kj} \frac{[\mathbf{W}^T \mathbf{V}]_{kj} + [2\alpha \mathbf{H}]_{kj}}{[\mathbf{W}^T \mathbf{W} \mathbf{H}]_{kj} + \gamma + [2\alpha \mathbf{H} \mathbf{H}^T \mathbf{H}]_{kj} + \varepsilon} \quad (30)$$

从上述迭代更新公式可以发现, 只有式(18)、(24)、(26)和(30)含有误差函数信息项。所以 \mathbf{W} 和 \mathbf{H} 的乘性迭代更新公式可行组合形式如表 1 所示。

4. 算法仿真与性能分析

源信号图像如图 1 所示, 随机产生非负混合矩阵, 经过混合得到混合的图像信号。经过大量的仿真实验得到平衡参数的合适取值分别为: $\gamma = 0.001$ 、 $\mu = 50$ 和 $\alpha = 0.00001$, 利用迭代公式更新 \mathbf{W} 和 \mathbf{H} , 迭代 30,000 次, 更新迭代终止, 最终得到由混合信号矩阵 \mathbf{V} 分离出的混合矩阵 \mathbf{W} 和源信号 \mathbf{H} 。

4.1. 迭代公式组合的有效性分析

大量的实验表明, 分母中不含有误差函数信息的迭代公式无法有效更新 \mathbf{W} 和 \mathbf{H} , 分离不出源信号, 与我们前文判断一致。

现通过实验验证八种不同的迭代公式组合是否有效。应用上述八种迭代更新公式组合分离上述混合信号, 算法能正常运行的用√表示, 不能正常运行的用×表示, 结果如表 1 所示。由表可见, 即使八种组

合分母中都包含了误差函数信息，但也只有三种组合方式是有效的，即组合 3、组合 4 和组合 7，所以可以得到三种算法，分别称为算法 1、算法 2 和算法 3。分析这三组迭代公式可见，迭代公式的分子分母项数基本平衡。

4.2. 三种算法性能分析

三种算法分离得到的图像信号分别如图 2 至图 4 所示。三种算法 10 次分离得到的源信号重构平均信噪比 SNR 如表 2 所示。由表 2 可见，算法 2 性能最好，算法 1 次之，算法 3 略差；三种算法性能在同一数量级，都能够较好地分离出源信号。

Table 1. Probability analysis of different iterative formulas

表 1. 不同迭代公式组合的可行性分析

方法	可行性
组合 1: 式(12)和式(18)	×
组合 2: 式(12)和式(24)	×
组合 3: 式(12)和式(26) (算法 1)	√
组合 4: 式(12)和式(30) (算法 2)	√
组合 5: 式(16)和式(18)	×
组合 6: 式(16)和式(24)	×
组合 7: 式(16)和式(26) (算法 3)	√
组合 8: 式(16)和式(30)	×

Table 2. SNR of three algorithms

表 2. 三种算法的重构平均信噪比(单位: dB)

图像编号	图 1	图 2	图 3	图 4
算法 2	6.4819	13.0446	12.0084	8.6149
算法 1	6.4619	12.7737	11.1487	8.5825
算法 3	6.3913	12.0751	10.8859	8.8719



Figure 1. Source image signal

图 1. 源图像信号



Figure 2. Picture of Algorithm 1

图 2. 算法 1 分离的图像信号



Figure 3. Picture of Algorithm 2
图 3. 算法 2 分离的图像信号



Figure 4. Picture of Algorithm 3
图 4. 算法 3 分离的图像信号

5. 结束语

本文研究了学习速率选择对 NMF 的盲源分离算法性能影响。首先推导给出了选择不同学习速率时各种迭代更新公式，然后进行了大量计算机仿真实验，最后通过比较分析发现，有效的迭代更新公式的分母必须包含误差函数信息，分子分母的项数应尽可能平衡。

致 谢

首先，我要感谢我的导师赵知劲教授。如果不是赵老师的悉心指导，无私地提出宝贵的修改意见，就不会呈现出这样一篇内容详实、推导严谨的论文。紧接着，我要感谢我的家人。在我专注于论文写作的过程中，是他们的鼓励与理解，让我得以全身心地投入我的写作，同时也激励着我去不断完善我的论文。最后，我要感谢所有帮助过我的老师和同学，这篇论文是大家共同智慧的结晶。再次感谢。

参考文献 (References)

- [1] Lee, D.D. and Seung, H.S. (1999) Learning the parts of objects by non-negative matrix factorization. *Nature*, **401**, 788-791.
- [2] 李乐, 章毓晋 (2008) 非负矩阵分解算法综述. *电子学报*, **36**, 737-743.
- [3] 马建仓, 牛奕龙, 陈海洋 (2006) 盲信号处理. 国防工业出版社, 北京.
- [4] 殷海青, 刘红卫 (2010) 一种基于 L1 稀疏正则化和非负矩阵分解的盲源信号分离新算法. *西安电子科技大学学报*, **37**, 835-841.
- [5] Zdunek, R. and Cichocki, A. (2007) Nonnegative matrix factorization with constrained second-order optimization. *Signal Processing*, **87**, 1904-1916. <http://dx.doi.org/10.1016/j.sigpro.2007.01.024>
- [6] 张倩 (2013) 水声信号盲源分离方法研究. 硕士论文, 哈尔滨工业大学, 哈尔滨.
- [7] 卢宏, 赵知劲, 杨小牛 (2011) 基于行列式和稀疏性约束的 NMF 的欠定盲分离方法. *计算机应用*, **31**, 553-555+558.
- [8] Wang, S., et al. (2014) A K-L divergence constrained sparse NMF for hyperspectral unmixing signal. *Proceedings of 2014 IEEE International Conference on Security, Pattern Analysis, and Cybernetics*, Wuhan, 18-19 October 2014, 223-228. <http://dx.doi.org/10.1109/SPAC.2014.6982689>
- [9] 张宇飞 (2010) 加稀疏约束的非负矩阵分解. 硕士论文, 大连理工大学, 大连.