

优化的 PCNN 自适应三维图像分割算法*

唐 宁, 江贵平, 吕庆文

(南方医科大学 生物医学工程学院, 广州 510515)

摘 要: 脉冲耦合神经网络(pulse coupled neural network, PCNN)对图像分割具有天然的优势,但是传统的 PCNN 模型参数难以确定,且算法耗时多。对多种 PCNN 模型进行研究改进,并利用统计学知识提出了一种精简高效的自适应三维分割算法。将其用于脑部磁共振成像(magnetic resonance imaging, MRI)图像的分割,把脑组织分成白质、灰质和脑脊液。与标准 PCNN、传统的 Otsu 阈值方法、SPM8 工具箱及专家手动分割结果的对比实验表明,该自适应算法具有精确性、高效性。

关键词: 优化脉冲耦合神经网络;自适应三维分割;脑磁共振成像

中图分类号: TP391 **文献标志码:** A **文章编号:** 1001-3695(2012)04-1591-04

doi:10.3969/j.issn.1001-3695.2012.04.110

Adaptive 3D image segmentation based on optimized PCNN

TANG Ning, JIANG Gui-ping, LV Qing-wen

(College of Biomedical Engineering, Southern Medical University, Guangzhou 510515, China)

Abstract: The segmentation algorithm with PCNN model has many natural advantages. But the typical PCNN model has too many parameters difficult to determinate and consumes too much time. This paper proposed an effective three dimension image segmentation model that integrated multiple PCNN models and the statistical model. It was used to segment brain MRI image into gray matter(GM), white matter(WM) and cerebrospinal fluid(CSF). And the segmentation results were compared with those of standard PCNN, traditional Otsu threshold, SPM8 toolbox and expert segmentation. It demonstrates this adaptive method is fairly accurate and effective.

Key words: optimized PCNN; adaptive 3D segmentation; brain MRI

PCNN 是依据猫、猴等动物的大脑皮层同步脉冲发放现象提出的一种新型神经网络,已广泛地应用于图像处理、目标识别、决策优化和通信等方面^[1]。由于这种网络的背景具有生物学基础,使其在图像分割方面具有天然的优势^[2,3]。但 PCNN 难以恰当设置其数学模型中的门限参数、衰减时间常数、加权因子等,其循环迭代的终止条件的确定更是一个难题,故单独的 PCNN 很难满足图像处理各种不同的需求,还需要对其进行优化并结合其他相关模型以达到更好的应用效果。因此,很多优化的 PCNN 模型被提出来,如 Xiao 等人^[4]在脉冲发生部分使用常数阈值代替动态阈值,Eckhorn 等人^[1]提出一种简化链接输入和反馈输入的 PCNN 模型。本文在结合上述方法优点的基础上提出了一种更为简洁的 PCNN 模型。

1 优化的 PCNN 模型

构成 PCNN 的单个神经元的基本模型如图 1(a)所示,神经元由接收、调制和脉冲产生器三部分组成。利用 PCNN 进行图像处理时,网络结构与图像结构相同,即神经元与图像像素一一对应。为了表述方便,下面以二维 PCNN 为例分析模型结构。

接收部分接收来自其他神经元与外部的输入。接收部分收到输入后,将其通过两条通道传输。其中一条通道称为 F 通道,另一通道称为 L 通道。




图1 PCNN模型

$$F_{ij}[n] = e^{-\alpha_F} F_{ij}[n-1] + V_F \sum m_{ijkl} Y_{kl}[n-1] + S_{ij} \quad (1)$$

$$L_{ij}[n] = e^{-\alpha_L} L_{ij}[n-1] + V_L \sum w_{ijkl} Y_{kl}[n-1] \quad (2)$$

式(1)和(2)中,下标 ij 表示位置 (i, j) 处的神经元; F_{ij} 、 L_{ij} 分别为第 (i, j) 个神经元的反馈输入和链接输入; S_{ij} 为外部输入刺激信号,这里为输入图像中第 (i, j) 个像素的密度; m 和 w 分别是反馈输入和链接输入中神经元之间的连接权重系数矩阵; α_F 和 α_L 分别为神经元 N_{ij} 对其邻域内的其他神经元输出进行漏电容积分的连接时间常数,一般情况下,神经元 N_{ij} 与所有相连神经元之间的反馈域时间常数均相同,链接域时间常数也相同; V_F 、 V_L 分别为反馈域、链接域的幅度系数; n 为第 n 时刻; Y_{ij} 为 PCNN 第 (i, j) 个神经元 N_{ij} 的脉冲输出。

调制部分中,先给链接输入加一个正的单位偏置,然后与反馈输入进行相乘调制,乘积就是神经元内部活动项 U 。

$$U_{ij}[n] = F_{ij}[n](1 + \beta L_{ij}[n]) \quad (3)$$

模型中常数 1 为规整偏移量, β 为神经元之间的链接强度。只要链接输入 L 不为零, U 就会大于反馈输入 β 。

收稿日期: 2011-09-02; 修回日期: 2011-10-07 基金项目: 广东省科技计划重点资助项目(2009B010800019)

作者简介: 唐宁(1986-),男,湖南衡阳人,硕士研究生,主要研究方向为图像分割(elegantfox@163.com);江贵平(1971-),男,教授,博士,主要研究方向为三维可视化、机器学习;吕庆文(1970-),男,副教授,主要研究方向为图像处理。

脉冲产生部分由阈值可变的比较器和脉冲产生器组成。当神经元输出一个脉冲,神经元的阈值就通过反馈迅速得到提高(见式(4))。当神经元的阈值 θ 超过 U 时,脉冲产生器就停止生产脉冲,神经元不点火(见式(5))。接着,阈值 θ 就开始指数下降,当 θ 低于 U 时,脉冲产生器被打开,神经元就被点火,即处于激活状态,输出一个脉冲或脉冲序列。

$$\theta_{ij}[n] = e^{-\alpha_{\theta}} \theta_{ij}[n-1] + V_{\theta} Y_{ij}[n-1] \quad (4)$$

$$Y_{ij}[n] = \begin{cases} 1 & \text{if } U_{ij}[n] > \theta_{ij}[n] \\ 0 & \text{otherwise} \end{cases} \quad (5)$$

其中: V_{θ} 为阈值输出的幅度系数, α_{θ} 为动态阈值函数的衰减时间常数。由式(5)可知,当内部活动项 U 超过阈值 θ 时,该神经元的阶跃函数发生器输出 1,否则为 0,即神经元的输出是二值变量。

在标准 PCNN 模型中,利用了生物神经元的阈值指数衰减特性,虽然这种阈值变化规律符合人眼对亮度响应的非线性特性,但对于计算机处理显然没必要^[5]。因此采用线性衰减方式调整动态阈值,不仅使模型更为简单,同时减少了算法的计算量^[6]。更进一步,由于模型达到平衡状态时的阈值对应最佳分割阈值,可以利用图像的先验知识直接得到最优分割阈值作为脉冲产生部分的点火阈值(如图 1(b)),这样就大大减少了迭代带来的计算量^[8]。

除此之外,目前对于 PCNN 的优化主要集中在输入部分^[1,7-9]。Eckhorn 将输入部分按如下公式进行优化:

$$F_{ij}[n] = S_{ij} \quad (6)$$

$$L_{ij}[n] = V_L \sum w_{jkl} Y_{kl}[n-1] \quad (7)$$

即神经元的反馈输入等于外部刺激,链接输入只与神经元上一次的输出有关系。Yao 等人^[10]将这个模型应用于视网膜血管的分割,证明了这种方法的可靠性。

本文在结合上述方法优点的基础上,对 PCNN 作了进一步的优化(如图 1(c))。改进后的神经元模型表达式如下:

$$F_{ij}[n] = S_{ij} \quad (8)$$

$$L_{ij}[n] = \sum w_{jkl} Y_{kl}[n-1] \quad (9)$$

$$U_{ij}[n] = F_{ij}[n] \times L_{ij}[n] \quad (10)$$

$$\theta_{ij}[n] = \text{const} \quad (11)$$

$$Y_{ij}[n] = \begin{cases} 1 & \text{if } U_{ij}[n] > \theta_{ij}[n] \\ 0 & \text{otherwise} \end{cases} \quad (12)$$

其与现有方法不同的地方主要有四点:a)简化了反馈输入部分,使其仅接收外部刺激(如式(8)),相对于传统模型需要依赖上次迭代的反馈输入,简化后的模型可避免由于参数设置不当而使神经元输出陷入局部最优值点;b)调整链接输入部分,去掉幅度系数项(如式(9)),并使用归一化连接权值系数 w 且使其中心神经元的权值略大于所有邻接神经元权值之和,这样,中心神经元只受邻接神经元的整体影响而不会受个别邻接神经元的干扰,具有较强的抗干扰性;c)优化内部活动项,使其为链接输入与反馈输入的乘积(如式(10)),则内部活动项表达的灰度变化意义更明确,模型对图像密度变化的反应更敏感,增强了 PCNN 的精确性;d)采用常数阈值,结合 Xiao 等人提出的方法,大大减少了神经网络的参数,解决了 PCNN 用于图像分割中其参数难以确定的问题。

熵是图像统计特性的一种表现形式,反映了图像包含信息量的大小。对于绝大多数图像来说,不管采用何种分割算法,一般分割后图像熵值越大,说明分割后从原图得到的信息量越大,分割图像细节越丰富,因而总体分割效果也越好^[11]。将此特性应用于本文提出的 PCNN 图像分割中,使该算法成为一种

自适应的自动分割算法。在具体算法中,当 PCNN 在每次循环迭代结束时计算其分割输出的二值图像(即点火图像 $Y[n]$)的信息量,即熵值 $H(p)$:

$$H(p) = -(p_0 \log_2 p_0 + p_1 \log_2 p_1) \quad (13)$$

其中: p_0, p_1 分别表示 $Y[n]$ 的元素为 1 或为 0(神经元点火或不点火)的概率。当熵值 $H(p)$ 最大值时结束迭代,此时的输出对应最优分割结果。

在文章的后续部分,将运用上述改进的优化 PCNN 模型扩展到三维空间,并结合其他方法把脑组织分割为灰质、白质、脑脊液。

2 脑组织的三维分割

MRI 以其非介入性、非损伤性、受目标物体运动的影响较小等特点,已被广泛运用于医学图像拍摄。人脑 MRI 图像的分析对脑部解剖、精神疾病等的分析研究具有重要的指导意义^[12]。由于脑 MR 图像的复杂性^[13]以及临床医学应用的需要^[14],将脑 MRI 图像的灰质、白质、脑脊液进行精确可靠的分割,是现代医学图像处理的难点和热点。

磁共振脑图像比较复杂,脑部各组织之间相互混叠且没有清晰的边界,不同个体之间的差异性较大,以及成像过程中磁场的均匀性、部分容积效应和噪声的影响造成的图像内在不确定性等,使分割问题显得更为复杂和困难。本文先利用脑部 MRI 图像的先验知识将脑与头颅组织分离,然后再利用优化的 PCNN 将脑组织分割为灰质、白质、脑脊液。为了充分利用脑部 MRI 图像的先验知识以及提高算法的速度,本文所有的操作都在三维空间完成。

2.1 预处理

在图像分割过程中,如果对图像的内容有更多的先验知识,那么就能设计更精确的分割算法,引入先验知识越多,算法对图像的分割也越精确^[15]。一般来说,根据磁共振脑图像的特点,可以依赖图像的密度、组织位置、组织形态等特征来设计分割算法,从而在算法中体现先验知识,使图像的可分割性加大。

本文中,预处理的目的是为了将脑与头颅组织分离,并且根据脑组织的直方图分析得到白质与灰质、灰质与脑脊液的最优分割阈值。先对三维图像采用 Otsu(大津法,最大类间方差法)^[16,17]去除背景得到脑和头颅组织数据;然后采用三维形态学开操作(先腐蚀再膨胀)去除脑和头颅组织的连接部分;再用三维区域增长得到完整的脑组织;最后分析脑组织数据的直方图,得到两个阈值。具体的分割过程如下(步骤 a)~c)对应的结果如表 1 所示):

a)阈值法去除背景。在三维空间,脑部 MRI 图像的背景与目标具有明显的分界,对原始的三维数据进行 Otsu 分割即可去除低密度的背景区域,得到完整的脑与头颅组织的二值图像。

b)形态学分离脑和头颅组织连接。多数情况下,通过域值分割无法分开脑组织和头颅组织,它们在视神经、垂体、脑膜组织等处存在一些细小的连通区域。形态学开操作作为解决这个问题提供了一个有效的方法。

c)区域增长得到完整脑组织。由上述的先验知识可知,脑组织位于图像中央并占有较大比例,并且考虑到脑室所在的位置,因此将种子点自动设在图像中部偏左,并进行局部验证即可。经过三维区域增长后得到脑组织的二值图像,将其与原

图像相乘,则得到原始的脑组织数据。

d)分析脑组织直方图得到两个阈值。脑组织的统计直方图(图2(a))具有三个明显的波峰,按灰度从大到小分别代表白质、灰质、脑脊液,但是直方图在局部仍不光滑,存在较小的波谷(图2(a))。由于获取的直方图符合高斯分布特点,一般采用高斯分布来对直方图进行拟合^[13],得到只有三个波峰的平滑曲线。对于拟合后的直方图,采用波谷作为相邻两类组织的最佳分割阈值(白质与灰质的阈值、灰质与脑脊液的阈值)(图2(b))。



表1 预处理过程

步骤	三维图像	第30层	第50层	第70层	第90层	第110层
原始图像						
a)						
b)						
c)						

2.2 三维优化PCNN分割

经过预处理得到了完整的脑组织数据以及两个最优分割阈值。由于白质密度偏大,先分割出白质,然后从剩下的部分中分离出灰质。另外,脑脊液对于医学诊断没有辅助意义,则直接从脑组织数据中减去白质与灰质,得到脑脊液图像。

传统的PCNN用于分割时,参数往往是根据关于某类图像以往的经验或不断试探得到的。本文提出的优化PCNN图像分割方法只需要设置连接权系数,解决了PCNN图像分割参数选择的难题。针对传统神经网络空间上部分不连接的缺陷,本文规定每个神经元(边缘处例外)与其邻接的26个神经元相连,并采用归一化的连接权系数。为使中心部位的神经元权值略大于所有邻接神经元权值之和,采用由远到近分别将它们的连接权值设为 $1/108$ 、 $2/108$ 、 $3/108$,并且将中心神经元的权值设为 $58/108$ (图3)。



设前面得到的脑组织图像为 S ,分割阈值为 T ,最大熵值为 H_m ,最大熵值对应的分割结果为 $Rslt$,每次迭代过程中的熵值为 H_i 。另外,为了避免神经元的输出结果始终无法达到最大熵值而使算法进入无限迭代状态,文中规定最大迭代次数为 N_m 。具体的算法流程如下:

- 初始化参数。按上述模型初始化连接权系数 w ;令 $F_{ijk}[n] = S_{ijk}$, $Y_{ijk}[0] = 1$, $H_m = 0$, $Rslt_{ijk} = 0$ 。
- 计算内部活动项 $U_{ijk}[n]$ 及输出。 $L_{ijk}[n] = \sum w_{ijklmn} Y_{lmn}[n-1]$, $U_{ijk}[n] = F_{ijk}[n] \times L_{ijk}[n]$;如果 $U_{ijk}[n] > T$, $Y_{ijk}[n] = 1$, 否则 $Y_{ijk}[n] = 0$ 。
- 计算最大互信息熵。通过 $Y[n]$ 计算得到本次分割结果

的熵值 H_i ,如果 $H_i > H_m$,则 $H_m = H_i$,且 $Rslt = Y[n]$ 。

d)判断迭代是否结束。如果到达最大阈值或 $n > N_m$,则结束迭代, $Rslt$ 即为分割结果;否则返回到步骤b)。

通过上面算法,分别分割出白质和灰质,然后由脑组织图像减去白质与灰质得到脑脊液,如表2所示。

表2 本文方法分割结果

组织	三维图像	第30层	第50层	第70层	第90层	第110层
白质						
灰质						
脑脊液						

3 实验结果

为验证算法的精确性与效率,本文选择选用McGill大学McConnell脑图像中心的在线图像库提供的图像进行分割,并与传统的Otsu全局阈值法及SPM8工具箱分割的结果进行了比较。另外,采用哈佛大学附属医院Massachusetts General脑部形态分析中心的网络图像标准分割库(Internet brain segmentation repository, IBSR)提供的20组正常人的脑部MRI图像作为实验数据,比较本文算法、标准PCNN算法、Otsu法、SPM8工具箱与专家手动分割结果的重叠率(overlap rate)。

采用Otsu全局阈值法对相同数据进行分割,先使用相同的预处理方法,然后分割出三类组织,如表3所示。可以看出,结果图像边缘粗糙,密度分布不均匀,噪点比较多。

表3 Otsu分割结果

组织	三维图像	第30层	第50层	第70层	第90层	第110层
白质						
灰质						

SPM8是一个MATLAB工具箱,已广泛用于磁共振图像的分析,具有较高的分割精度。其提供的分割算法使用MATLAB实现,所需时间较多,对大小为 $256 \times 256 \times 150$ 的脑部数据进行分割需要8 min以上。而在不考虑运行效率的情况下,它的分割功能为脑部结构及功能分析提供了良好的预处理步骤^[18]。由于SPM8分割出了颅内全部的白质、灰质及脑脊液,本文为了实验数据的同一性,亦使用相同的预处理方法得到脑组织,然后用SPM8对脑组织进行分割,结果如表4所示。该方法分割的结果孤立点比较少,边缘平滑完整,密度均匀。而本文方法边缘同样比较平滑,但是可以分割出孤立的区域,与视觉效果相差不大,这也反映了PCNN分割的优点。

表4 SPM8分割结果

组织	三维图像	第30层	第50层	第70层	第90层	第110层
白质						
灰质						

重叠率是用于刻画分割精度的一个通用指标,表示用不同分割方法得到的结果的体素重叠情况。一般用自定义方法与专家手动分割的结果相比较,重叠率越高,表示该方法分割精度越

高(详情见 <http://www.cma.mgh.harvard.edu/ibsr/>)。

表 5 给出了本文算法、标准 PCNN 算法、Otsu 法、SPM8 提供的方法与 IBSR 专家分割结果的灰质、白质平均重叠率,其中专家分割的重叠率通过比较两位专家的分割结果得到。

表 5 分割结果重叠率对照

方法	白质	灰质
本文算法	0.604	0.609
标准 PCNN	0.592	0.604
Otsu	0.497	0.453
SPM8	0.601	0.631
专家分割	0.832	0.876

可以看出,本文优化的 PCNN 算法分割精度要远远高于 Otsu 方法,同时在大大提高分割速度的情况下仍比标准 PCNN 算法要略高一些。但是灰质的重叠率比 SPM8 提供的方法要低一些,而由于 SPM8 比较难以分割出孤立性区域等原因,使本文提出的方法对于白质分割的重叠率要稍高一些。

本文所涉及的算法皆采用 C++ 在 CPU 为 2.66 GHz,内存为 2 GB 的台式机上实现。McConnell 脑图像中心提供的图像规格为 $181 \times 217 \times 181$,层间距为 1 mm。IBSR 提供的图像单层大小为 256×256 ,层数在 60 ~ 67 之间。实验最后对本文优化的 PCNN 与标准 PCNN 算法的时效性进行对比,如表 6 所示。在相同条件下,本文算法比标准 PCNN 分割所需时间大大减少,能够满足临床快速分割的需求。

表 6 两种 PCNN 算法分割耗时对照

数据来源	本文算法	标准 PCNN
McConnell	约 7 s	约 64 s
IBSR	约 6 s	约 51 s

4 结 束 语

本文在结合其他改进的 PCNN 分割算法优点的基础上,提出了一种更精简、高效的三维 PCNN 分割算法,并对脑部 MRI 图像进行仿真实验。该算法无须选取参数,使用最大熵原则控制迭代次数,可迅速而准确地提取图像的边缘,保留丰富的细节信息,有效地保证了医学图像边缘的连续性、完整性,具有较强的自适应性。

参考文献:

- [1] ECKHORN R, REITBOECK H J, ARNDT M, *et al.* Feature linking via synchronization among distributed assemblies: simulations of results from catvisual cortex[J]. *Neural Computation*, 1990, 2(3): 293-307.
- [2] LU Yun-feng, MIAO Jun, DUAN Li-juan, *et al.* A new approach to image segmentation based on simplified region growing PCNN[J]. *Applied Mathematics and Computation*, 2008, 205(2): 807-814.
- [3] 赵勇,陈立潮,张英俊,等. 基于模糊熵的改进型 PCNN 图像分割方法[J]. *计算机技术与发展*, 2009, 19(10): 141-144.
- [4] XIAO Zhi-heng, SHI Jun, CHANG Qian. Image segmentation with simplified PCNN[C]//Proc of the 2nd International Congress on Image and Signal Processing, 2009: 1-4.
- [5] 毕英伟,邱天爽. 一种基于简化 PCNN 的自适应图像分割方法[J]. *电子学报*, 2005, 33(4): 647-650.
- [6] 陈兴杰,柴晓冬. 一种基于简化 PCNN 的红外图像分割方法[J]. *安徽大学学报*, 2010, 34(1): 74-77.
- [7] LIU Qing, MA Yi-de, ZHANG Shao-gang, *et al.* Image target recognition using pulse coupled neural networks time matrix[C]//Proc of the 26th Chinese Control Conference, 2007: 96-99.
- [8] JI Lu-ping, YI Zhang. A mixed noise image filtering method using weighted-linking PCNNs[J]. *Neurocomputing*, 2008, 71(13-15): 2986-3000.
- [9] MA Yi-de, LIN Dong-mei, ZHANG Bei-dou, *et al.* A novel algorithm of image enhancement based on pulse coupled neural network time matrix and rough set[C]//Proc of the 4th International Conference on Fuzzy Systems and Knowledge Discovery. Washington DC: IEEE Computer Society, 2007: 86-90.
- [10] YAO Chang, CHEN Hou-jin. Automated retinal blood vessels segmentation based on simplified PCNN and fast 2D-Otsu algorithm[J]. *Journal of Central South University of Technology*, 2009, 16(4): 640-646.
- [11] 马义德,戴若兰,李廉. 一种基于脉冲耦合神经网络和图像熵的自动图像分割方法[J]. *通信学报*, 2002, 23(1): 46-51.
- [12] 张建伟,陈允杰,夏德深. 基于高斯混合模型的脑部 MR 图像自动分割[J]. *计算机工程与应用*, 2006, 42(24): 207-210.
- [13] 周震,马斌荣. 结合水平集和区域生长的脑 MR 图像分割[J]. *北京生物医学工程*, 2007, 26(1): 44-47.
- [14] FU J C, CHEN C C, CHAI J W, *et al.* Image segmentation by EM-based adaptive pulse coupled neural networks in brain magnetic resonance imaging[J]. *Computerized Medical Imaging and Graphics*, 2010, 34(4): 308-320.
- [15] 曹会志,罗述谦. 基于自动策略的脑图像分割[J]. *中国医学影像技术*, 2007, 23(2): 303-306.
- [16] OTSU N. A threshold selection method from gray-level histograms[J]. *IEEE Trans on Systems, Man, and Cybernetics*, 1979, 9(1): 62-66.
- [17] JEKIC M, DING Yu, DZWONCZYK R, *et al.* Magnetic field threshold for accurate electrocardiography in the MRI environment[J]. *Magnetic Resonance in Medicine*, 2010, 64(6): 1586-1591.
- [18] BITTER T, BRÜDERLE J, GUDZIOL H, *et al.* Gray and white matter reduction in hypoxic subjects: a voxel-based morphometry study[J]. *Brain Research*, 2010, 1347: 42-47.
- [8] YE J P, JANARDAN R, LI Q. Two-dimensional linear discriminant analysis[C]//Proc of Neural Information Processing Systems Conference, 2004.
- [9] LEE, J H, PARK S, AHN C M, *et al.* Automatic generic document summarization based on non-negative matrix factorization[J]. *Information Processing and Management*, 2009, 45(1): 20-34.
- [10] LIN C J. Projected gradient methods for non-negative matrix factorization[J]. *Neural Computation*, 2007, 19(10): 2756-2779.
- [11] GANDINI M, LDMBARDI F, VACCARINO F. Blind separation of manufacturing variability with independent component analysis: a convolutive approach[J]. *Expert Systems with Applications*, 2011, 38(8): 9939-9946.

(上接第 1590 页)

- [4] ZUO Wang-meng, ZHANG Hong-zhi, ZHANG D, *et al.* Post-processed LDA for face and palmprint recognition: what is the rationale[J]. *Signal Processing*, 2010, 90(8): 2344-2352.
- [5] WANG Jian-gang, SUNG E, YAU Wei-yun. Incremental two-dimensional linear discriminant analysis with applications to face recognition[J]. *Journal of Network and Computer Applications*, 2010, 33(3): 314-322.
- [6] YANG Wan-kou, YAN Xiao-yong, ZHANG Lei, *et al.* Feature extraction based on fuzzy 2DLDA[J]. *Neurocomputing*, 2010, 73(10-12): 1556-1561.
- [7] 张志伟,夏克文,杨帆,等. 一种应用于人脸识别的有监督 NMF 算法[J]. *光电子·激光*, 2007, 18(5): 622-624.