

文章编号:1001-9081(2007)06-1497-03

## 基于单输出型神经网络的血细胞分类研究

毕 峰<sup>1,2</sup>

(1. 辽东学院 计算中心,辽宁 丹东 118000; 2. 大连理工大学 电信学院,辽宁 大连 116024)  
(davis\_bf@126.com)

**摘要:** 分别利用 BP 神经网络与单输出型神经网络对已经得到的血细胞特征参数进行计算,设计出分类器对血细胞进行自动分类识别。单输出型神经网络分类器与 BP 神经网络分类器相比,具有设计简单、收敛速度快、识别精度高且更加稳健的优点,取得了较好的应用效果。

**关键词:** 模式识别; 神经网络; 分类器

**中图分类号:** TP183; TP391.41      **文献标识码:**A

### Blood cell's classification based on single-output artificial neural network

BI Feng<sup>1,2</sup>

(1. Computer Center, Liaodong University, Dandong Liaoning 118000, China;  
2. School of Electronic and Information Engineering, Dalian University of Technology,  
Dalian Liaoning 116024, China)

**Abstract:** The blood cell's characteristic parameters that have been obtained previously were processed with both BP Neural Network and Single-output Neural Network in order to classify the blood cells automatically. Compared with the BP Neural Network, the Single-output Neural Network is affirmed with more effective result due to a few advantages such as simpler design, faster convergence speed, higher accuracy of recognition and better robustness.

**Key words:** pattern recognition; artificial neural network; classifier

应用数字图像处理、模式识别和人工智能技术对血细胞显微图像进行自动识别是现代医学影像技术的代表性研究课题之一,具有重要的临床价值,与人工识别方法相比,既提高了效率又使分析结果更具有客观性。随着模式识别理论和人工神经网络的不断发展,许多新成果已经应用于商品化细胞自动分析系统中<sup>[1]</sup>。但是,目前的通用细胞分析系统还存在着价格昂贵、性能不够稳定以及实时处理困难等一些问题,所以,首先研制开发基于微型计算机的专用细胞识别分析系统具有很大的实用价值。本文主要完成对受到病菌感染的显微图像中正常与异常血细胞的自动识别分类任务,首先把采集到的血细胞图像做去噪、增强、分割及二值化等预处理<sup>[2]</sup>,然后提取细胞的特征参数,最后设计出合适的分类器完成对血细胞的识别工作。在对细胞图像的分析识别阶段,分别使用三层 BP 神经网络和单输出级联型神经网络设计分类器,通过实验发现,二者都能够完成分类任务,但三层 BP 网络针对该问题存在收敛速度慢及网络对参数过于敏感的不足;而单输出型网络由于充分利用了血细胞图像的特征,具有设计简单、训练速度快与稳健性好等优点,能够更好地完成识别任务。

### 1 多层前馈神经网络及两种应用模型

#### 1.1 多层前馈神经网络

人工神经网络<sup>[3]</sup>按照网络拓扑结构可分为前馈网络和反馈网络两大类。所谓反馈网络是指它的输出信号通过与输入连接而返回到输入端;而前馈网络的特点是信号的流向只从输入通向输出。

将两个或多个神经元并联起来,即可组成一个神经元层,其中每一个神经元产生一个输出,这样的网络就是单层

神经网络;将两个以上的单层神经网络级联起来则组成多层神经网络,它的第一层称为输入层,最后一层称为输出层,其他的中间层称为隐含层,所以一个多层网络至少有三层,即输入层、输出层和一个隐含层。

具有前馈网络结构的多层网络就是多层前馈网络,在一定条件下,三层前馈网络可以逼近任意的多元非线性函数。多层前馈神经网络用于监督模式识别时,一般有以下 2 种应用模型<sup>[4]</sup>。

#### 1.2 多输出网络模型与单输出网络模型

在多输出网络模型中,网络每 1 个输入节点对应样本的 1 个特征,而输出层节点数等于应分的类别数,1 个输出节点对应 1 个类。在训练阶段,如果输入训练样本的类别标号为  $i$ ,则训练时的期望输出设为第  $i$  个节点为 1,而其余输出节点均为 0;在识别阶段,当一个未知类别的样本作用到输出端时,考查各输出节点的输出,并将这个样本的类别判定为与输出值最大的那个节点对应的类别,在某些情况下,如果输出最大的节点与其他节点输出的差距较小(小于某个预设值),则可以做出判决决策。

而在单输出网络模型中,网络的每 1 个输入节点对应样本 1 个特征,而输出层节点只有 1 个。为每个类建立 1 个这样的网络,对每 1 类分别进行训练,将属于这 1 类的样本期望输出设为 1,而把属于其他类的样本期望输出设为 0。在识别阶段,将未知类别的样本输入到每 1 个网络,如果某个网络的输出接近 1(或大于某个预设值),则判断该样本属于这 1 类。

多输出网络模型是用多层前馈网络进行模式识别的最基本方式,尤其是多层 BP 网络能够解决各种复杂的分类问题,但是很多实验表明,在多输出方式中,由于网络要同时适应所

有类别,势必需要更多的隐层节点,当待分类的问题很复杂时,学习过程往往收敛较慢,且容易陷入局部极小,当样本类别之间耦合严重时,甚至会造成网络无法收敛;此时可以采用多个单输出型网络,让每个网络只完成识别 2 类的分类,经常可以取得更好的效果。显然,在每个识别 2 类问题中,只需要一个单输出型网络即可,这就使得训练网络的速度大大加快,把多个这样的单输出型网络级联仍然可以用来解决复杂的分类问题。与多输出网络相比,单输出网络具有更快的训练速度和识别速度,从而更加适用于实时任务。

## 2 血细胞模式识别问题及分类器设计

### 2.1 血细胞模式识别问题描述

血细胞显微图像分析系统的工作流程如图 1 所示,简单说明如下:

图像采集:取受到病菌感染的血液样本制成薄血膜涂片,并用姬氏染色法染色。使用 XSJ—2 型显微镜与东芝数码摄像头相连接,采集软件为 MV2000 显微数字图像分析软件,放大倍数为 400 倍,通过图像采集卡获得相应血细胞的真彩色图像。

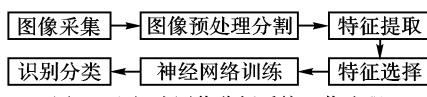


图 1 血细胞图像分析系统工作流程

图像预处理及分割:把原始图像转换为灰度图像并进行滤波去噪、增强等预处理,采用自适应阈值化方法二值化图像并进行分割与标记处理。

细胞特征提取与选择:按照特定算法,获得细胞图像的各种特征参数并加以选择,找出最有效的若干特征作为分类依据,达到分离正常与异常细胞的目的。

神经网络分类器:使用部分典型细胞的特征值对神经网络进行训练,收敛后即可作为分类器,实现对正常与异常细胞的自动识别。

### 2.2 两种不同的分类器设计与实验

首先按照图 1 的步骤对采集到的受病菌感染的血细胞图像进行预处理及分割,然后提取出单个细胞的特征值。经分析发现,在图像的识别阶段,每幅二值化后的受感染血细胞显微图像中共有大约 100 个细胞,可以分为 4 类,再加上预处理阶段没有被去除的较大噪声点共有 5 种目标需要识别,如图 2 所示。



其中,一类为正常细胞;二类为受到病菌感染的异常细胞;三类为粘连细胞;四类为处于图像边界位置的不完整细胞;五类为图像中的噪声。每一个目标有 6 个特征,分别是:面积、周长、灰度密度、形状参数、圆形性和偏心率,从每一类中选取三个典型目标的特征值作为参考,见表 1。

在具体识别过程中,对上面的 5 个类别,应该把它们分成 3 类,即:正常细胞、异常细胞和拒绝识别目标,其中的拒绝识别目标包括第三、四和五类。为完成对目标的分类任务,分别设计了一个多输出型神经网络分类器和一个单输出型神经网络分类器。

表 1 部分血细胞特征值

	面积	周长	灰度密度	形状参数	圆形性	偏心率
一正常	823.88	98.75	127.58	0.9419	3.5252	1.0398
	870.13	103.38	126.88	0.97733	4.5116	1.023
	827.63	98.25	125.03	0.92816	4.1647	1.1753
二异常	1123.6	120.5	94.335	1.0284	4.8798	1.1353
	1420	134	99.591	1.0063	3.6775	1.1439
	1377.1	133.38	103.41	1.0279	5.094	1.0836
三粘连	1663	184.13	123.81	1.6223	0.27609	1.755
	2222.4	225.88	127.46	1.8269	0.22526	1.9109
	1555.3	192.5	124.16	1.8961	0.22875	1.8935
四不完整	227.75	65.625	119.12	1.5048	0.78636	3.2222
	197.13	65.25	120.75	1.7187	0.66186	3.75
	220.25	66.5	121.28	1.5978	0.70121	3.4444
五噪声	6.25	6.25	125.12	0.49736	16.42	2
	5.125	5.125	130.54	0.40783	34.29	1.6667
	28.75	15.5	125.29	0.66499	2.4772	1

### 2.2.1 多输出型神经网络分类器

多输出型分类器采用三层 BP 神经网络<sup>[5]</sup>,训练样本数为 44,输入层有 6 个节点分别对应待分类目标的 6 个特征,输出层有 3 个节点代表要分成的 3 个类别,根据经验,隐含层使用 20 个节点,隐含层与输出层均使用对数 Sigmoid 型激活函数。在 Matlab 环境中各参数设置如下:

特征输入 P:6 × 44 矩阵;

期望输出 T:3 × 44 矩阵,即:分 3 类;T 矩阵中第 i 类目标对应第 i 行为 1,其余行为 0;

S1:隐含层神经元数目,取值为 20;

训练最大次数:20000;

学习率:0.01;

使用均方误差函数,期望最小值为 0.0001。

初始权值与阈值使用 Rands 函数随机给出。为加快网络收敛速度,采用牛顿法<sup>[6]</sup>对网络进行训练。为了增强网络的抗干扰能力,在网络的最后再加上一个竞争网络,以使网络的输出只有 1 个位置对应为 1,其他元素均为 0。

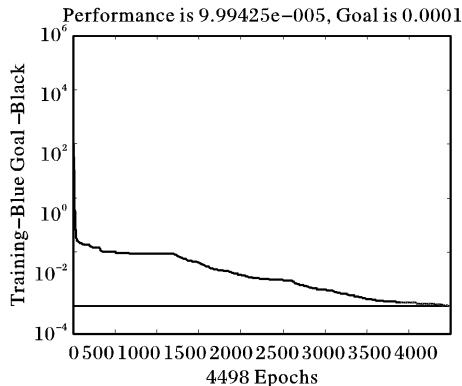


图 3 多输出型 BP 网络训练图

结果网络经过 4498 次训练后收敛,见图 3。从实验可以看出网络收敛速度较慢,而且在训练过程中,发现针对这一特定分类问题,网络的稳健性不是很好,网络中的几个关键参数为:初始权值和阈值、隐层节点数、训练算法和学习率,它们中的一个或几个只要有微小变化,就会对网络的性能产生显著影响。例如,在其他条件不变时,仅把学习率提高到 0.05,网络在 20000 次训练后仍未收敛。

### 2.2.2 单输出型神经网络分类器

针对本问题,三层 BP 网络存在收敛速度较慢和稳健性

不好等问题,现在改用单输出型网络级联模型来设计分类器,这实际上是把原来在6维空间中寻找一个区分3类目标的分类面问题转变为在多个较低维空间中进行分类的问题,在每一个较低维空间寻找1个更加容易实现的简单平面来仅仅区分2类目标,这样就把原来的一个复杂分类问题转变成了多个简单分类问题的组合,其分类流程如图4所示。

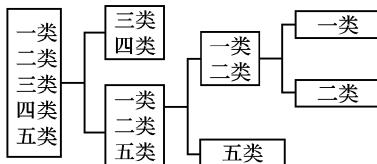


图4 单输出型神经网络分类流程图

具体分析如下:由于最终目的是要区分出原图像中所有的正常与异常细胞,所以在上面的五个类别中,三类、四类与五类目标并不是我们所关心的,在图像识别阶段首先应该能够把三、四和五类目标排除,考虑到三类与四类目标的圆形性和偏心率特征与其他3类目标相比区别较大,所以可先使用这两个特征参数把三、四类排除;在剩下的一、二和五类目标中,使用面积和圆形性两个特征参数可以较好的把一、二类与五类分开,从而把五类目标排除;最后剩下的一类与二类目标使用面积和灰度密度就可以区分,同时考虑到异常细胞多少存在变形问题,所以再加上圆形性参数一同与前两个参数训练网络,可以增加网络的抗干扰能力。

在图4中,由于每次分类都已经选择了最佳的特征参数,所以使每一个分2类的问题可以只用单层感知器就可以简单的解决,几个这样的简单网络级联后仍然可以解决复杂的问题,但每个网络的训练时间大大缩短且更加稳健。

在Matlab环境中使用3个感知器级联组成单输出型神经网络分类器,这3个感知器的名字分别为“netIsCellCE”、“netIsNoiseAC”和“netIsIgADC”。三个网络的最小期望误差均为0,使用随机初始权值和初始阈值,最大训练次数为2000次,描述如下:

1) netIsCellCE:完成第1次分类,使用圆形性(C)和偏心率(E)特征;特征输入P: $2 \times 44$ 矩阵;期望输出T: $1 \times 44$ 矩阵,对一、二和五类目标期望输出1,三、四类期望输出0。

网络训练在第3次就达到期望输出,网络最终权值W=[3.5195 -4.3971];最终阈值B=[-1.1616]。

2) netIsNoiseAC:完成第2次分类,使用面积(A)和圆形性(C)两个特征参数;特征输入P: $2 \times 26$ 矩阵;期望输出T: $1 \times 26$ 矩阵,对一、二类目标期望输出1,五类期望输出0。

网络训练在第11次达到期望输出,网络最终权值W=[20.8470 -237.3813];最终阈值B=[-34.4758]。

3) netIsIgADC:完成第3次分类,使用细胞面积(A)、灰度密度(D)和圆形性(C)特征;特征输入P: $3 \times 20$ 矩阵;期望输出T: $1 \times 20$ 矩阵,对一类目标期望输出1,二类期望输出0。

网络训练在第59次达到期望输出,网络最终权值W=[597.96214271.347510.6144];最终阈值B=[18.8894]。

单输出型神经网络训练情况如图5,使用该图与图3比较可以看出,网络收敛速度有效加快,而且期望误差由 $1e-4$ 减小到0;除最大训练次数以外,单输出型网络几乎不需要人为调整参数;无论初始权值与阈值如何选取,对于线性可分问题总能在有限训练次数内收敛。

### 2.2.3 识别结果与分析

以1幅经过预处理的完整图像为例,分别使用上面设计的三层BP网络分类器与单输出型级联网络分类器进行分类,把图像中每一个目标的特征列向量作为1组数据,共有

98个目标,其中正常细胞为56个,异常细胞为14个,拒绝识别目标28个(粘连细胞和不完整细胞共22个、噪声6个),它们构成一个 $6 \times 98$ 的输入矩阵。

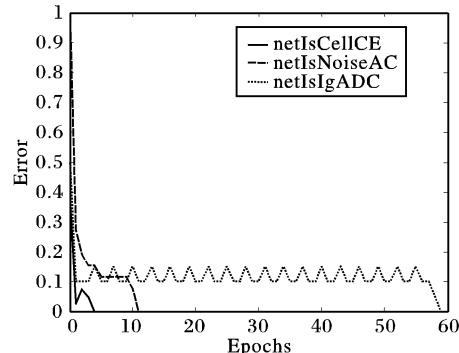


图5 单输出型神经网络训练图

让两个网络各自进行20次识别,结果BP网络平均错分6个目标;而单输出型级联网络错分3个。BP网络错分情况不一,而单输出型网络错分情况主要集中在第一与二类,按(错分目标数/所有目标总数/2)计算网络误检率,得到BP网络平均误检率为3%;单输出型网络平均误检率为1.5%。

### 3 分类器性能测试与评价

为了进一步测试系统的性能,检验2个不同网络的可靠性,下面对加入随机噪声的多组数据进行分类:对图像中目标的输入特征值矩阵加入最大值为0.4,步长为0.02的随机噪声,构成11组数据(每一组为1个特征值矩阵),分别使用2个网络对11组数据逐组分类,发现BP网络的误检率基本上在3%~4%之间,而单输出型网络的误检率维持在1%~2%之间。图6分别给出2个网络随噪声逐渐增加的误差曲线图,其中横轴为噪声增量,纵轴为误检率。

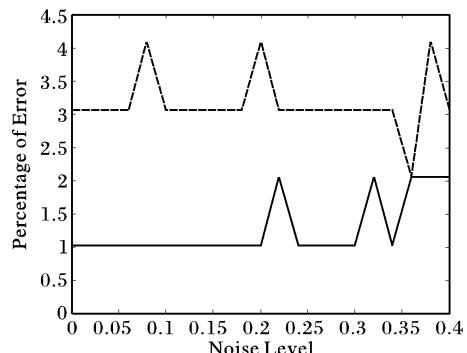


图6 单输出型网络(实线)与BP网络(虚线)的误差曲线图

### 4 结语

从以上可以看出,多输出型网络与单输出型网络都可以胜任血细胞的分类识别任务。三层BP网络一般已经可以解决各种复杂问题,但同时也存在着对某特定分类问题训练速度慢、容易陷入局部极小以及稳健性不好的缺点。

而在对特定分类问题有一定先验知识的情况下,可以用单输出型网络级联的方法将原来复杂的分类问题转化为一些分2类问题的组合,实验证明,用该方法设计分类器具有:设计简单,易于扩展;训练速度快,识别精度高;抗干扰能力强,稳健性好等优点。通过Visual C++ 6.0与Matlab的混合编程接口把用Matlab开发的分类器模块制作成Windows环境下的动态链接库,可以大大提高血细胞分类器的反应速度,从而为开发出实用的血细胞识别系统奠定基础。

(下转第1507页)

### 3.2 求解步骤

SVM的训练算法本质上就是求解一个有大量约束的二次规划问题,训练结束后就获得了SVM的参数。在训练过程中,将一个未知身份的 $p$ 与库 $\{g_j\}$ 存在的 $m$ 个已知的虹膜图进行比较。计算 $p$ 与图库中的各图的相似度 $\sigma_j$ :

$$\sigma_j = \operatorname{sgn} \left\{ \sum_{i=1}^n \alpha_i y_i K(x_i, g_j - p) + b \right\}$$

如果 $p$ 与 $j$ 具有最大的相似度,则认为 $p$ 和 $j$ 是同一个人。

在识别过程中,将一个未知身份的 $p$ 与在训练中认为是同一个人的 $j$ 计算它们的相似度 $\sigma$ :

$$\sigma = \operatorname{sgn} \left\{ \sum_{i=1}^n \alpha_i y_i K(x_i, g_j - p) + b \right\}$$

如果 $\sigma$ 小于预先设定的值 $\Delta$ ,则接受;否则拒绝。

## 4 实验结果及分析

表1 实验结果1

	第1组 实验	第2组 实验	第3组 实验	第4组 实验	第5组 实验	第6组 实验
基向量 个数	5	10	15	20	25	30
误识率(%) (FAR)	3.59	2.36	1.24	1.02	1.19	1.73
误拒率(%) (FRR)	2.32	1.67	1.02	0.76	0.78	0.81
正确识别率(%)	94.09	95.97	97.74	98.22	98.03	97.46

表2 实验结果2

	Gabor 小波方法	本文方法
编码长度(Bytes)	256	80
编码时间/ms(每人)	108	42
等错率(EER)(%)	1.92	1.78

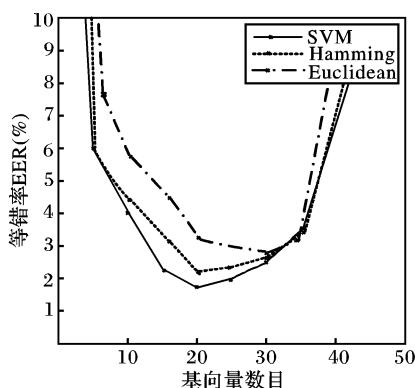


图4 EER与ICA-MJE基向量数目分布曲线

本文所用的虹膜图像库包括10人的20只眼睛的图像,

每只眼睛为8位灰度图像,分辨率为 $320 \times 280$ 。采集过程分2个阶段,每次4张。参加实验共有20类的160幅虹膜图像。实验是在奔腾 III 800PC 机上进行的。试验取每类虹膜前4幅图像编码为模版数据库数据,而后4类虹膜图像为测试输入数据,在虹膜特征提取阶段,每幅图像分别选取5,10,15,20,25和30个基向量,做六组实验。实验结果如表1所示。

ICA-MJE 方法训练虹膜区域样本图像,虹膜编码长度由基向量个数决定。基向量数目直接影响虹膜识别算法的性能。基向量数目过多或过少都会使等错率(EER)增大。因为,数目过多时基向量包含了大量噪音信号;过少时基向量丢失了太多虹膜图像的特征信息。实验结果表明,基向量数目为20时,识别效果最佳(EER = 1.78%),虹膜编码长度为80字节。如表2所示,与 Gabor 小波的方法比较,编码长度减小,计算复杂度降低,编码时间也明显缩短。

本文选取径向基函数(RBF)作为SVM的核函数。在其他条件相同的情况下,分别比较了SVM与海明距离、欧氏距离的识别效果。如图4所示,SVM取得了最好的识别结果。由上述实验结果可以看出,本文提出的基于最大判别熵的独立分量分析和支持向量机的虹膜识别方法无论在编码长度还是编码时间方面都有较明显地改进,并且取得较低的等错率(EER = 1.78%)。该算法完全适合应用到安全性要求较高的身份识别系统。ICA-MJE 方法提取虹膜特征有效地避免了线性变换方法的缺陷,结合 SVM 算法获得了理想的识别结果。

### 参考文献:

- [1] 黄雅平,罗四维,陈恩义. 基于独立分量分析的虹膜识别方法[J]. 计算机研究与发展, 2003, 40(10): 1451–1457.
- [2] COMMON P. Independent component analysis a new concept [J]. Signal Processing, Elsevier, April 1994, 36(3): 287–314.
- [3] HYVÄRINEN A. Independent component analysis applied to feature extraction from contourand stereo images[J]. Network: Computation in Neural Systems, 2002, 11(3): 191–210.
- [4] GIROLAMI M, FYFE C. Blind separation of sources using exploratory projection pursuit network[A]. Speech and Signal Processing, Int'l Conf. on the Engineering Applications of Neural Networks[C]. London, 1996.
- [5] HYVÄRINEN A, OJA E. Independent component analysis: Algorithms and applications[J]. Neural Networks, 2000, 13(4–5): 411–430.
- [6] AMARI SI, CICHOCKI A, YANG H. A new learning algorithm for blind source separation[A]. In: Proc. of Advances in Neural information Processing System[C]. Colorado: MIT Press, 1996. 473–484.
- [7] CORTES C, VAPNIK V. Support vector networks [J]. Machine Learning, 1995, 20: 273–297.
- [8] SHOLKOPF B, SUNG K, et al. Comparing Support Vector Machine with Baussian Kernels to Radial Basis Function Classifiers[J]. IEEE Trans. Signal Processing, 1997, 45: 2758–2765.

(上接第1499页)

### 参考文献:

- [1] 乐家新,丛玉隆.血细胞分析技术进展与临床应用[J].继续医学教育,2006,20(26):43–48.
- [2] 章毓晋.图像处理和分析[M].北京:清华大学出版社,1999.
- [3] SHAHIN A, MENARD M, EBOUEYA M. Cooperation of fuzzy segmentation operators for correction aliasing phenomenon in 3D color Doppler imaging[J]. Artificial Intelligence in Medicine, 2000, 19(2): 121–154.

- [4] 边肇祺,张学工,等.模式识别[M].第2版.北京:清华大学出版社,1999.
- [5] CHEN DS, JAIN RC. A Robust Back Propagation Learning Algorithm for Function Approximation[J]. IEEE Trans NN, 1994, 5(3): 467–479.
- [6] BATTIT R. First and Second Order Methods for Learning: Between Steepest Descent and Newton's Method [J]. Neural Computation, 1992, 4: 141–166.