

文章编号:1004-4213(2011)07-1066-5

# 基于图像处理的模拟尾流气泡幕分类识别

常洋, 崔红, 张建生

(西安工业大学 数理系, 西安 710032)

**摘要:**提出了一种应用数字图像处理技术对模拟尾流气泡幕分类识别的新方法. 文章介绍了BP神经网络的基本结构及其工作原理, 通过仿真测试了BP神经网络对模拟尾流气泡幕图像的模式分类. 应用灰度图像统计矩法得到了均值、归一化系数、三阶矩、一致性和熵等特征量, 设定神经网络学习率为0.1时经过14次循环可以达到训练目标误差为0.001, 此时网络对不同压强下的尾流气泡幕分类正确率到达100%. 这种方法在处理尾流图像时具有直观、高效、精确等特点, 易于应用于对尾流探测、识别等工程技术中.

**关键词:**尾流气泡幕; BP神经网络; 图像识别; 仿真

**中图分类号:** O439

**文献标识码:** A

**doi:** 10.3788/gzxb20114007.1066

## 0 引言

舰船尾流是含有大量气泡的气幕带. 大小、航速不同的舰船所产生的尾流气幕带也会不同. 为了对不同尾流的探测、跟踪或识别, 很多研究者对尾流所具有的声学特性、光学特性、电磁学特性以及热特性等物理学特性做了大量研究<sup>[1-4]</sup>. 随着计算机技术的迅猛发展, 数字图像处理技术为我们研究尾流气泡幕提供了新的方法, 基于二值图像的逻辑运算, 边缘提取等手段可得到气泡的轮廓, 并使用填充算法对气泡轮廓进行填充得到气泡尺寸<sup>[5]</sup>. 当尾流气泡幕密度较大时, 气泡间会出现重叠, 用区域分割技术对气泡幕图像进行伪彩色显示<sup>[6]</sup>, 可定性分析气泡尺度分布规律等特性, 定量得到一定等效直径下气泡的比例或密度. 粒子图像测速法 (Particle Image Velocimetry, PIV) 是一种瞬态、多点、无接触的流体力学测速方法, 经过近几十年的发展和完善将这种方法应用于尾流气泡幕的研究中, 它能在同一瞬态记录下大量空间点上的速度分布信息, 并提供丰富的流场空间结构以及流动特性<sup>[7-8]</sup>. PIV研究的另一分支为粒子追踪技术 (Particle Tracking Velocimetry, PTV), 它能够给出单个粒子的运动轨迹, 而且可以从二维测速技术直接扩展为三维测速技术<sup>[9]</sup>. 先进的数字图像处理技术可以准确、可靠、全自动的得到单帧或序列运动气泡图像中包含

的气泡信息, 高速的DSP器件可以使得运动气泡图像采集和处理系统实时化、快速化、小型化. 本文通过实验模拟尾流气泡幕, 应用BP神经网络通过MATLAB<sup>[10]</sup>仿真, 对不同压强下的模拟尾流气泡幕样本作出了精确的分类判断, 为今后尾流气泡幕数字化监测分析进行了有用的探索.

## 1 模拟尾流气泡幕的样本采集

尾流图像拍摄系统主要由模拟尾流发生器、高速摄像机、照明光源和图像采集及处理组成. 实验通过控制压强的大小, 采集四类不同的尾流气泡幕图像, 如图1, (a)、(b)、(c)、(d)分别对应于压强为




图1 不同压强下气泡幕的灰度图像  
Fig. 1 Gray images of bubble films under different pressures

**基金项目:** 武器装备预研基金 (No. 51448030101ZK1801)、陕西省自然科学基金项目 (No. 2004A18) 和陕西省教育厅专项科研计划项目 (No. 2010JK585) 资助

**第一作者:** 常洋 (1986-), 男, 硕士研究生, 主要研究方向为水下信息光学. Email: rogerfederer@126.com

**导师:** 张建生 (1966-), 男, 教授, 主要研究方向为气泡尾流光学检测、水下信息光学、光学和光学测试. Email: zhangjish@xatu.edu.cn

**收稿日期:** 2010-11-08; **修回日期:** 2011-03-02

0.020 MPa、0.025 MPa、0.030 MPa、0.035 MPa. 图中已将彩色图像转换为灰度图像. 四类样本图像各采集 14 幅图, 每类中 10 幅作为 BP 神经网络的训练集, 4 幅作为测试集.

## 2 模拟尾流气泡幕图像模糊分类的原理

### 2.1 BP 神经网络的基本结构

人工神经网络是一种非线性的映射方式, 由于受到人和动物的神经系统启发, 利用大量简单处理单元互联而构成的复杂系统. 神经网络中大量神经元并行分布运算的原理, 高效的学习算法以及对人的认知系统的模仿能力使它适于解决图像模式识别问题.

BP 神经网络<sup>[11]</sup>是一种单向传播的多层前向网络, 其结构如图 2. 它是一种具有三层或三层以上的神经网络, 包括输入层、中间层(隐层)和输出层. 上下层之间实现全连接, 而每层神经元之间无连接.




图 2 BP 神经网络的结构

Fig. 2 The structure of BP neural network

### 2.2 BP 神经网络的训练与识别

BP 神经网络使用的算法称为“误差逆传播算法”, 即 BP 算法. 当一对学习样本提供给网络后, 神经元的激活值从输入层经各中间层向输出层传播, 在输出层的各神经元获得网络的输入响应. 接下来按照减少目标输出与实际误差的方向, 从输出层经过各中间层逐层修正各连接权值, 最后回到输入层. 随着这种误差逆的传播修正不断进行, 网络对输入模式响应的正确率也不断上升.

## 3 MATLAB 仿真实现尾流气泡幕分类

### 3.1 BP 网络设计

首先, 从输入样本中提取气泡幕灰度图像的特征量. 随着气压的增大气泡会出现重叠现象, 随机因素的干扰会使气泡幕分类难度加大, 特征提取过程是去除冗余信息的过程, 具有提高识别准确度、运算速度的作用. 应用灰度图像直方图统计矩法, 提取

了均值、归一化系数、二阶矩、三阶矩、一致性和熵 6 个统计量. 相同压强下的相同统计量的值很接近, 说明统计参量受随机因素干扰小, 具有可靠性; 每个特征参量在不同压强下的值有很好的区分性, 这 6 个特征量能有效地反映图像的本质特征.

为了简化网络结构并能够实现神经网络分类的效果, 我们选用三层 BP 网络作为状态分类器. 根据 Kolmogorov 定理<sup>[12]</sup>, 输入层  $N=6$ , 中间层为  $2N+1=13$ , 输出层为  $M=4$ , 其中  $N$  表示输入特征向量分量数,  $M$  表示输出状态类别总数. 表 1 表示尾流气泡幕的模式分类.

表 1 尾流气泡幕的模式分类

Table 1 Pattern classification of wakes' bubble film

SWBF classification	Corresponding describe
SWBF under pressure 0.020MPa	(0,0)
SWBF under pressure 0.025 MPa	(0,1)
SWBF under pressure 0.030 MPa	(1,0)
SWBF under pressure 0.035 MPa	(1,1)

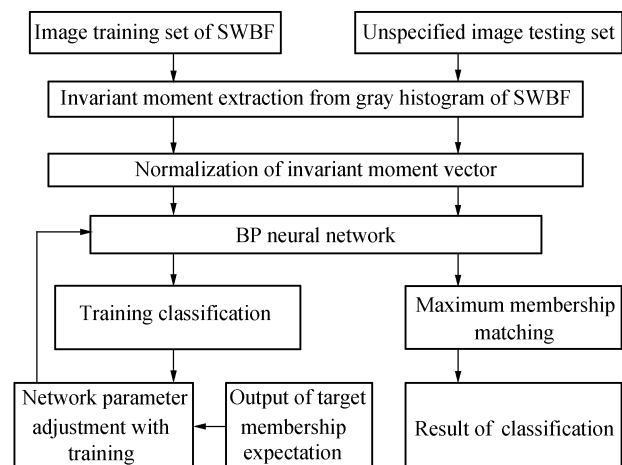


图 3 BP 神经网络训练与识别过程

Fig. 3 Training and the identification process of BP neural network

由于训练图像有 40 幅, 经过归一化后的特征量数据较多, 只能给出部分数据, 如表 2 和表 3. 为更直观得到 40 组数据的分布, 绘制这 40 组数据的三维分布图如图 4.

由于压强的不断增大, 较大的气泡所占的比例逐渐增大, 气泡幕的间隙或空白区域面积逐渐减小, 强烈的反射和折射效应使得透射减少, 反映到灰度图像中来就是图像的平均灰度级逐渐增大. 我们从图 4 中可以得到, 三阶矩和均值的敏感度较强, 随着压强增大分别成递增和递减的趋势; 标准偏差、归一化、一致性、熵的曲线中 0.025MPa 所对应的值为曲线的转折点, 在此处一致性与其它统计参量的转折方向相反.

表 2 归一化后的统计量(部分 1)  
Table 2 Normalized statistical parameters(part 1)

Image sample ordinal *	Mean value	the second moment	Normalized coefficient	The third moment	Uniformity	Entropy
6/1	0.000 9	0.756 6	0.697 5	0.961 7	0.506 8	0.511 4
6/2	0.111 1	0.886 3	0.853 5	0.752 9	0.068 5	0.911 7
6/3	0.714 7	0.440 5	0.359 9	0.271 9	0.274	0.515 4
6/4	0.815 7	0.096 7	0.066 9	0.079	0.643 8	0.157 5

\* 图像样本序号第 1 列为图像编号,第 2 列为类别标号,下同。

表 3 归一化后的统计量(部分 3)  
Table 3 Normalized statistical parameters(part 2)

Image sample ordinal	Mean value	the second moment	Normalized coefficient	The third moment	Uniformity	Entropy
1/1	0.022 9	0.688 2	0.617 8	0.972 7	0.597 3	0.561 1
2/1	0.066 7	0.626	0.547 8	0.936 7	0.521 9	0.526 5
3/1	0.012 1	0.671 2	0.598 7	0.924	0.584 9	0.566 2
4/1	0.031 7	0.723 2	0.656 1	0.9	0.520 5	0.502 6
5/1	0.009 8	0.723 8	0.659 2	0.850 4	0.465 8	0.525 7
6/1	0.000 9	0.756 6	0.697 5	0.961 7	0.506 8	0.511 4
7/1	0.132 2	0.615 1	0.538 2	1	0.501 3	0.598 3
8/1	0.030 2	0.678 8	0.608 3	0.984 8	0.547 9	0.449 2
9/1	0.045 7	0.763	0.703 8	0.877 3	0.424 7	0.578 6
10/1	0	0.722 6	0.656 1	0.902 1	0.506 8	0.510 2

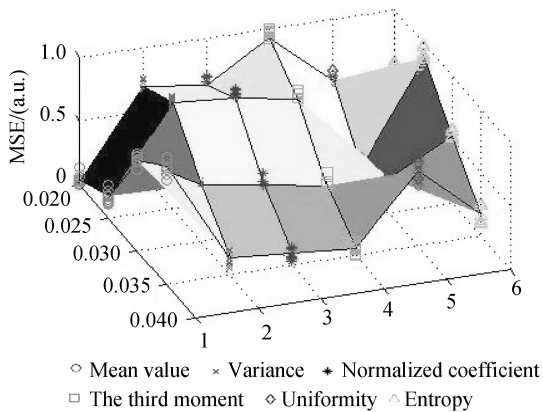


图 4 统计量-压强-统计量归一化后数值的三维分布  
Fig. 4 Three dimensional distribution of statistic-pressure-normalized statistic

设训练网络输入变量为  $P$ , 目标变量为  $T$ ,  $P$  从 40 组特征量中得出,  $T$  从表 1 中得到. BP 网络的传递函数必须是可微的, 常用的传递函数有 Sigmoid 型的对数、正切函数或线性函数. 正是由于传递函数处处可微, 对于 BP 网络来说所划分区域不再是一个线性划分, 而是一个非线性超平面组成的区域, 因而它的分类比线性划分更加精确. 网络建立命令如下:

```
net = newff(minmax(P), [13, 2], {'tansig', 'logsig'}, 'trainlm')
```

### 3.2 网络训练

网络创建后必须经过训练并达到所设定参量后, 才可以作为模式分类器来使用, 我们采用

trainlm 函数对网络进行训练. 网络训练命令<sup>[13]</sup>如下:

```
net.trainParam.epochs=a;%设定循环次数 a
net.trainParam.goal=b;%训练误差为 b
net.trainParam.lr=c;%网络的学习率为 c
net=train(net,P,T);
sim(net,P)
```

我们通过设置不同的训练参量来调整使网络达到稳定, 如图 5(a), 设定训练循环次数  $a=1$ , 目标训练误差为 0.001, 学习率为 0.1, 实验结果显示经过 1 次训练无法满足目标训练误差, 其均方误差 MSE (Mean Square Error) 由开始时的 0.497 0 下降到 0.265 9, 训练次数与 MSE 呈线性关系. 图 5(b) 设定循环次数  $a=1000$ , 目标训练误差为 0.001, 学习率为 0.1, 经过 14 个周期训练均方误差  $MSE=0.00042$  达到 0.001 的训练目标, 当训练进行到 11 次时均方误差接近线性下降. 此时已经可以很精确的对不同类型的尾流气泡幕进行分类. 为得到更为普遍性规律, 设定循环次数为 1000, 目标训练误差为 0, 学习率为 0.1, 从图 5(c) 得到当训练 26 次时  $MSE=5.79867e^{-14}$  基本接近于 0, 此时经过训练的网络权值的设定更为精确, 但所用时间也会增加, 在实际应用中出现的数据量会更加庞大, 我们应在保证在误差允许的范围内使训练时间达到最小, 这样才能更加有效地对测试数据进行分类.

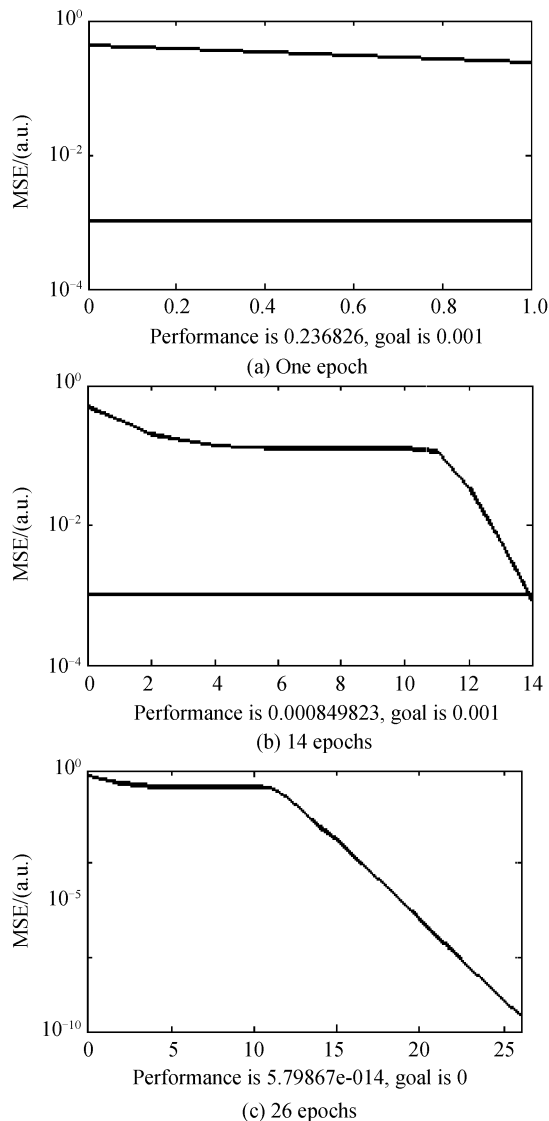


图5 网络训练结果  
Fig. 5 Results of network training

### 3.3 网络测试

为了测试网络是否满足我们分类的要求,需要用测试集的图像来验证.一共有16幅图像作为测试集.

测试命令如下:

```
P_test=[
0.0229 0.6882 0.6178 0.9727 0.5970 0.5611;
0.0667 0.6260 0.5478 0.9367 0.5219 0.5265;
.....
```

```
0.9595 0.1928 0.1401 0.0037 0.5205 0.2381]
```

```
P_test=P_test';
```

```
Y=sim(net,P_test);
```

```
error=Y-T
```

```
res=norm(error)
```

运行结果:

```
Y=[0.000 0 0.000 0 ..... 1.000 0 1.000 0
0.000 0 0.000 2 0.963 2 0.950 0]
```

所有测试结果如图6.




图6 测试结果  
Fig. 6 Test results

由测试结果可知测试值都落在目标分类值的附近,由于训练时设定的训练误差为0.001,在0.030 MPa和0.035 MPa处的测试值有些偏离目标值,但不影响准确判别出每幅测试图片所属类别,如第一组数据运行结果为(0.000 0,0.000 0),从表1可以看出它属于0.020 MPa下拍摄的尾流气泡幕图像,测试数据准确率为100%.从训练结果来看BP神经网络自身也存在着一定的缺陷和不足:BP算法可以使权值收敛到某个值,但不能保证其为误差平面的全局最小值;网络的隐含层层数和单元数是根据经验或反复实验确定,因此网络存在很大的冗余性;这些原因都会使测试结果存在一定的误差.

## 4 结论

本文通过高速摄影技术采集模拟尾流气泡幕,使用BP神经网络作为分类器,对不同压强下的气泡幕做了准确的分类.通过理论和仿真得到以下结论:

1)通过对训练参数的调整使训练网络达到稳定,当设置学习率为0.1,目标训练误差为0.001时,经过14个周期即可达到训练要求;训练进行到11次以后训练次数与MSE近似呈线性下降,当经过26周期后训练后误差近似为0.综合实际应用中效率与最大所允许误差的情况,选择训练14次即可满足模式分类要求.

2)从理论上说明了对不同压强下的模拟尾流气泡幕分类时所选用的特征量具有可区分性、可靠性和独立性,使接下来的BP神经网络的训练和测试顺利进行.运用数字图像处理手段对不同压强下的气泡幕图像处理,具有直观、高效、准确等优点,易于今后应用到尾流的数字化监测分析中.

在实际应用中由于气泡幕图像将更为复杂随机因素也将影响训练和测试的最终结果,测试集和训练集将更为庞大,我们需要进一步对神经网络的基本结构进行调整以适应实际项目中的需求.

## 参考文献

- [1] ZHANG Jian-sheng, KANG Xiao-feng, Li Yu-qing, *et al.* Development of ship wake target recognition base on SGGA [J]. *Journal of Xi'an Institute of Technology*, 2007, **27**(1): 78-81.  
张建新,康筱锋,李玉清,等.传播尾流目标识别的随机梯度遗传算法研究[J].西安工业大学学报,2007,**27**(1):78-81.
- [2] JI Bang-jie. Study of anti-interference technology in laser wake detection[J]. *Torpedo Technology*, 2007, **15**(1): 48-50.  
冀邦杰.光尾流自导中抗干扰技术研究[J].鱼雷技术,2007,**15**(1):48-50.
- [3] YUAN Jun-xing, CHEN Liang-yi. Wake holographic imaging [J]. *Acta Photonica Sinica*, 2009, **38**(3): 636-640.  
袁军行,陈良益.尾流的全息成像方法研究[J].光子学报,2009,**38**(3):636-640.
- [4] ZHANG Jian-sheng, SUN Chuan-dong, CHEN Liang-yi, *et al.* The moment of air bubbles in water by use of high speed photography[J]. *Acta Photonica Sinica*, 2000, **29**(10): 952-955.  
张建新,孙传东,陈良义,等.高速摄影技术对水中气泡运动规律的研究[J].光子学报,2000,**29**(10):952-955.
- [5] GE Wei-long, ZHANG Xiao-hui, LEI Xuan-hua. Computing underwater bubble radius using image processing[J]. *Laser & Infrared*, 2006, **36**(1): 74-76.  
葛卫龙,张晓晖,雷选华.水中气泡尺度计算的图像处理方法[J].激光与红外,2006,**36**(1):74-76.
- [6] ZHANG Jian-sheng, LIN Shu-yu, MIAO Run-cai, *et al.* Research of stimulated wakes bubble film based on image processing[J]. *Acta Photonica Sinica*, 2007, **36**(12): 2371-2376.  
张建新,林书玉,苗润才,等.基于图像处理的模拟尾流气泡幕研究[J].光子学报,2007,**36**(12):2371-2376.
- [7] LIU Zheng-liang, YING Zheng. PIV study of bubble rising behavior[J]. *Powder Technology*, 2006, **168**: 10-20.
- [8] SAKAKIBARA K, YAMADA M, MIYAMOTO T, *et al.* Measurement of the surrounding liquid motion of a single rising bubble using a dual-camera PIV system [J]. *Flow Measurement and Instrumentation*, 2007, **18**: 211-215.
- [9] ORITZ-VILLAFUERTE J, SCHMIDL W D, HASSAN Y A. Three-dimensional ptv study of the surrounding flow and wake of a bubble rising in a stagnant liquid [J]. *Fluids*, 2000, **29**: S202-S210.
- [10] RAFAEL C G, RICHARDE W, STEVEN L E. 数字图像处理[M].阮秋琦,等译.数字图像处理[M].北京:电子工业出版社,2006:540-542.
- [11] 范立南,韩晓微,张广渊.图像处理与模式识别[M].北京:科学出版社,2007,127-143.
- [12] LIU Ou-geng, HE Su-liang. Determining automatically structure parameters of BP artificial neural network by a computer [J]. *Computer Engineering and Applications*, 2004, **24**(13): 72-75.  
刘耦耕,贺素良. BP神经网络结构参量的计算机自动确定[J].计算机工程与应用,2004,**24**(13):72-75.
- [13] LUO Hang-cheng. Realization of BP network based on neural network tool kit in MATLAB[J]. *Computer Simulation*, 2004, **21**(5): 109-112.  
罗成汉.基于MATLAB神经网络工具箱的BP网络实现[J].计算机仿真,2004,**21**(5):109-112.

## SWBF Classification Based on BP Neural Network

CHANG Yang, CUI Hong, ZHANG Jian-sheng

*(Math-Physical Department, Xi'an technological University, Xi'an 710032, China)*

**Abstract:** A new method which classification of simulated wake bubble films (SWBF) can be obtained by using imaging processing methods. The paper introduces the basic structure and working principals of the BP neural network, the simulation tested classification of SWBF image based on BP neural network. The characteristic quantities such as mean value, normalized coefficient, the third moment, uniformity, entropy can be extracted based on gray histogram statistical moment. After 14 epochs, training error can be reached 0.001 when we setting neural network learning rate is 0.1, while the classification accuracy can be up to 100% under different pressures on SWBF. The method has characteristics such as visibility, high efficiency and accuracy, and can be apt to applied in engineering projects for wakes' detection and recognition.

**Key words:** WBF; BP neural network; Image recognition; Simulation