

文章编号:1001-9081(2010)04-0977-03

基于相对熵函数准则的小波网络字符识别方法

薛亚军, 丁 勇

(南京航空航天大学 自动化学院, 南京 210016)

(linyi_963@hotmail.com)

摘 要:针对传统小波网络(WNN)基于均方差函数的梯度学习算法收敛速度慢和产生局部极小点的缺点,结合熵函数准则优于均方差函数准则,可以改善网络的收敛速度等优点,研究了一种基于相对熵函数准则的小波网络算法的字符识别方法。首先对分割后的车牌字符图像进行二值化、归一化等一系列预处理,然后利用新的不变矩算法提取不变矩,以此作为字符图像的特征向量,最后应用基于新优化算法的小波网络进行分类识别。计算机仿真结果表明,该方法对字符的识别取得了较好的效果。

关键词:相对熵;不变矩;小波网络;字符识别

中图分类号:TP391.41 **文献标志码:**A

Vehicle license plate character recognition based on relative entropy function criterion

XUE Ya-jun, DING Yong

(Institute of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing Jiangsu 210016, China)

Abstract: Based on gradient method, the conventional learning algorithm of Wavelet Neural Network (WNN) using the Mean Square Error (MSE) criterion may affect the convergence speed and make the process fall into local minimal. The entropy function criterion is superior to the MSE criterion, possible to improve convergence rate. Thus based on relative entropy function criterion, a novel vehicle license plate character recognition method using WNN was proposed. Firstly, image preprocessing was done on character images, including image binary, image normalization and so on. Then invariant moment of character image using the new invariant moment algorithm was extracted, which was taken as the characteristic vector. Finally, the optimized wavelet neural network was used to classify and recognize the target. Computer simulation shows that this method achieves good recognition effect.

Key words: relative entropy; invariant moment; Wavelet Neural Network (WNN); character recognition

0 引言

在车牌识别系统中,字符识别是最为关键的环节之一。字符识别效果的好坏,主要与特征量选取和分类器的设计密切相关。近年来,人工神经网络作为分类器以其抗噪声、容错、自适应、自学习能力强,融合预处理和识别于一体,识别速度快等特点受到人们重视,在字符识别技术中得到了广泛应用^[1-2]。随着神经网络的发展,国内外学者提出基于神经网络的车牌字符识别方法,在识别效果的准确率、容错性、鲁棒性等方面取得了一定的进展,小波网络(或小波神经网络)^[3]即是其中的一种。

小波网络结合小波分析和神经网络的优点,具有良好的时频局域化特性,将其用于字符识别,有效提高了目标识别率。而在以往的小波网络中最常用的学习算法是基于均方差函数的梯度下降法,这是一种局部搜索算法,其收敛速度慢,泛化能力无法保证,而使得网络训练效果不尽人意。本文将相对熵函数代替均方差函数应用于小波网络算法的设计,并用所设计的小波网络对字符进行识别实验,同时与采用均方差函数的小波网络进行比较,仿真实验表明了本文所提出的方法的有效性。

1 相对熵函数准则

一般小波网络的学习过程都采用了BP算法,而传统BP算法收敛速度慢、产生局部极小点的原因之一是该算法采用均方误差准则,经过理论分析和研究发现熵函数准则优于均方误差准则^[4]。

对于两个系统 M 和 N ,它们的状态 M_i 和 N_i ($i=1, \dots, L$)之间的差别程度可用Kullback-Leibler距离^[5]来度量:

$$C = \sum_{i=1}^L \left\{ M_i \log \frac{M_i}{N_i} + (1 - M_i) \log \frac{1 - M_i}{1 - N_i} \right\} \quad (1)$$

其中 C 越小,则系统 M 、 N 的状态差别越小。 C 称为系统 M 和 N 的相对熵。对于神经网络的输出层,在学习过程中,它获得的信息就是要保证其与理想的输出最为接近,而网络的输出值和理想输出值的接近程度可用相对熵来度量:

$$C = \sum_{i=1}^N \left\{ d_i \log \frac{d_i}{y_i} + (1 - d_i) \log \frac{1 - d_i}{1 - y_i} \right\} \quad (2)$$

其中: d_i 为理想输出; y_i 为实际输出。基于相对熵函数准则的小波网络算法可以避免网络的假饱和状态,从而提高了网络收敛速度。

本文将采用相对熵函数准则对小波网络进行优化。为了减小振荡,同时还要保证加快收敛,可以采用模拟退火技术加

收稿日期:2009-07-14;修回日期:2009-09-02。

作者简介:薛亚军(1982-),男,陕西渭南人,硕士研究生,主要研究方向:模式识别、智能交通; 丁勇(1967-),女,江苏南京人,副教授,硕士,主要研究方向:计算机控制、智能控制、故障诊断。

以改进^[6]。

2 基于相对熵函数的小波网络优化方法

本文采用小波神经网络结构如图1所示。




图1 小波网络结构

对于多变量输入输出系统: $f: \mathbf{R}^m \rightarrow \mathbf{R}^N$, 令 $net_j =$

$\sum_{k=0}^m w_{jk}x_k - b_{1j}$, 则有:

$$\psi_{a,b}(net_j) = h\left(\frac{net_j - b_j}{a_j}\right) \quad (3)$$

于是小波神经网络的输入输出关系可以表示为^[7]:

$$y_i(t) = \delta\left(\sum_{j=0}^n w_{ij}\psi_{a,b}(net_j) - b_{2i}\right) \quad (4)$$

其中: $x_k (k = 1, 2, \dots, m)$ 是输入的第 k 个训练矢量; $y_i (i = 1, 2, \dots, N)$ 为第 i 个输出分量; w_{ij} 为隐层第 j 个单元到输出层第 i 个单元的连接权值; w_{jk} 为输入层第 k 个单元到隐层第 j 个单元的连接权值; a_j, b_j 分别为小波函数的尺度和位移; b_{1j}, b_{2i} 分别是隐层第 j 个节点和输出层第 i 个节点的阈值; m, n 和 N 分别为输入、输出和隐层单元数; $\delta(z) = 1/(1 + e^{-z})$ 。

定义样本误差函数为:

$$E = \sum_{p=1}^P \sum_{i=1}^N \left\{ d_i^p \ln \frac{d_i^p}{y_i^p} + (1 - d_i^p) \ln \frac{1 - d_i^p}{1 - y_i^p} \right\} \quad (5)$$

其中: d_i^p 为第 p 个样本输出层第 i 个节点的期望分类输出; y_i^p 为实际分类输出。

分类参数 $w_{ij}, w_{jk}, a_j, b_j, b_{1j}, b_{2i}$ 可通过使能量函数 E 最小化达到最优。选取 Morlet 小波 $h(z) = \cos(1.75z) \exp(-\frac{z^2}{2})$ 作为小波函数, 具体的训练算法如下。

1) 初使化参数 $w_{ij}, w_{jk}, a_j, b_j, b_{1j}, b_{2i}$ ^[8], 设定学习率 η 和动量因子 μ 。

2) 输入学习样本 $x_k^p (k = 1, 2, \dots, m; p = 1, 2, \dots, P)$ 及相应的期望输出 $d_i^p (i = 1, 2, \dots, N; p = 1, 2, \dots, P)$ 。

3) 网络训练学习。依据当前网络参数, 利用式(5)计算网络输出 $y_i^p(t)$ 。

4) 计算瞬时梯度向量:

$$\delta_i^p = \beta(d_i^p - y_i^p) + \gamma \exp\left(-\frac{1}{|y_i^p - d_i^p|}\right)(d_i^p - y_i^p)$$

$$\begin{aligned} \frac{\partial E}{\partial w_{ij}} &= - \sum_{p=1}^P \delta_i^p \psi_{a,b}(net_j^p) \\ \frac{\partial E}{\partial w_{jk}} &= - \sum_{p=1}^P \sum_{i=1}^N \delta_i^p w_{ij} \psi_{a,b}'(net_j^p) \frac{x_k^p}{a_j} \\ \frac{\partial E}{\partial b_j} &= \sum_{p=1}^P \sum_{i=1}^N \frac{\delta_i^p w_{ij} \psi_{a,b}'(net_j^p)}{a_j} \\ \frac{\partial E}{\partial a_j} &= \sum_{p=1}^P \sum_{i=1}^N \frac{\delta_i^p w_{ij} \psi_{a,b}'(net_j^p) (\frac{net_j^p - b_j}{a_j})}{a_j} \end{aligned} \quad (6)$$

$$\frac{\partial E}{\partial b_{1i}} = - \sum_{p=1}^P \sum_{i=1}^N \frac{\delta_i^p w_{ij} \psi_{a,b}'(net_j^p)}{a_j}$$

$$\frac{\partial E}{\partial b_{2j}} = - \sum_{p=1}^P \sum_{i=1}^N \delta_i^p$$

对于 β, γ 取值可参考文献[9]中的介绍。

5) 网络参数优化:

$$\begin{cases} w_{jk}(t+1) = w_{jk}(t) - \eta \frac{\partial E}{\partial w_{jk}} + \mu \Delta w_{jk}(t) \\ w_{ij}(t+1) = w_{ij}(t) - \eta \frac{\partial E}{\partial w_{ij}} + \mu \Delta w_{ij}(t) \\ a_j(t+1) = a_j(t) - \eta \frac{\partial E}{\partial a_j} + \mu \Delta a_j(t) \\ b_j(t+1) = b_j(t) - \eta \frac{\partial E}{\partial b_j} + \mu \Delta b_j(t) \\ b_{1j}(t+1) = b_{1j}(t) - \eta \frac{\partial E}{\partial b_{1j}} + \mu \Delta b_{1j}(t) \\ b_{2j}(t+1) = b_{2j}(t) - \eta \frac{\partial E}{\partial b_{2j}} + \mu \Delta b_{2j}(t) \end{cases} \quad (7)$$

6) 收敛判定: 如果 $E(t) < \varepsilon$, 停止网络学习; 否则令 $t = t + 1$, 返回步骤2)。

3 基于不变矩的字符特征提取方法

在对字符图像进行特征提取之前首先要对其进行一系列预处理, 以便后面提取有利于神经网络准确分类的特征量, 如图2所示。



图2 车牌字符预处理效果

应用神经网络进行字符识别, 输入特征向量的选取尤为重要, 特征向量的好坏对于一个模式识别系统的识别效果有重要的影响。所要提取的特征向量应当具有可区别性、可靠性、独立性好的少量特征。

图像的不变矩具有平移不变性、旋转不变性、比例不变性等特性。因此本文是利用 M. K. Hu 的 7 个不变矩作为神经网络的输入特征向量。一幅图像可以用二维函数 $f(x, y)$ 表示, 则其 $(p+q)$ 阶原点矩表示为:

$$m_{pq} = \sum_{m=1}^M \sum_{n=1}^N x^p y^q f(x, y) \quad (8)$$

从而其 $(p+q)$ 中心矩为:

$$u_{pq} = \sum_{m=1}^M \sum_{n=1}^N (x - \bar{x})^p (y - \bar{y})^q f(x, y) \quad (9)$$

其中: $p, q = 0, 1, \dots$; \bar{x}, \bar{y} 是图像的重心坐标 $\bar{x} = m_{10}/m_{00}$, $\bar{y} = m_{01}/m_{00}$ 。

文献[10]给出了由二阶和三阶中心矩的线性组合而成的 Hu 的 7 个不变矩, 并证明在连续状态下其具有平移、旋转和比例不变性, 然而在实际应用过程中则往往是离散的。文献[11]已经证明在离散状态下不变矩对比例因子不具备不变性。

当图像进行比例变化时, 归一化的中心矩变成了:

$$\eta'_{pq} = \frac{\mu'_{pq}}{(\mu'_{00})^r} = \frac{\rho^{pq} \mu_{pq}}{\mu_{00}^r} = \rho^{p+q} \eta_{pq} \quad (10)$$

其中: ρ 是原始图像和变化后图像的比例因子; $r = \frac{(p+q)}{2} +$

1. 这就表明了离散状态下,比例因子 ρ 对 η_{pq} 产生了影响,而且与矩的阶数有关,即由 M. K. Hu 所定义的 7 个不变矩在离散状态下不具有比例因子不变性。所以本文采用新的不变矩算法,使其在离散状态下保持比例因子不变性,同时具备平移和旋转不变性^[12]。

7 种不变矩特征在比例因子 ρ 变化前后的关系为:

$$\begin{aligned}\varphi'_1 &= \rho^2 \cdot \varphi_1, \varphi'_2 = \rho^4 \cdot \varphi_2, \varphi'_3 = \rho^6 \cdot \varphi_3, \\ \varphi'_4 &= \rho^6 \cdot \varphi_4, \varphi'_5 = \rho^{12} \cdot \varphi_5, \varphi'_6 = \rho^8 \cdot \varphi_6, \\ \varphi'_7 &= \rho^{12} \cdot \varphi_7\end{aligned}$$

其中 $\varphi_1 \sim \varphi_7, \varphi'_1 \sim \varphi'_7$ 表示发生比例因子 ρ 变化前后的 7 个不变矩。

构造新的不变矩 $\beta_1 \sim \beta_6$ 如下:

$$\begin{aligned}\beta_1 &= \frac{\varphi'_2{}^2}{\varphi'_1}, \beta_2 = \frac{\varphi'_3{}^3}{\varphi'_1}, \beta_3 = \frac{\varphi'_4{}^3}{\varphi'_1}, \\ \beta_4 &= \frac{\varphi'_5{}^6}{\varphi'_1}, \beta_5 = \frac{\varphi'_6{}^4}{\varphi'_1}, \beta_6 = \frac{\varphi'_7{}^6}{\varphi'_1}\end{aligned}$$

很明显可以看出 $\beta_1 \sim \beta_6$ 对比例因子的变化具有不变性,同时对平移和旋转也具有不变性。

由于直接所求的 7 个不变矩的变化范围比较大,而且可能出现负值的情况,不利于作为代表字符的特征向量,所以实际采用取对数的方法进行数据压缩。因此,实际采用的不变矩为:

$$\varphi'_k = \lg |\varphi_k|; k = 1, 2, \dots, 7 \quad (11)$$

表 1、表 2 给出了字符“浙”归一化后的不变矩数据以及构造的新不变矩数据。从表 1、2 中可以看出,同类字符图像的特征不变矩对于旋转有一定变化,但变化相对较小。而对于缩放,7 个不变矩有较大的变化,但是新的不变矩变化比较小。因此,从实验数据上说明 Hu 不变矩在离散状态下不具有比例不变性,而新构造的不变矩具有比例不变性。

表 1 Hu 不变矩数据

Hu 不变矩	旋转			缩放	
	0°	30°	60°	2 倍	0.8 倍
$\varphi_1 [10^{-3}]$	1.2623	1.2629	1.2631	1.2702	1.2584
$\varphi_2 [10^{-7}]$	4.7604	4.7601	4.7624	4.8328	4.8632
$\varphi_3 [10^{-13}]$	2.9507	3.0179	3.0661	3.1645	2.3848
$\varphi_4 [10^{-13}]$	5.2602	5.3479	5.4229	5.5038	4.3774
$\varphi_5 [10^{-26}]$	-2.9338	-2.7835	-2.3635	-3.3889	-2.1520
$\varphi_6 [10^{-17}]$	2.3691	2.6094	3.0601	2.8173	7.3074
$\varphi_7 [10^{-25}]$	-2.0515	-2.1304	-2.1986	-2.2718	-1.3978

表 2 新不变矩数据

新不变矩	旋转			缩放	
	0°	30°	60°	2 倍	0.8 倍
β_1	-0.752370	-0.752490	-0.752500	-0.752990	-0.750680
β_2	0.514380	0.514090	0.513850	0.514560	0.510620
β_3	0.504070	0.503890	0.503680	0.504670	0.503020
β_4	-0.043028	-0.043086	-0.043212	-0.043163	-0.043497
β_5	-0.235440	-0.234920	-0.233960	-0.235250	-0.227400
β_6	-0.041605	-0.041596	-0.041577	-0.041762	-0.041506

4 仿真实验

实验选取了“A”,“B”,“E”,“0”,“5”,“陕”,“浙”,“苏”这 8 类字符作为识别对象。把这 8 类图像中的每一幅图像依次旋转 30°,再进行缩放、加噪处理可以得到 192 幅样本。

小波神经网络结构如图 1 所示,本文中小波神经网络的输入节点个数为 6,输入值为新的不变矩特征值。隐含节点

个数使用经验值,输入节点个数的 2 倍即 12 个隐含节点数,输出节点数为 3 个。采用二进制表示识别的字符。实验当中小波神经网络使用的参数如下:学习率 $\eta = 0.2$,动量因子 $\mu = 0.7$,目标误差 0.001, $\beta = 0.4, \gamma = 0.5$ 。

本文采用提取的新的不变矩特征值对优化后的小波神经网络进行训练,其训练完成时的误差曲线如图 3(a)所示,并用训练好的小波神经网络对测试字符进行识别,测试识别率达到 96% 以上。

同时本文也给出对采用均方差函数的小波网络进行训练的误差曲线图,如图 3(b)所示。对比两组误差曲线图可以得出,本文所提出的方法对网络的收敛速度有了很大程度的改善。




图 3 训练误差曲线

5 结语

本文提出基于熵函数准则的小波网络用于车牌字符识别的方法,该方法对传统小波网络的学习算法进行了优化,使得收敛性和分类性有了很大的加强,并具有较强的应用性。就车牌字符识别来看,本文给出的方法能取得较好的识别效果,从而表明基于相对熵函数准则的小波网络应用于车牌字符识别是行之有效的。

参考文献:

- [1] 武强,童学锋,季隽.基于人工神经网络的数字字符识别[J].计算机工程,2003,29(14):112-113,132.
- [2] 王海涛,黄文杰,朱永凯,等.基于聚类分析与神经网络的车牌字符识别[J].数据采集与处理,2008,23(2):238-242.
- [3] ZHANG Q, BENVENISTE A. Wavelet networks[J]. IEEE Transactions on Neural Networks, 1992(3): 889-898.
- [4] SUN ZEHANG, HU SHAOHAI, ZHANG SIDONG, et al. The entropy function criterion for BP algorithm[J]. 北方交通大学学报, 1997,21(5):543-547.
- [5] 朱雪龙.应用信息理论基础[M].北京:清华大学出版社,2002.
- [6] 廉春波.基于相对熵函数准则的 BP 算法收敛性分析[D].哈尔滨:哈尔滨工程大学,2007.
- [7] CHEN Z, FENG T J, MENG Q C. The application of wavelet neural network in time series prediction and system modeling based on multiresolution learning[C]// IEEE International Conference on Systems, Man, and Cybernetics. New York: IEEE, 1999:425-430.
- [8] 赵学智,邹春华,陈统坚,等.小波神经网络的参数初值化研究[J].华南理工大学学报:自然科学版,2003,31(2):77-79.
- [9] 赵亚丽,西广成,易建强.基于相对熵函数准则的 BP 算法[J].计算机工程,2005,31(19):12-14.
- [10] HU MINGKUI. Visual pattern recognition by moment invariants[J]. IRE Transactions on Information Theory, 1962, 8(2): 179-187.
- [11] 丁明跃.不变矩算法的研究[J].数据采集与处理,1992,7(1):1-9.
- [12] 吕洪涛,周继成.离散状态下的不变矩算法研究[J].数据采集与处理,1993,8(2):44-48.