

# 基于 QNN 的图像特征提取字符识别系统设计

王金环, 黄玉蕾

(西安培华学院, 西安 710125)

**摘要:** 为提高字符识别的正确率与可靠性, 将图像处理技术与量子神经网络(QNN)相结合, 对基于 QNN 的字符识别系统进行了研究; 采用粗网格特征法对图像的特征量进行提取, 同时, 为了增强粗网格特征法抗位置变化的能力, 在特征提取前, 对字符图像进行了定位, 并将其平移至模板中心, 再进行特征提取, 然后采用基于多层激励函数的量子神经网络对字符进行识别; 采用 matlab 进行仿真实验, 结果表明量子神经网络具有较好的识别效率, 准确率可达 90% 以上, 抗噪能力强, 可以更好地分类; 这说明系统的确可以从一定程度上达到提高识别正确率的效果, 达到了预期效果。

**关键词:** 字符识别; 特征提取; 图像处理; 量子神经网络

## Character Recognition System Design Based on Image Feature Extraction And QNN

Wang Jinhuan, Huang Yulei

(Xi'an Peihua University, Xi'an 710125, China)

**Abstract:** In order to improve the accuracy and reliability of character recognition, combining the image processing technology with the quantum neural network (QNN), the character recognition system based on QNN is studied. Coarse mesh feature method is used to extract the image features. At the same time, in order to enhance the ability of coarse mesh method to resist the change of position, the character image is located and translated to the center of the template before the feature extraction. Then, the quantum neural network based on multilayer excitation function is used to recognize characters. The simulation experiments using MATLAB show that the quantum neural network has better recognition efficiency, and even the accuracy rate can reach more than 90%, and strong noise immunity, and better classification. This shows that the system can indeed improve the correct rate of recognition to a certain extent and achieved the desired results.

**Keywords:** character recognition; feature extraction; image processing; QNN

## 0 引言

近年来, 字符识别一直是图像处理及模式识别领域的研究热点<sup>[1-5]</sup>, 其实用性强, 尤其在大规模数据统计上, 其应用前景更是广阔。伴随着计算机的快速发展, 在图像处理及模式识别研究中, 许多人类难以解决的相对复杂的问题, 都可以借助计算机的高速运算来解决<sup>[6-9]</sup>。在字符识别领域里, 是否能够选取合适的特征提取算法, 其将直接影响到识别率的高低, 鉴于粗网格特征法具有反映字符的整体特征又能缩减网络的规模的优点, 为了更好地提高字符识别的正确率, 本文提出了一种基于粗网格特征法对图像特征量进行提取的字符识别系统。同时, 由于量子神经网络具有高速并行处理能力、良好的容错能力、自学习能力及较强的分类能力等特点<sup>[10-11]</sup>, 且 QNN 克服了传统神经网络所具有的识别精度低、学习速率慢等的缺陷。所以在识别阶段, 对于识别字符来说, 本文采用神经网络分类器是非常有效的手段。

## 1 字符识别系统设计

### 1.1 图像特征提取字符识别系统

本文以数字型字符为研究对象, 针对数字, 设计了基于粗网格特征提取及 QNN 的字符识别系统, 系统大致可分为数字输入、预处理、特征提取、QNN 识别 4 个部分。其工作过程

为: 首先利用样品进行训练, 确定 QNN 识别器的具体参数, 完成分类器的设计。然后再把待识别数字样本集的样品输入到网络中, 用经二值化、行字切分、平滑、去噪、细化等预处理后, 再特征提取的特征量来作为量子神经网络的输入来识别待识别数字, 并输出识别结果。

### 1.2 字符预处理

由于现实环境的影响难以避免, 实际获得的数字图像可能受到严重的噪声干扰, 所以进行特征提取前要先对数字图像进行二值化、平滑、去噪声等预处理, 然后对其进行特征提取。而且当数字图像出现偏移时, 将导致对应网格之间的错位, 从而降低识别率, 所以逐个识别前, 还要进行归一化处理, 必须把它们的位置和大小归一化到一个标准尺寸上, 为数字识别做准备。

由于数字经二值化、平滑、去噪声等预处理后, 可能还存在大小不一的现象, 因此需进行归一化过程。归一化又分为大小及位置归一化。

位置归一化是把整个字符点阵图移到规定位置上, 从而消除其位置偏差。以质心为基础的位置归一化比基于字符外边框的位置归一化方法抗干扰能力强, 所以本文选用基于质心的位置归一化方法。

质心计算:

$$x_c = \frac{\sum_{x=L}^R \sum_{y=B}^T x f(x, y)}{\sum_{x=L}^R \sum_{y=B}^T f(x, y)} \quad (1)$$

$$y_c = \frac{\sum_{x=L}^R \sum_{y=B}^T y f(x, y)}{\sum_{x=L}^R \sum_{y=B}^T f(x, y)} \quad (2)$$

式中,  $x, y$  分别为横、纵坐标,  $f(x, y)$  为字符二值点阵,

收稿日期: 2017-08-11; 修回日期: 2017-09-14。

作者简介: 王金环(1979-), 女, 山东菏泽人, 硕士, 讲师, 主要从事大数据、数据挖掘方向的研究。

$T, B, L, R$  分别表示字符的上下左右边界。

字符大小归一化原理：假设  $f(x, y)$  为原字符图像，大小为  $m \times n$ ， $g(u, v)$  为归一化后字符图像，大小为  $M \times N$ 。 $f(x, y)$  中的任意一点  $(x_0, y_0)$  对应于  $g(u, v)$  中的点  $(u_0, v_0)$ 。 $(u_0, v_0)$  和  $(x_0, y_0)$

之间的映射关系为：

$$\begin{bmatrix} u_0 \\ v_0 \\ 1 \end{bmatrix} = \begin{bmatrix} M/m & 0 & 0 \\ 0 & N/n & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_0 \\ y_0 \\ 1 \end{bmatrix} \quad (3)$$

若映射的  $(x_0, y_0)$  是整点坐标，可直接令： $g(u_0, v_0) = f(x_0, y_0)$ 。若不是整点坐标，再经差值运算确定将  $f(x, y)$  中哪一个点映射到  $g(u, v)$  中。本文选用邻近插值算法，即是取  $(x_0, y_0)$  相邻的上下左右 4 个点中，距离和  $(x_0, y_0)$  最近的点作为插值结果，将此点的  $f(x, y)$  值赋给  $g(u_0, v_0)$ 。将字符大小归一为  $16 \times 16$  像素。

### 1.3 字符特征提取

常用的特征提取方法如：逐像素特征提取法的算法简单，运算快，可以使网络很快地收敛，但适应性不强；骨架特征提取法对于线条粗细不同的数字有一定的适应性，但难以识别偏移图像；垂直方向数据统计特征提取法效果不是很理想，适应性不强<sup>[12]</sup>。本文采用粗网格特征法进行特征量提取。由于粗网格特征法具有抗位置变化能力差的缺陷，所以将其进一步改善，即是在特征提取步骤的前面，先对字符图像定位，找到其中心，并平移到模板中心，再提取粗网格特征<sup>[13]</sup>。本文将已归一化为  $16 \times 16$  像素的数字字符划分为大小为  $2 \times 2$  的  $8 \times 8$  个网格，并将每个网格内的黑像素数量作为特征，因而共抽取 64 个特征。

## 2 识别模型

由于 QNN 具有容错性、自学习、并行处理和分类识别能力强的优点，且字符识别普遍存在相近字符数据交叉问题，所以本文的识别系统，采用基于多层激励函数的 QNN 模型，进行数字字符识别<sup>[14-15]</sup>。

### 2.1 QNN 模型

本文采用基于多层激励函数的 QNN 进行识别工作，网络结构分为输入层、隐含层和输出层。隐含层激励为多个 S 型函数的叠加，相邻函数间有着不同的量子间隔，因而一个隐层神经元能表示的量级和状态增多，网络模糊性增加，网络模式识别的准确率提高。线性叠加的 S 型函数如图 1 所示。

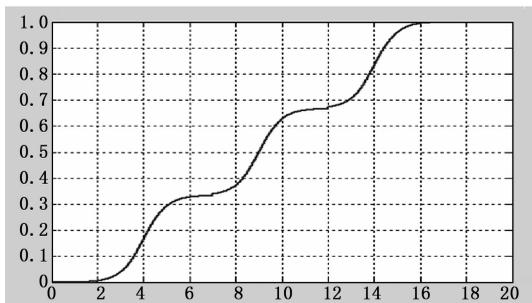


图 1 量子神经网络激励函数

量子神经网络结构如图 2 所示， $LA, LB, LC$  分别为输入层、隐层、输出层，其各层对应节点数  $m, u, n$ 。激励函数  $f(x) = (1 + e^{-x})^{-1}$ ， $W_{ir}, V_{ri}$  分别为输入层神经元到隐层神经

元、隐含层神经元到输出层神经元的连接权， $\theta_s$  为隐层量子间隔， $(s = 1, 2, \dots, ns)$ ， $\varphi$  表示输出层单元的阈值， $X$  是网络的输入向量。

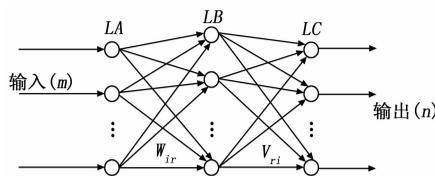


图 2 量子神经网络结构

则可得隐含层节点输出函数表达式为：

$$b_r = \frac{1}{ns} \sum_{s=1}^{ns} f[\beta(W^r X - \theta_s)]$$

输出层节点输出函数表达式为：

$$C_j = f(V^T B - \varphi)$$

式中， $\beta$  是斜率因子， $W$  为权向量，

$X$  为输入向量， $r = 1, 2, \dots, u, j = 1, \dots, n$ 。

### 2.2 训练算法

对 QNN 的训练主要分为对权值和对隐层神经元的量子间隔调整。量子间隔调整使数据不确定性合理化，权值调整可以对输入数据更好地分类。

具体过程为：

1) 令输入特征向量：

$X_k = [x_{1,k}, x_{2,k}, \dots, x_{m,k}]$ ，则对第  $k$  个输入，隐层第  $j$  个单元的 outputs 为：

$$h_{j,k} = \frac{1}{n_s} \sum_{s=1}^{n_s} f\left(\sum_{i=0}^m v_{ji} x_{i,k} - \theta_j\right) \quad (4)$$

输出层第  $i$  个单元的 outputs 为：

$$y_{i,k} = f\left(\beta_0 \left(\sum_{j=0}^u w_{ij} h_{j,k}\right)\right) \quad (5)$$

2) 权值调整采用误差梯度下降算法：

设第  $k$  个输入向量对应实际目标输出：

$$Y'_k = [y'_{1,k}, y'_{2,k}, \dots, y'_{m,k}] \quad (6)$$

期望输出：

$$Y_k = [y_{1,k}, y_{2,k}, \dots, y_{m,k}] \quad (7)$$

输出误差：

$$E_K = \frac{1}{2} \sum_{k=0}^m (y_{i,k} - y'_{i,k})^2 \quad (8)$$

对输出误差求偏导，并结合式 (4)、(5)、(8) 得权值调整公式：

$$w_{pj,k} = -\eta \frac{\partial E_K}{\partial w_{pj}} - w + w_{pj,k-1} \quad (9)$$

$$w_{sq,k} = -\eta \frac{\partial E_K}{\partial w_{sq}} + w_{sq,k-1} \quad (10)$$

$\eta$  为学习速率，在  $0 \sim 1$  内取值， $w_{pj,k-1}$ ， $w_{pj,k}$  为输入层第  $p$  个节点与隐层第  $j$  个节点间调整前后的权值。 $w_{sq,k-1}$ ， $w_{sq,k}$  为隐层第  $s$  个节点与输出层第  $q$  个节点间调整前后的权值。

3) 量子间隔调整仍采用梯度下降法，输入同一类样本，对应输出会映射到同一量级上；输入不同类样本，对应输出会映射到不同量级上。

设对第  $m$  个类  $C_m$  的所有样本计算其隐层第  $P$  个单元的 output 变化：

$$\sigma_{p,m}^2 = \sum_{x_k \in C_m} (h_{p,C_m} - h_{p,k}) \quad (11)$$

$$h_{p,C_m} = \frac{1}{|C_m|} \sum_{x_k \in C_m} h_{p,k} \quad (12)$$

其中:  $|C_m|$  代表类  $C_m$  数集系数。  
则:

$$G = \frac{1}{2} \sum_{p=1}^n \sum_{m=1}^n \sum_{x_k \in C_m} (h_{p,C_m} - h_{p,k})^2 \quad (13)$$

$$\Delta \theta_p^s = -\eta \frac{\partial G}{\partial \theta_p^s} \quad (14)$$

式中,  $\theta_p^s$ 、 $G$  分别代表隐层第  $p$  个神经元相对的第  $s$  个量子间隔、隐层单元对所有类样本输出变化的和,  $\eta$  为调整量子间隔时的学习速率, 联立式 (11) ~ (14) 的量子间隔调整式:

$$\Delta \theta_p^s = -\eta \frac{\partial \beta}{\partial n_s} \sum_{m=1}^n \sum_{x_k \in C_m} (h_{p,m} - h_{p,k}) \left( \frac{1}{|C_m|} \sum_{x_k \in C_m} h_{p,k}^s (1 - h_{p,k}^s) - h_{p,k}^s (1 - h_{p,k}^s) \right) \quad (15)$$

### 2.3 样本库建立

对于数字值 0, 1, ..., 9, 本文通过 Windows 自带的画图工具分别构造了 50 个粗细不一样的相等的数字值, 共 500 个样本作为训练样本库, 计算出他们各自的 128 个特征量, 训练神经网络。由用户手写 0, 1, ..., 9, 共 10 个数字值各 50 个做为待识别样本库。

### 3 系统测试与分析

经预处理及特征提取后, 得到 64 个特征量, 又网络输出采用 8421 编码, 故网络神经元个数输入为 64, 输出为 4, 隐层采用 3 层激励函数, 神经元个数为 15, 输出层激励为 S 型函数, 训练误差平方和不大于 0.005、学习率为 0.005。

图 3 为采集图像原始图, 二值化处理效果如图 4 所示。



图 3 采集图像原始图

图 4 采集图像二值化结果

为验证算法有效性, 本文首先将训练样本库中的数字样本数据分别输入到量子神经网络中进行训练, 以得到合适的权值及量子间隔, 再将测试样本经预处理、特征提取后送入到网络中识别, 并得出识别结果。本文采用 Matlab 做仿真实验, 例如对其中数字 2, 4, 6 进行测试的实验结果及误差分别如图 5~7 所示, 由此可见, 误差范围的确在合理范围 0.005 内。例如对数字 2 识别的均方误差为 2.631189e-03, 对数字 2 识别的均方误差为 1.307583e-03。式 (16) 为正确识别率的公式:

$$\text{识别正确率} = \frac{\text{错误识别数}}{\text{待识别的样本总数}} \times 100\% \quad (16)$$

对实验结果进行统计得表 1, 表 2 为采用传统 BP 神经网络的识别结果。由表 1 可以看出本方案的识别准确率一般都在 92% 以上, 甚至对数字 1 和 6 的识别准确率达到 100%。而从表 2 中可以看出, 采用传统神经网络的对数字的识别准确率有不少都是在 90% 以下, 例如, 对数字 3 和 8 的识别准确率才达到 88%, 并且没有一个数字的识别准确率可以达到

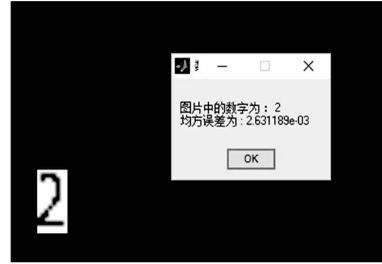


图 5 数字 2 识别结果



图 6 数字 4 识别结果



图 7 数字 6 识别结果

100%。这表明本文将图像处理技术与 QNN 相结合确实达到提高识别准确率的目的, 并且采用 QNN 进行数字字符识别的方法比传统神经网络具有更高的识别效率, 更好的适用性。仔细观察表 1, 表 2 还可以发现, 这两个方法对数字 3, 4, 5, 8 的识别准确率一般都偏低, 这是由于这些数字的结构比其他数字复杂些, 而训练样本的数目有限致使不能达到足够高的训练精度, 所以会识别率会比较低。

表 1 QNN 识别结果统计表

数字	训练样本数	测试样本数	正确识别数	准确率
0	50	50	48	0.96
1	50	50	50	1
2	50	50	49	0.98
3	50	50	46	0.92
4	50	50	46	0.92
5	50	50	47	0.94
6	50	50	50	1
7	50	50	47	0.94
8	50	50	46	0.92
9	50	50	49	0.98

表 3 为对数字 1 在不同的噪声级别下进行测试得到的正确识别率的统计结果, 从中可以发现, 在噪声级别相同时, QNN 的识别正确率比 BPNN 的识别正确率明显大得多, 尤其是噪声级别较高时, 其效果更为明显, 例如当噪声级别为 0.50 时, QNN 比 BPNN 的识别正确率高 20%。这表明量子神

表 2 BPNN 识别结果统计表

数字	训练样本数	测试样本数	正确识别数	准确率
0	50	50	47	0.94
1	50	50	48	0.96
2	50	50	48	0.96
3	50	50	44	0.88
4	50	50	46	0.92
5	50	50	45	0.90
6	50	50	46	0.92
7	50	50	45	0.90
8	50	50	44	0.88
9	50	50	47	0.94

神经网络比传统神经网络具有更高的抗噪能力及可靠性。同时可以看出,无论是 BPNN 还是 QNN,他们的识别正确率都随着噪声级别的增大而减小,只是 QNN 减小的比较缓慢,所以抗噪能力强。

表 3 BPNN 和 QNN 在不同噪声级

噪声标准差	BPNN 识别正确率	QNN 识别正确率	差值
0	0.96	1	0.04
0.5	0.96	1	0.04
0.10	0.92	1	0.08
0.15	0.90	0.98	0.08
0.20	0.90	0.98	0.08
0.25	0.86	0.96	0.10
0.30	0.80	0.90	0.10
0.35	0.74	0.86	0.12
0.40	0.70	0.86	0.16
0.45	0.64	0.80	0.16
0.50	0.54	0.74	0.20

### 4 结论

传统识别方法一般都是单纯依靠图像处理技术,其普遍存在在识别率低的问题。为了能够有效地提高字符的识别率和可靠性,本文将粗特征提取法与基于多层激励函数的 QNN 相结合,并引入模式识别之中,提出一种基于粗特征提取和 QNN 的数字字符识别算法。用粗网格特征法提取图像的特征量,既能够反映字符的整体特征,又能够在一定程度上使网络规模减

(上接第 186 页)

[5] 常军涛,于达仁,鲍文. 基于支持向量机的高超声速进气道不起动模式细化分类研究 [A]. 中国工程热物理学会 2008 年热机气动热力学与流体机械学术会议 [C]. 2008.

[6] Kononenko I. Estimating attributes: Analysis and extensions of RELIEF [J]. Machine Learning: ECML-94, 1994, 784: 171-182.

[7] Kohavi R, John G H. Wrappers for feature subset selection [J]. Artificial Intelligence, 1997, 97 (1): 173-324.

[8] 张丽新,王家康,赵雁南,等. 基于 Relief 的组合式特征选择 [J]. 复旦学报 (自然科学版), 2004, 43 (5): 893-898.

[9] 吴红霞,吴悦,刘宗田,等. 基于 Relief 和 SVM-RFE 的组合式 SNP 特征选择 [J]. 计算机应用研究, 2012, 29 (6): 2074-2077.

[10] 杜洪波,董文娟. Relief-PSO 混合算法在基因微阵列特征选择中的应用 [J]. 沈阳工程学院学报 (自然科学版), 2016, 12 (3): 267-271.

[11] Hank J, Murphy J, Mutzman R. The X-51A Scramjet Engine

小,具有一定的优越性, QNN 作为一种模糊系统,能合理分配决策的不确定性数据到各模式中,从而提高识别的准确率。本文以数字字符为例,结合图像处理技术,采用 Matlab 编程进行进行字符识别仿真实验,通过比较发现, QNN 比传统的 BPNN 的有更高的识别效率,抗噪能力强,可以更好地分类,隐层多层激励函数的使用使得相近字符的数据交叉问题得到有效解决。

### 参考文献:

[1] 陈园园,袁焱丽,室齐双. 基于神经网络的手写体数字识别 [J]. 智能计算机与应用, 2016.

[2] 赵伟,王俊宏,李娟,等. BP 网络在手写体数字识别中的应用 [J]. 林业劳动安全 2005, 20 (9): 1073-1076.

[3] 蔡自兴,成浩. 一种基于骨架特征和神经网络的手写字符识别技术 [J]. 计算技术与自动化, 2001, 20 (3): 59-65.

[4] Qing W, Zhen C, Feng D D, et al. Match between normalization schemes and feature sets for handwritten Chinese character recognition [A]. Document Analysis and Recognition, Proceedings six International Conference [C]. 2001: 551-555.

[5] 胡钟山,楼震,杨静宇,等. 基于多分类器组合的手写体数字识别 [J]. 计算机学报, 1999, 22 (14): 369-374.

[6] 高津京. 计算机测量与控制 [M]. 2002.

[7] 张光建,申时全. 基于 Windows 的计算机测量与控制软件设计 [J]. 贵州大学学报: 自然科学版, 2003, 20 (4): 411-413.

[8] 苟永明. 《计算机测量与控制》发展之路 [J]. 今传媒, 2011, 19 (6): 78-79.

[9] 马智峰. 浅析计算机测量控制系统的自我诊断 [J]. 无线互联科技, 2015 (17): 93-94.

[10] Kak S C. On quantum neural computing [J]. Information Sciences, 1995, 83: 143-160.

[11] Behman E C, Chandrashkar V G, Wang C K. A quantum neural network computes entanglement [J]. Physical Review Letters, 2002, 16 (1): 152-150.

[12] 杨淑莹. 模式识别与智能计算—Matlab 技术实现 [M]. 北京: 电子工业出版社, 2008.

[13] 陈艳平,赵磊. 基于 8 邻域编码逐像素跟踪法的指纹细节特征提取算法 [J]. 电脑知识与技术: 学术交流, 2008, 3 (11): 932-934.

[14] 李政广,吴黎明,等. 骨架提取在 IC 晶片缺陷机器视觉识别中的研究 [J]. 半导体技术, 2007, 32 (4): 53-56, 86.

[15] 刘春丽,吕淑静. 基于混合特征的孟加拉手写体数字识别 [J]. 计算机工程与应用, 2007, 43 (20): 214-215.

[16] Flight Demonstration Program [A]. AIAA International Space Planes and Hypersonic Systems and Technologies Conference [C]. 2008.

[12] 余华兵,唐士廷,胡仁喜. FLUENT14. 5 流场分析从入门到精通 [M]. 北京: 机械工业出版社, 2014.

[13] 周志华. 机器学习: = Machine learning [M]. 北京: 清华大学出版社, 2016.

[14] Cortes C, Vapnik V. Support-Vector Networks [J]. Machine Learning, 1995, 20 (3): 273-297.

[15] 邓乃扬,田英杰. 支持向量机: 理论、算法与拓展 [M]. 北京: 科学出版社, 2009.

[16] 卢运梅. SVM-RFE 算法在数据分析中的应用 [D]. 吉林: 吉林大学, 2009.

[17] 齐立磊,陆剑. 基于粒子群算法改进 SVM 的滑模控制研究 [J]. 计算机测量与控制, 2014 (10): 3230-3232.