

基于改进神经网络算法的蔬菜图像识别

Vegetable image recognition based on improved neural network algorithm

芦 范

LU Fan

(商丘职业技术学院, 河南 商丘 476000)

(Shangqiu Polytechnic, Shangqiu, Henan 476000, China)

摘要:文章提出了改进神经网络算法,建立了径向基函数神经网络模型,包括梯度下降方法求解权重参数,增大邻域半径的均值聚类方法求取隐函数中心值,利用相邻聚类中心获得核宽度,通过量子遗传算法删除冗余权重和神经元;提取了蔬菜图像的特征,并给出了算法流程。仿真试验表明,试验算法对蔬菜图像的形状特征平均识别率为97.56%,纹理特征平均识别率为95.60%,颜色特征平均识别率为93.25%,训练时间平均为5.83 s,识别时间平均为2.18 s,优于其他算法。

关键词:神经网络;径向基函数;量子;蔬菜图像

Abstract: In order to improve the effect of vegetable image recognition, a neural network algorithm was proposed. Firstly, radial basis function neural network model was established, including gradient descent method for solving the weight parameters, K-means clustering method increasing the radius of neighborhood was calculated implicit function center value, and the nuclear width was used adjacent cluster centers. Secondly, quantum genetic algorithm was deleted the redundant weights and neuron. Thirdly, vegetable image feature extraction was extracted. Finally, the process was given. The simulation results showed that the average recognition rate of shape feature was 97.56%, and the texture feature was 95.60%. Moreover, the color feature was found 93.25%, after trained for 5.83 s, and the average recognition time was 2.18 s. The algorithms we reported here was found better than other kinds.

Keywords: neural network; radial basis function; quantum; vegetable image

蔬菜图像识别在食品生产中有着非常重要的地位^[1-2],不但有利于规模化采购,还能按识别结果进行分类,大大减少人力成本。目前,蔬菜图像识别的方法主

要有人工识别^[3]、神经网络算法(NN)^[4]、概率神经网络方法(PNN)^[5]、层次聚类神经网络算法(HCNN)^[6]、卷积神经网络模型(CNN)^[7]、小波分析(WA)^[8]、人工鱼群算法(AFS)^[9]及支持向量机回归(SVR)预测模型^[10]。人工识别存在主观性且效率较低;NN适合自适应学习及进行非线性拟合,但网络结构、神经元的初始权值和阈值随机设定使得最终结果易陷入局部极小值;PNN实现简单,同时识别结果较好,但提取蔬菜图像维度的同时对分类器要求较高;HCNN利用层次聚类结构融合神经网络解决蔬菜识别问题,但聚类的层次数无法自适应调整,且无法避免随机性权值矩阵时的死点问题;CNN的仿生结构较优越,但实现较复杂,训练所需时间较长;WA可提取蔬菜图像的纹理特征,但存在参数优化的难题;AFS由于初始参数设定以及步长因子对算法优化效果会产生较大影响,应用受限;SVR可避免维数灾难,但参数较难选择。

试验拟采用改进神经网络(Improved Neural Network, INN)算法,对神经网络的权值、隐函数中心值、核宽度参数值进行优化求解,同时对多余的神经元通过量子遗传算法删除处理,旨在提高算法的运行速度。

1 改进神经网络

1.1 径向基函数神经网络描述

径向基函数神经网络(RBFNN)具有多层结构^[11],假设第*i*个样本点所包含的输入向量为 $\mathbf{X}_i (i = 1, 2, \dots, n)$, *n*为单元数,第*j*个样本点的输出向量为 $\mathbf{Y}_j (j = 1, 2, \dots, m)$, *m*为输出层单元个数,第*j*个径向基函数的中心向量为 $\mathbf{c}_j (j = 1, 2, \dots, n_c)$,则RBFNN输出为:

$$Y_{ij} = w_{i0} + \sum_k w_{ik} f(\|x_j - c_k\|) = \sum_{k=0}^{n_c} w_{ik} f(c_k - x_j), \quad (1)$$

式中:

w_{i0} ——第*i*个节点的阈值;

基金项目:河南省政府决策研究招标课题(编号:2008B157)

作者简介:芦范(1982—),女,商丘职业技术学院讲师,硕士。

E-mail: 2373984110@qq.com

收稿日期:2019-10-28

w_{ik} —— 隐藏层与输出节点间权重;

Y_{ij} —— 第 i 个节点的输出;

f —— 核函数;

n_c —— 隐藏层节点数。

RBFNN 的核函数为:

$$R_i(x) = \exp\left(\frac{\|x - c_i\|^2}{2\sigma_i^2}\right) \quad i = 1, 2, \dots, m, \quad (2)$$

式中:

$\|x - c_i\|$ —— x 和 c_i 之间的欧式距离;

σ_i —— 核宽;

c_i —— 隐藏层函数的中心值。

1.2 基于梯度下降方法的权重参数计算

RBFNN 权重参数的训练方法采用梯度下降法^[12], 其迭代过程为:

$$\begin{aligned} w_{kj}(t) &= w_{kj}(t-1) - \eta \frac{\partial E}{\partial w_{kj}(t-1)} + a[w_{kj}(t-1) - w_{kj}(t-2)] \\ c_{ji}(t) &= c_{ji}(t-1) - \eta \frac{\partial E}{\partial c_{ji}(t-1)} + a[c_{ji}(t-1) - c_{ji}(t-2)], \end{aligned} \quad (3)$$

式中:

$c_{ji}(t)$ —— 第 j 个隐藏层的第 i 个输入神经元在第 t 次迭代的中心分量;

$w_{kj}(t)$ —— 第 k 个输出神经元与第 j 个隐藏层在第 t 次迭代的权重;

η —— 学习率;

E —— 神经元评价函数。

$$E = \frac{1}{2} \sum_{l=1}^N \sum_{k=1}^q (y_{lk} - o_{lk})^2, \quad (4)$$

式中:

o_{lk} —— 第 l 个输入样本的第 k 个输出神经元的期望输出值;

y_{lk} —— 输出值。

1.3 基于增大邻域半径的均值聚类方法求取 c_i

(1) 网络初始化: 随机选取 h 个训练样本, 计算每个样本的密度值 D_i 。

$$D_i = \sum_{j=1}^n \exp(-\alpha \|x_i - x_j\|^2), \quad (5)$$

式中:

α —— 参数, 取 $\frac{4}{r^2}$;

r —— 样本 x_i 的一个邻域半径。

选取最大 D_{c1} 所对应的样本 x_{c1} 作为第一个聚类中心, 其聚类域为 $W_1(x_{c1})$ 。

(2) 通过增大邻域半径更新样本密度值 D'_i :

$$D'_i = D_i - D_{c1} \exp(-\beta \|x_i - x_{c1}\|^2), \quad (6)$$

式中:

α —— 参数, 取 $\frac{4}{(2r)^2}$ 。

选取最大 D_{c2} 所对应的样本 x_{c1} 作为第二个聚类中心, 聚类域为 $W_2(x_{c2})$; 依次进行密度值更新至 $D_{ci} \leq 0.12D_{c1}$ 。

(3) 计算所有样本输入与聚类中心的距离 $\|x_i - x_{ci}\|$, 按最小距离原则进行分类, 重新计算各个集合中样本的聚类平均值, 若新的聚类中心与原来的一致, 则所得的 x_{ci} 即最终的隐函数中心值, 否则返回(2)进行下一轮求解。

1.4 核宽度计算

对最近 l 个相邻聚类中心进行计算, 获得核宽度:

$$\sigma_i = \frac{1}{l} \left(\sum_{j=1}^l \|c_j - c_i\|^2 \right)^{\frac{1}{2}}, \quad (7)$$

式中:

c_j —— 最近 l 个相邻点的矩心 c_i 。

2 量子遗传算法删除冗余权重和神经元

2.1 量子遗传算法描述

2.1.1 量子比特 量子比特可表示 0, 1 两种状态或者叠加态^[13]:

$$|\varphi\rangle = \alpha |0\rangle + \beta |1\rangle, \quad (8)$$

式中:

α —— 量子比特处于 0 状态的概率幅;

β —— 量子比特处于 1 状态的概率幅;

$|0\rangle$ 、 $|1\rangle$ —— 自旋向下态、自旋向上态;

α^2 —— 量子比特处于 0 状态的概率;

β^2 —— 量子比特处于 1 状态的概率, 满足 $|\alpha|^2 + |\beta|^2 = 1$ 。

2.1.2 染色体编码方案 量子遗传中染色体采用量子位的概率幅进行编码:

$$P_i = \begin{bmatrix} \left| \begin{matrix} \cos(\theta_{i1}) \\ \sin(\theta_{i1}) \end{matrix} \right| & \left| \begin{matrix} \cos(\theta_{i2}) \\ \sin(\theta_{i2}) \end{matrix} \right| & \cdots & \left| \begin{matrix} \cos(\theta_{ik}) \\ \sin(\theta_{ik}) \end{matrix} \right| \end{bmatrix}, \quad (9)$$

式中:

θ_{ij} —— 量子比特的相位, 取 $2\pi \times rand$, $i = 1, 2, \dots, n, j = 1, 2, \dots, k$;

n —— 染色体数目;

k —— 量子位的位数;

$rand$ —— 随机数, 取 $0 \sim 1$ 。

由量子遗传编码规则可知, 量子位分上、下两行, 因此每个个体可包含两个候选解, 在种群规模不变的情况下, 候选解的个数比遗传算法多 1 倍, 增加了解空间的多样性, 提高了寻优成功的概率^[14]。

2.2 量子遗传算法操作过程

2.2.1 神经元权重量子编码方法 对每条神经元的每个

节点的权重进行 0 或者 1 二进制编码,当编码均为 1 时,神经元的权重有效;当编码为 0 时,此节点需删除,以便优化神经网络。因此,神经网络是由 0 和 1 构成的多条序列染色体,染色体长度为该神经网络权重数之和^[15]。

2.2.2 适应度函数 将隐含层数量设为 1,以便精简神经网络,此时适应度函数表达式为:

$$f(net) = \frac{1}{1 + C_i Q_i + C_f Q_f + C_o Q_o}, \quad (10)$$

式中:

Q_i 、 Q_o 、 Q_f ——分别为输入层神经元数量、输出层神经元数量、反馈抽头数量;

C_i 、 C_o 、 C_f ——调整系数。

2.2.3 进化规则 根据优胜劣汰的操作规则,通过轮盘赌选择演变,适应性强的个体更容易遗传给下一代,适应性较低的个体不易遗传给下一代。当在突变过程中从隐含层或输入层删除神经元时,神经元的相应权重也将被删除。

3 蔬菜图像识别过程

3.1 蔬菜图像特征提取

3.1.1 形状特征 圆形度:

$$\begin{cases} C = \frac{S}{\left(\frac{D}{Num}\right)} \\ D = \sum_{i=1}^{Num} \sqrt{(x-X)^2 + (y-Y)^2} \end{cases}, \quad (11)$$

式中:

Num ——边界的像素点数;

x ——蔬菜图像的横坐标;

y ——蔬菜图像的纵坐标;

X 、 Y ——蔬菜图像的质心坐标;

S ——目标图像的面积。

C 越小,蔬菜形状与圆形的差别越大。

外接最小矩形:

$$\begin{cases} \alpha = x \cos \omega + y \sin \omega \\ \beta = -x \sin \omega + y \cos \omega \end{cases}, \quad (12)$$

式中:

ω ——方向角, ($^\circ$);

L ——外接矩形长(取 $\alpha_{\max} - \alpha_{\min}$), cm;

W ——外接矩形宽(取 $\beta_{\max} - \beta_{\min}$), cm。

L/W 越大越能将较细长的物体与方形或圆形物体区分开。

惯量最小的矩的轴角度为:

$$\omega = \frac{1}{2 \arctan \left[\frac{2u_{1,1}}{(u_{2,0} - u_{0,2})} \right]}, \quad (13)$$

式中:

$u_{1,1}$ 、 $u_{2,0}$ 、 $u_{0,2}$ ——分别为(1,1)阶、(2,0)阶、(0,2)阶中心矩。

圆形性:

$$\xi = \frac{L^2}{4\pi S}, \quad (14)$$

式中:

L ——目标图像的周长, cm;

S ——目标图像的面积, cm^2 。

圆形性与 1 差异越大,则其与圆的差别越大。

3.1.2 纹理特征 纹理相关性:

$$S_1 = \frac{\sum_{i=1}^N \sum_{j=1}^N ij p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y}, \quad (15)$$

式中:

S_1 ——判定提取图像像素在某个方向上的相似程度;

$p(i, j)$ ——灰度共生矩阵中位置 (i, j) 处的像素灰度值;

N ——灰度共生矩阵的阶数;

μ_x 、 σ_x ——图像行 x 处的 $p_x(i)$ 的均值、方差;

μ_y 、 σ_y ——图像列 y 处的 $p_y(j)$ 的均值、方差。

3.1.3 颜色特征 颜色直方图只包含蔬菜图像中某一颜色值出现的频次,未考虑颜色的空间位置信息。为了避免两幅不同图像存在相同的直方图,将各颜色通道的像素值量化至 G 个范围内,像素值处于第 g 段的个数为: $\zeta_g + \phi_g$, ζ_g 是颜色为第 g 段内一致性像素个数, ϕ_g 是颜色为第 g 段内不一致性像素个数,颜色一致性特征矢量 H 为:

$$H = [(\zeta_1 + \phi_1), (\zeta_2 + \phi_2), \dots, (\zeta_G + \phi_G)]. \quad (16)$$

3.2 训练过程

将量子遗传算法用于 RBFNN 训练学习 C_i 、 σ_i 、 w_k , 加快收敛速度,优化网络连接结构。设 I_i 为量子神经元的第 i 个输入,则输出为:

$$\begin{cases} u = \sum_{i=1}^n f(\theta_i) f(I_i) - f(\lambda) \\ y = \frac{\pi}{2} g(\delta) - \arg(u) \\ O = f(y) \end{cases}, \quad (17)$$

式中:

$\arg(u)$ —— u 的相位;

λ ——偏置值;

θ_i ——输入角度的相移;

δ ——角度控制;

O ——输出。

蔬菜图像识别流程为:

- ① 对蔬菜样本预处理,产生 RBFNN 的学习与测试样本;
- ② 通过梯度下降方法获得节点间权重;
- ③ 通过增大邻域半径的均值聚类方法获得隐函数中心值;
- ④ 通过相邻聚类中心计算获得核宽度;
- ⑤ 通过量子遗传算法删除冗余权重和神经元;
- ⑥ 根据结果值对训练样本进行训练,获得蔬菜图像识别结果,若达到预先设置的识别准确率,则进行步骤⑦,否则进行步骤②;
- ⑦ 获得最优蔬菜图像识别模型。

4 试验仿真

输入层、输出层神经元数分别为 80,40,隐含层神经元最大数目为 15 个,设定目标误差 10^{-5} ,训练得到的输入层至隐含层的权值为 138 个,阈值为 25 个,隐含层至输出层的权值为 90 个,阈值为 15 个,迭代次数为 300,量子遗传编码长度为 20,最优个体保持代数 6 时算法终止。


蔬菜图像共 12 种:黄瓜、胡萝卜、大白菜、茄子、韭菜、红辣椒、平菇、苦瓜、丝瓜、洋葱、西红柿、菠菜,每种至少包含 50 个样本,在每类蔬菜中随机性选取 30 幅图像进行训练,送入训练程序中,提取相关特征,并以蔬菜名作为文件名称,将特征以文件形式保存,剩余图像作为测试数据,提供给分类器进行识别操作。

4.1 识别结果


算法包括 NN、PNN、HCNN、CNN、WA、AFS、SVR、INN,每种算法进行 50 次试验,在总样本集中进行训练样本,每次随机获取测试样本,并在总样本集中进行测试。

由图 1 可知,INN 算法高于其他算法的平均识别率,INN 算法的形状特征平均识别率为 97.56%,相比 NN、PNN、HCNN、CNN、WA、AFS、SVR 分别提高了 7.95%, 5.65%, 3.68%, 2.15%, 8.37%, 9.74%, 6.19%;纹理特征平均识别率为 95.60%,相比 NN、PNN、HCNN、CNN、WA、AFS、SVR 分别提高了 6.76%, 4.80%, 3.13%, 1.83%, 7.11%, 8.28%, 5.26%;颜色特征平均识别率为 93.25%,相比 NN、PNN、HCNN、CNN、WA、AFS、SVR 分别提高了 5.74%, 4.08%, 2.66%, 1.55%, 6.05%, 7.04%, 4.47%。由于采用量子遗传算法优化 RBFNN 神经网络参数,对冗余神经元权重进行删除,提高了蔬菜图像的识别准确率。


由图 2 可知,洋葱图像平均识别率最高,菠菜图像平均识别率最低,是因为洋葱图像有其自身特殊性,洋葱图像比较接近圆形,旋转其图像变化不大,菠菜由于自身纹理、颜色等易与其他青菜混淆,不便于识别。



(a) 形状特征的平均识别率



(b) 纹理特征的平均识别率



(c) 颜色特征的平均识别率

图 1 不同算法对蔬菜图像的平均识别率

Figure 1 Average recognition rate of vegetable images using different algorithms




图 2 各种蔬菜图像平均识别率

Figure 2 Average recognition rate of vegetable images

4.2 处理时间分析

由图 3 可知,INN 训练时间平均为 5.83 s、识别时间

平均为 2.18 s,与其他算法相比,试验算法消耗的时间较少。




图 3 各种算法的识别性能比较

Figure 3 Recognition performance comparison results of various algorithms

5 结论

针对基本神经网络算法在蔬菜图像识别过程中存在识别率低的问题,提出了一种改进神经网络算法。通过优化径向基函数神经网络、量子遗传算法删除冗余权重和神经元,获得最优的神经网络结构,试验仿真对 12 种蔬菜图像的形状特征、纹理特征、颜色特征平均识别率高于其他算法,说明该方法在蔬菜图像识别中十分有效。试验只针对常见的蔬菜图像进行识别,后续将对外观极度相近的蔬菜图像进行识别。

参考文献

- [1] 程福安,章家岩,冯旭刚,等.基于灰色模型的蔬菜农药残留量不确定度评定[J].食品与机械,2019,35(7):98-102.
- [2] 杨松,伍玉茜,陈敏,等.不同品种莲藕加工脆片适宜性评价[J].食品与机械,2019,35(7):199-203.
- [3] HAMEED K, DOUGLAS C, RASSAU A. A comprehensive review of fruit and vegetable classification techniques[J]. Image and Vision Computing, 2018, 80(11): 24-44.
- [4] 程鸿芳,张春友.自然场景下基于改进 LeNet 卷积神经网络的苹果图像识别技术[J].食品与机械,2019,35(3):161-164.
- [5] FAN Hong-guang, PEI Ji-hong, ZHAO Yang. An optimized probabilistic neural network with unit hyperspherical crown mapping and adaptive kernel coverage[J]. Neurocomputing, 2019, 24(9): 1-11.
- [6] GIAN SALVO C, GABRIELE C, PIETRO B, et al. The GH-EXIN neural network for hierarchical clustering[J]. Neural Networks, 2020, 121(1): 57-73.
- [7] ZHANG Shan-wen, HUANG WEN-zhun, ZHANG Chuan-lei. Three-channel convolutional neural networks for vegetable leaf disease recognition[J]. Cognitive Systems Re-

search, 2019, 53(2): 31-41.

- [8] ZHANG Zhi-guo, KON M A. Wavelet sampling and generalization in neural networks[J]. Neurocomputing, 2017, 267(6): 36-54.
- [9] ZHANG Ze-qiang, WANG Kai-pu, ZHU Li-xia, et al. A Pareto improved artificial fish swarm algorithm for solving a multi-objective fuzzy disassembly line balancing problem[J]. Expert Systems with Applications, 2017, 86(15): 165-176.
- [10] TSIRIKOGLU P, ABRAHAM S, CONTINO F, et al. A hyperparameters selection technique for support vector regression models[J]. Applied Soft Computing, 2017, 61(12): 139-148.
- [11] PAVEL B, MARTIN K. Sensorless control of variable speed induction motor drive using RBF neural network[J]. Journal of Applied Logic, 2017, 24(11): 97-108.
- [12] AMIN A A, MOHAMMAD R D, MEGHDAD A. Neutron spectrum unfolding using radial basis function neural networks[J]. Applied Radiation and Isotopes, 2017, 129(11): 35-41.
- [13] LIU Hua-long. Acoustic partial discharge localization methodology in power transformers employing the quantum genetic algorithm[J]. Applied Acoustics, 2016, 102(15): 71-78.
- [14] 江务学.基于结构优化递归神经网络的网络流量预测[J].西南大学学报:自然科学版,2016,38(2):149-154.
- [15] 赵建龙,曲桦,赵季红,等.基于 Morlet-SVR 和 ARIMA 组合模型的网络流量预测[J].北京邮电大学学报,2016,39(2):53-57.