

文章编号:1001-9081(2010)08-2235-03

基于图像特征的籽棉品级分级模型

马东昱,孙龙清

(中国农业大学信息与电气工程学院 北京 100083)

(gynmania@163.com)

摘要:为了提高在籽棉收购环节中品级分级的客观性和准确性,籽棉品级分级模型以籽棉图像的特征参数为依据,以BP神经网络为分类算法。依据GB1103-2007中籽棉品级分级标准,提取籽棉图像的白度、黄度、杂质作为特征参数,使用部分样本对BP神经网络进行训练,训练后的BP神经网络对未参加训练的样本进行分级,精度达到81%。实验证明,该模型能够提高籽棉分级的客观性和准确性。

关键词:籽棉;图像特征;反向传播神经网络;分级

中图分类号:TP317.4 **文献标志码:**A

Grading model of seed cotton based on image features

MA Dong-yu, SUN Long-qing

(College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China)

Abstract: In order to improve the accuracy and objectivity of classification of seed cotton, the paper presented a grading model. The model was based on image features and used BP neural networks as the classification algorithm. According to GB1103-2007 national standards of seed cotton, white degree, yellow degree and impurity degree were extracted as characteristic parameters. The BP neural networks were trained with part of the samples. After completion of the training, the left samples were substituted into the trained networks, and the result showed that classification precision of the model was 81%. The experimental results show that this model can promote grading accuracy and objectivity.

Key words: seed cotton; image feature; BP neural network; grading

0 引言

籽棉收购是棉花产业链中十分重要的一环,籽棉品级是衡量籽棉收购价格的重要标准。目前,我国籽棉分级检验主要采用手扯目测法,这种基于人工的检验方式受限于检验员的经验,还容易受到人情、利益等诸多因素的影响。研究表明,商业检验品级与专家鉴定品级相符率仅为47%^[1]。导致在收购时混级混价、压级压价、抬级抬价的现象时有发生,不但降低了籽棉收购企业的公信力,也挫伤了棉农的种棉积极性。本文依据国家籽棉品级分级标准对籽棉图像进行特征分析和提取,利用BP神经网络的学习能力和非线性映射能力建立分类模型,在有导师的训练下,使BP神经网络记忆样本信息,具备对籽棉进行分级的能力。

1 特征参数的提取

1.1 样本采集

籽棉样本图像在黑背景下由数码相机拍摄生成。以3~5品级籽棉为例,抽样选取了各级籽棉中16个棉样共3×16个样本。

1.2 图像分析

国家标准GB1103-2007《棉花—细绒棉》中规定,籽棉品级依据成熟度、白度、黄度、棉瓣大小、僵瓣多少、杂质含量等指标分为七个品级。

籽棉白度间接反映了籽棉成熟度,是对籽棉品级贡献最大的正相关因子;籽棉黄度很大程度上反映了籽棉生长期受到的霜害及病害^[2],是由自然因素引起的籽棉品级负相关因

子;杂质含量反映了籽棉在采摘、搬运过程中混入的各种异物,是由人为因素引起的籽棉品级负相关因子。与采摘时相比,收购时的籽棉由于挤压等物理行为产生严重变形,使棉瓣的尺度信息损失过大,综合考虑国家标准的要求与籽棉图像的特点,选取了白度、黄度、杂质作为自变量,籽棉品级作为因变量。

为了提取特征参数,需要统计籽棉样本图像各个区域(白色区域、黄色区域、杂质区域、背景区域)的大小。考虑到籽棉样本图像不具备明显的尺度与纹理特征^[3],采用基于像素统计特征的区域归类方法。在RGB颜色空间下,每个像素由红(R)、绿(G)、蓝(B)3个颜色分量按不同比例混合而成。分别对样本图像的白色区域、黄色区域、杂质区域、背景区域进行抽样选点并统计其RGB分量的均值与方差,结果如表1所示。

由表1数据可知,白棉像素RGB各分量值相当,均值较大(100~255),方差较小(0~10),属灰色系;黄棉像素的RG分量值相当,与B分量值相差较大,均值较大(100~255),方差较大(10~50),属黄色系;杂质像素呈现均值较小(0~100),方差较大(10~40)的总体特征,多为木屑、植物叶与异性纤维,无明确色系;背景像素RGB各分量值相当,均值较小(0~20),方差较小(0~10),属灰色系。考虑到白棉区域占了籽棉的绝大部分,为了更精确地反映籽棉的品级,进一步将白棉区域细分为优白棉区域(均值100~150)与次白棉区域(均值150~255)。综上,采用以下归类方案:

- 1) 均值150~255,方差0~10,归为优白棉;
- 2) 均值100~150,方差0~10,归为次白棉;

收稿日期:2010-02-07。 基金项目:国家科技支撑计划项目(2006BAD30B05)。

作者简介:马东昱(1983-),男,辽宁本溪人,硕士研究生,主要研究方向:数字图像处理、农业信息化; 孙龙清(1964-),男,副教授,主要研究方向:软件理论与设计、计算机网络、智能信息处理。

3) 均值 100 ~ 255, 方差 10 ~ 50, 归为黄棉;

4) 均值 020 ~ 100, 方差 10 ~ 40, 归为各类杂质;

5) 均值 000 ~ 020, 方差 00 ~ 10, 归为黑色背景;

6) 上述特征以外的像素, 作为奇异点(噪声)单独统计。

表 1 各区域抽样像素的统计特征

白棉像素统计特征					黄棉像素统计特征					杂质像素统计特征					背景像素统计特征				
R	G	B	均值	方差	R	G	B	均值	方差	R	G	B	均值	方差	R	G	B	均值	方差
195	203	205	201.00	5.29	118	85	34	79.00	42.32	123	102	59	94.66	32.62	8	8	8	8	0
187	188	193	189.33	3.21	171	159	117	149.00	28.35	76	48	34	52.66	21.38	11	13	12	12	1
204	208	207	206.33	2.08	177	171	137	161.66	21.57	34	21	15	23.33	9.71	16	16	16	16	0
174	180	176	176.66	3.05	176	168	131	158.33	24.00	84	62	39	61.66	22.50	9	9	9	9	0
191	203	201	198.33	6.42	177	172	130	159.66	25.81	85	79	55	73.00	15.87	13	13	13	13	0
179	190	186	185.00	5.56	160	155	117	144.00	23.51	33	28	22	27.66	5.50	8	8	8	8	0
194	199	193	195.33	3.21	110	90	53	84.33	28.91	51	45	33	43.00	9.16	3	3	3	3	0
177	183	179	179.66	3.05	121	99	58	92.66	31.97	74	70	67	70.33	3.51	8	8	8	8	0
142	154	152	149.33	6.42	94	87	59	80.00	18.52	85	82	63	76.66	11.93	7	7	7	7	0
201	207	197	201.66	5.03	195	194	173	187.33	12.42	89	75	49	71.00	20.29	9	11	10	10	1

1.3 预处理

在对籽棉图像进行取样时, 无法保证每一次的光照条件均相同。即便对同一棉样进行连续拍摄, 所得图像的亮度也会存在差异。实际中, 无法控制时间、场所、天气等不可控因素, 这些物理条件的变更又确实影响了拍摄时的光照程度, 导致图像亮度失去其作为衡量参数的准确性。为了最大限度上减弱这种因亮度抖动带来的误差, 需要对图像进行亮度修正, 方法是对图像亮度进行整体平移。

设在标准环境下进行采样的籽棉图像具备最大亮度的像素点($R = G = B = 255$)。统计实际籽棉图像的最大亮度, 记为 ℓ , 则亮度修正系数 $\eta = 255 - \ell$ 。归类分割时, 每个像素的亮度(均值)都加上 η 进行同步修正, 在没有改变图像整体亮度分布的情况下, 模拟出相同条件下的光照环境。现有两张样本图像, 由同一棉样分两次拍摄生成。亮度修正前, 提取的归一化特征参数如表 2 所示。

表 2 亮度修正前提取的特征参数

优白棉比重	次白棉比重	黄棉比重	杂质比重	修正系数
0.8934	0.1013	0.0046	6.8129E-4	0
0.9172	0.0771	0.0052	4.9428E-4	0

可见差异系数分别为 0.0258、0.0242、0.0006、1.8701E-4; 亮度修正后, 提取的特征参数如表 3 所示, 其差异系数分别为 0.0146、0.0150、0.0005、0.4342E-4。修正后, 差异同比缩小 43.4%、38.0%、16.7%、76.8%, 效果较为理想。

表 3 亮度修正后提取的特征参数

优白棉比重	次白棉比重	黄棉比重	杂质比重	修正系数
0.9190	0.0758	0.0047	4.7387E-4	9.3333
0.9336	0.0608	0.0052	4.3045E-4	8.3333

1.4 特征提取

利用 1.2 节讨论的基于像素 RGB 统计特征的归类方案, 遍历所有像素并归为 7 个区域。每个区域的像素总数反映了该区域在图像中所占的比重, 其中, 目标物(籽棉区域)由白棉区域、次白棉区域、黄棉区域、杂质区域构成, 记像素总数分别为 S_1, S_2, S_3, S_4 , 它们各自在籽棉区域所占比重(R_i)的计算公式为:

$$R_i = S_i / \sum_{j=1}^4 S_j \quad (1)$$

其中 $R_i (i = 1, 2, 3, 4)$ 即为籽棉图像的归一化特征参数。依据该方法对 15 张样本图像进行特征参数提取, 结果如表 4。

表 4 籽棉图像归一化特征参数

5 级				4 级				3 级			
优白棉	次白棉	黄棉	杂质	优白棉	次白棉	黄棉	杂质	优白棉	次白棉	黄棉	杂质
0.6333	0.3607	0.0040	0.0020	0.8820	0.1071	0.0027	0.0082	0.9230	0.0753	0.0013	3.0626E-4
0.7265	0.2675	0.0046	0.0014	0.7746	0.2217	0.0021	0.0016	0.8974	0.0981	0.0036	9.1583E-4
0.6680	0.3176	0.0121	0.0022	0.8890	0.0926	0.0151	0.0033	0.9354	0.0622	0.0022	2.1637E-4
0.6529	0.3410	0.0043	0.0017	0.8626	0.1338	0.0030	5.6900E-4	0.9010	0.0976	0.0011	3.7177E-4
0.7318	0.2544	0.0017	0.0121	0.8934	0.1013	0.0046	6.8129E-4	0.8293	0.1694	9.4868E-4	3.3204E-4

2 分类模型的构建

2.1 BP 神经网络的拓扑结构及学习算法

BP 神经网络是由大量处理单元组成的非线性大规模自适应系统^[4], 它采用基于赫布(Hebb)规则的误差反向传播学习算法^[5], 将网络的学习过程转化为一个优化搜索过程。典型的 BP 神经网络如图 1 所示。

记 $d(n)$ 为第 n 次迭代时期望输出向量, $y(n)$ 为第 n 次迭代时实际输出向量, $e(n) = d(n) - y(n)$ 为第 n 次迭代时误差向量, 定义 $E(n)$ 为第 n 次迭代时输出端总的平方误差, 公

式为:

$$E(n) = \frac{1}{2} \| e(n) \|^2 \quad (2)$$

BP 算法在每次迭代过程中, 以权向量 $w(n)$ 为自变量, 以 $E(n)$ 为目标函数, 采用梯度下降法对权向量进行逐次修正, 公式为:

$$w(i+1) = w(i) + \eta g(i) \quad (3)$$

其中: $w(i)$ 表示第 i 次修正前的权向量, η 表示修正步长, $g(i)$ 表示第 i 次修正时目标函数 $E(n)$ 关于权向量 w 的梯度, $w(i+1)$ 表示第 i 次修正后的权向量。通过输入信号前向传播

和误差信号反向传播的交替进行,在权向量空间执行误差函数沿梯度下降的策略,动态迭代搜索一组权向量,使网络误差函数 $E(n)$ 达到最小值,从而完成信息提取和记忆过程。

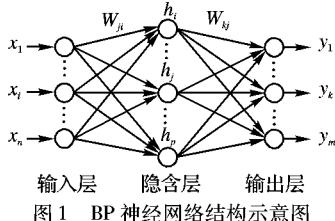


图1 BP神经网络结构示意图

2.2 隐含层及传递函数的选择

本文的籽棉品级分级模型要实现特征参数到品级的非线性映射。理论证明,仅有输入层、输出层的神经网络只能解决线性可分的分类模式问题,要增强网络的分类能力,唯一的方法是采用多层网络结构,即在输入层与输出层之间增加一个或多个隐含层。Robert Hecht-Nielson 在 1998 年证明了对任何在闭区间内的连续函数,都可以用一个隐含层的 BP 网络来逼近,一个三层的 BP 网络可以完成任意的 n 维到 m 维的映射。因此,本文选择了具有一个隐含层的三层网络结构。

隐含层单元数的确定是 BP 神经网络至今难以解决的问题。单元数过少会使训练精度降低,单元数过多则会出现“过拟合”现象,即网络记忆了过多细节导致泛化能力下降。通常,隐含层单元的数目是由试错法决定的,也有一些经验公式可供参考^[6]:

$$n_1 = \ln n \quad (4)$$

$$n_1 = \sqrt{n + m} + a \quad (5)$$

其中: n_1 为隐含层单元数, n 为输入层单元数, m 为输出层单元数, a 为 1 ~ 10 的常数。依据式(5),本文的 n 为 4, m 为 1, 则 n_1 的范围为 3 ~ 13。通过多次实验效果的比较,最终确定 n_1 为 10。

本文 BP 网络为 4-10-1 型拓扑结构,输入层与隐含层神经元均选择了标准的 sigmoid 函数(如图 2(a))作为传递函数,该函数可将实数范围内的输入映射为(0,1)的输出,很好地模拟了生物神经元兴奋(输出为 1)与抑制(输出为 0)的状态,又连续可微,满足了误差反向传播的需要。输出层为单神经元结构,其输出值为最终品级,要求范围在(0,8),因此,不能采用输出受限的 sigmoid 函数,而采用了输出可为任意值的纯线性 purelin 函数(如图 2(b))。

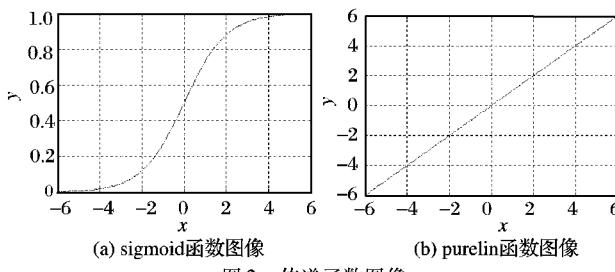


图2 传递函数图像

2.3 网络收敛速度的改善

为了提升 BP 网络在大批量籽棉样本图像下的训练速度,本文从两个方面对学习算法进行了改进。

首先,在标准的权值调整公式 $\Delta w(n) = \eta g(n)$ 中,引入了一个动量项 $\alpha w(n-1)$ ^[7],令:

$$\Delta w(n) = \alpha w(n-1) + \eta g(n) \quad (6)$$

其中: α 为遗忘因子,在[0,1] 取值, $w(n-1)$ 为调整前的权值。当本次的修正量 $\eta g(n)$ 与前一次同号时,式(6)增大了权

值修正量,从而提高了收敛速度;当本次的修正量 $\eta g(n)$ 与前一次异号时,说明有一定的震荡,式(7)减小了权值修正量,起到了稳定的作用。

其次,为了使步长 η 可以随着迭代而产生适当的调整,引入了自适应步长^[8-9]:

$$\eta(k) = \eta_0 \frac{1}{1 + k/k_0} \quad (7)$$

其中: k 代表迭代的次数, η_0 代表初始学习参数, k_0 是恰当选择的常量,在 100 ~ 500。当 $k \ll k_0$ 时,学习率近似为常量 η_0 ,对应于搜索阶段,网络离全局最小值相当远,步长相对较大,以使网络能向误差曲面的最小值方向迅速下降;当 $k \gg k_0$ 时,学习率以每次 $1/k$ 的比例减少,对应于收敛阶段,网络已十分接近全局最小值,步长相对较小,并且能随着迭代逐步减小,以使网络能进行权值的精细调整。

同时引入动量项及自适应步长后,在训练样本相同的情况下,改进型 BP 算法迭代 6000 多次达到预设精度,标准 BP 算法迭代 25000 多次达到预设精度,速度提升约 4 倍。

2.4 输入的预处理及权值的初始化

在 1.4 节中,提取了优白棉比重、次白棉比重、黄棉比重、杂质比重作为籽棉样本图像的特征参数。这 4 个参数分别代表了不同的物理量,大量实验数据表明,它们的取值范围分别落在(0.5,1),(0,0.5),(0,0.1),(0,0.1),差别很大。对于采用了 sigmoid 函数作为激活函数的网络而言,为了避免工作在函数的平坦区域或剧变区域,需要把输入数据限制在 0.1 ~ 0.9,做如下区间变换:

$$x_{in} = 0.9 - \frac{0.9 - 0.1}{x_{max} - x_{min}}(x_{max} - x) \quad (8)$$

其中: x_{max} 为 x 可能取的最大值, x_{min} 为 x 可能取的最小值,用变换后的 x_{in} 值代替 x 值作为网络输入。以表 4 中特征参数(0.8890, 0.0926, 0.0151, 0.0033)为例,处理后,网络实际输入为(0.7224, 0.2482, 0.2208, 0.1264),均在激活函数的最佳工作区间,网络性能较佳。

在首次训练之前,需要对网络权值进行初始化。为了适应本文 BP 网络单隐层的特点,选择了针对单隐层进行优化过的 Nguyen-Widrow 算法^[10], 初始化过程如下:

1) 计算缩放因子 $\gamma = 0.7^{\eta_0} \sqrt{n_1}$, n_0 为输入层神经元个数, n_1 为隐含层神经元个数。本模型中, $n_0 = 4, n_1 = 10$, 则 $\gamma = 1.24$ 。

2) 初始化所有权值为 -0.5 ~ 0.5 的随机数。

3) 按下式重新初始化权值:

$$w_{ij} = \gamma \frac{w_{ij}}{\sqrt{\sum_{i=1}^{n_1} w_{ij}^2}}$$

4) 对于隐含层第 i 个神经元,设置偏置(阈值)为一个为 $-w_{ij} \sim w_{ij}$ 的随机值。

经多次测试,采用该算法初始化的权向量,将取得一个较好的迭代起始点,有效降低了网络陷入局部极小值的可能性,并提高获得全局最优解的概率。

2.5 网络的训练及测试

在 VC++ 下,用 C 语言实现整个籽棉分级模型。

将样本分为训练集和测试集,随机选取 3×10 个训练集样本,在 0.0001 精度要求下对网络进行训练,迭代 6000 次后达到精度要求,训练完成。再随机选取 3×7 个测试集样本,

(下转第 2268 页)

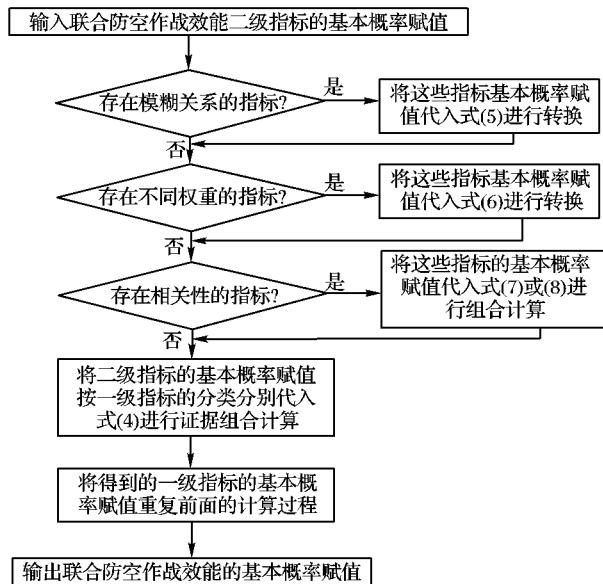


图 2 基于证据理论的联合防空作战效能评估运算流程

5 结语

联合防空作战效能评估是一个复杂而重要的问题。本文通过对证据理论的深入分析，并利用这种重要的不确定性推理方法，建立了基于改进证据推理的联合防空作战效能综合评估模型，并充分考虑了模糊、证据加权、证据相关等可能出现的实际问题。通过对模型进行改进和完善，将联合防空作战效能评估问题划分为若干个评价指标，并对这些指标进行

分析和细化，构造出了层次化的指标体系。在对子指标、子证据进行处理后，由下层往上层利用证据组合规则进行多次证据组合运算，计算出顶层目标的基本概率赋值，然后选择合适的决策规则得出原问题的判决结果。实例表明，利用该模型能对联合防空作战效能进行全面、客观的评估，比较符合实际，可为作战指挥员决策提供重要依据，本文的研究也将为联合防空作战效能的评估提供一个崭新的研究思路和方法。

参考文献：

- [1] 孙巨为, 王贻峰, 王仰国. 一体化联合防空作战指挥效率评估研究[J]. 现代防御技术, 2008, 36(1): 70 - 74.
- [2] 李明军, 张志顺. 模糊综合评判在军队指挥效能评估中的应用[J]. 火力与指挥控制, 2004, 29(5): 51 - 53.
- [3] 王颖龙. 联合防空战役研究[R]. 三原: 空军工程大学导弹学院, 2003.
- [4] 何友, 王国宏. 多传感器信息融合及应用[M]. 北京: 电子工业出版社, 2007.
- [5] BEYNON M, CURRY B, MORGAN P. The dempster-shafer theory of evidence: an alternative approach to multicriteria decision modeling[J]. The International Journal of Management Science, 2000, 28(1): 37 - 50.
- [6] 胡子康, 王永县, 朱涛. 基于改进的证据推理方法的多指标决策模型[J]. 运筹与管理, 2006, 15(6): 1 - 7.
- [7] LEFEVRE E. Belief function combination and conflict management[J]. Information Fusion, 2002, 3(2): 149 - 162.
- [8] 杨春, 李怀祖. 一个证据推理模型及其在专家意见综合中的应用[J]. 系统工程理论与实践, 2001, 21(4): 43 - 48.

(上接第 2237 页)

其分级效果如表 5 所示。

表 5 测试集分级结果

5 级		4 级		3 级	
实际品级	预测品级	实际品级	预测品级	实际品级	预测品级
5	5.3607	4	4.3876	3	3.2764
5	5.2675	4	3.9042	3	3.4651
5	5.3176	4	4.5390	3	3.0453
5	4.3410	4	4.2905	3	3.7923
5	5.2544	4	5.2043	3	3.2192
5	4.7963	4	4.3756	3	3.3559
5	5.4760	4	4.0988	3	2.8391

预测品级为浮点数，实际品级为正整数，采取四舍五入的方法对预测品级进行取整后，5 级样本的分级精度为 85.7%，4 级样本的分级精度为 71.4%，3 级样本的分级精度为 85.7%，总的分级精度为 81.0%。

3 结语

依据国家籽棉品级的分级标准，结合籽棉样本图像的特殊性，提取优白棉比重、次白棉比重、黄棉比重、杂质比重作为品级分级判断的特征参数。通过对图像中各个区域像素的抽样分析，归纳出各区域像素在 RGB 颜色空间下的统计特征，以此为原则遍历并划分像素，统计出各区域比重。为了减小非标准拍摄环境所带来的亮度抖动，采用亮度修正系数对图像亮度进行了补偿，取得较好的效果。分类器选用了 BP 神经网络，针对本文具体的输入输出要求，确定了网络的传递函

数、隐含层数、隐单元数等拓扑参数。在标准 BP 算法的基础上，同时引入了动量项和自适应步长改善网络的收敛速度，实验证明，改进后的学习算法收敛速度明显加快。使用已分好级的样本图像对网络进行训练和测试，其训练精度为 100%，测试精度为 81%，高于人工分级的精度，效果较为理想。

参考文献：

- [1] WAN S-A. Research and analysis of cotton quality [J]. China cotton processing, 2002, 5: 18 - 21.
- [2] 于慧春. 霜黄棉的品级检验[J]. 中国棉花加工, 2003(5): 14 - 17.
- [3] 章毓晋. 图像工程[M]. 北京: 清华大学出版社, 2007.
- [4] 史忠植. 神经网络[M]. 北京: 高等教育出版社, 2009.
- [5] RUMELHART D E, HINTON G E, WILLIAM R J. Learning representation of back-propagation errors [J]. Nature, 1986, 323: 533 - 536.
- [6] 韩立群. 人工神经网络[M]. 北京: 北京邮电出版社, 2006.
- [7] RUMELHART D E, MCCLELLAND J L. Parallel distributed processing: exploration in the microstructure of cognition[M]. Cambridge, MA: MIT Press, 1986.
- [8] DAYAN P. Computation modeling[J]. Current Opinion in Neurobiology, 1994, 4: 212 - 217.
- [9] HAGAN M T, DEMUTH H B, BEALE M. 神经网络设计[M]. 戴葵,译. 北京: 机械工业出版社, 2002.
- [10] NGUYEN D, WIDOW B. Improving the learning speed of 2-layer neural networks by choosing initial values of adaptive weights[C]// Proceeding of the International Joint Conference on Neural Networks. San Diego, CA: [s. n], 1990: 21 - 26.