

DOI: 10. 13475/j.fzxb.20180305606

应用四层 BP 神经网络的棉纱成纱质量预测

查刘根, 谢春萍

(生态纺织教育部重点实验室(江南大学), 江苏 无锡 214122)

摘要 为进一步提高 BP 神经网络在纱线质量预测时的精度和训练速度, 在传统单隐层的三层 BP 神经网络模型的基础上, 提出具有双隐层的四层 BP 神经网络来进行棉纱成纱质量预测。构建纯棉纱的断裂强力模型和纱线条干 CV 值模型, 并在每个模型下分别设计出 1 个三层 BP 神经网络和 1 个四层 BP 神经网络, 最后利用 MatLab 进行训练和仿真, 且为保证结果的可比较性, 2 种网络模型的训练参数设置和使用的数据均保持一致。结果表明: 在纱线断裂强力模型下, 四层网络相比于三层网络最大训练步数由 740 步减少到 533 步, 相对平均误差由 9.6% 下降到 7.5%; 在纱线条干 CV 值模型下, 四层网络相比于三层网络, 最大训练步数由 929 步减少到 604 步, 相对平均误差由 10.2% 下降到 8.3%。

关键词 成纱质量预测; 棉纱; 四层 BP 神经网络; MatLab 仿真

中图分类号: TS 111.9 文献标志码: A

Prediction of cotton yarn quality based on four-layer BP neural network

ZHA Liugen, XIE Chunping

(Key Laboratory of Eco-Textiles (Jiangnan University), Ministry of Education, Wuxi, Jiangsu 214122, China)

Abstract In order to further improve the accuracy and training speed of the BP neural network in yarn quality prediction, a four-layer BP neural network with double hidden layers was proposed for cotton yarn quality prediction on the basis of the conventional three-layer BP neural network model of single hidden layer. By constructing the model of the breaking strength of pure cotton yarn and the CV model of yarn levelness, a three-layer BP neural network and a four-layer BP neural network were designed under each model, and the final training and simulation were performed using MatLab. In order to ensure the comparability of the final results, the training parameters of the two network models and the data used are consistent. The experimental results show that under the fracture strength model, the maximum number of training steps in the four-layer network compared to the three-layer network is reduced from 740 to 533, and the relative average error decreases from 9.6% to 7.5%. In the yarn levelness CV value model under the four-layer network, compared with the three-layer network, the maximum number of training steps decreases from 929 to 604, and the relative average error decreases from 10.2% to 8.3%.

Keywords yarn quality prediction; cotton yarn; four-layer BP neural network; MatLab simulation

纺纱工艺是纺织生产加工过程中一道十分关键的工序, 纱线品质的高低不仅影响着后道加工工序的效率, 也直接决定了最终织物产品的质量。另外, 纺纱过程中涉及的参数种类众多, 客户对纱线品质的要求不同, 需要经常对工艺参数进行大量调整, 而

且从原棉到纱线, 中间经过了很长的加工流程^[1-2]。然而, 目前对于国内大多数纺织企业来说, 依据纱线品质指标确定配棉方案和调整加工工艺参数时所采用的手段依然是凭借着历史生产经验, 而且还需通过进一步的大量试纺来调节和确定最后生产方案,

收稿日期: 2018-03-23 修回日期: 2018-09-07

基金项目: 国家重点研发计划项目(2017YFB0309200); 江苏省产学研项目(BY2016022-16); 江苏省自然科学基金项目(BK20170169); 纺织服装产业河南省协同创新项目(hnfx14002); 中央高校基本科研业务费专项资金资助项目(JUSRP51731B)

第一作者: 查刘根(1992—), 男, 硕士生。主要研究方向为计算机配棉。

通信作者: 谢春萍(1960—), 女, 教授。主要研究方向为新型纺纱技术。E-mail: wxchp@vip.163.com。

浪费了大量时间和原材料,影响了企业整个生产加工进程。对于我国大多数纺织企业来说,迫切需要找到一种能够代替历史经验的高效智能化的纱线质量预测方法来优化其纺纱工艺,从而提高生产效率和竞争力,合理优化纺纱加工工序,科学地设定生产工艺参数和选择最经济的配棉方案,同时要达到客户及后道工序对纱线品质的要求。

因其突出的优点 BP 神经网络用途十分广泛。其结构简单,具有很强的自适应学习能力,很好的容错性,近十几年来被广泛应用于数据预测等问题上^[3-5]。在进行质量预测问题的建模时,设计者构造的一般都是单隐层的三层神经网络,因为万能逼近定理证明三层网络模型就可完成任意 m 维和 n 维之间的映射。

理论上说,隐含层层数的增加会使网络结构更加复杂化,从而拉长网络误差反向传播的路径,同时还会降低训练的效率,但是,考虑到纱线质量预测模型是一个小样本预测模型,且输入和输出单元数较少,所以,本文在进行棉纱断裂强力 and 条干 CV 值的预测时,提出双隐层的四层 BP 神经网络结构,来进行 2 种模型的训练和仿真实验,并与单隐层的三层 BP 神经网络进行对比分析。

1 BP 神经网络算法与设计

实际上,标准的 BP 神经网络模型结构十分简单,一共包含 3 个组成部分,最前面的是输入参数的输入层,中间是具有 1 个或者多个隐含层的中间层,最后面是网络的输出层,提供最后运算结果。BP 神经网络的训练过程可拆分为 2 步:第 1 步是外界输入信息由输入层到输出层的正向传播;第 2 步是网络处理后的误差信号沿着原来的路径反向传播。网络在传递误差的同时,会进行部分参数的修正,也就是各层之间的连接权值以及隐含层和输出层的阈值大小都会随着反传误差的传递不断地发生变化,当权值和阈值调整到某个适当值时,训练误差将会满足设计者的要求,此时网路训练终止^[6]。图 1 示出一个最基本的 BP 神经网络模型。

图中 P_R 为该模型输入层的第 R 个神经元,权值 W_R 负责连接前后 2 层网络中的神经元, i 为输入层神经元的个数, N 为所有神经元输出的累积, B 为网络的阈值,传递函数 F 定义了网络的输入层向输出层的转换方式, Y 为网络最后的输出,可以用下式表示:

$$Y = F(\sum W_R \sum P_R + B)$$

运用神经网络对纱线的成纱质量进行预测时,




图 1 基本的 BP 神经网络模型

Fig.1 Basic BP neural network model

还有一个问题需要注意,由于神经网络输入层的输入变量单位不同,加上各神经元的权值还会相差若干个数量级,如果直接对原始数据进行神经网络训练很容易出现信息丢失和计算不稳定的情况,因此,在进行神经网络预测前,有必要对收集来的原始数据进行标度,进行统一的标准化处理,从而使最后数据的精度达到预先设定的要求,并在一定程度上提高神经网络的训练效率^[7-8]。本文在构建神经网络前用 \log_{10} 函数对原始数据进行归一化处理。

本文数据来自山东某纺织厂的原棉物理指标及细纱质量指标,棉纱均在相同的生产条件(成纱的工艺配置和温湿度)下纺制。首先构建 2 个预测模型——纱线断裂强力模型和条干 CV 值模型(2 个模型除输出参数不同外,输入参数和网络的结构均保持一致),然后用 MatLab 分别构造 1 个单隐层的三层 BP 神经网络和 1 个双隐层的四层 BP 神经网络,通过同步训练和仿真,完成 2 个模型的预测实验,并通过实验结果比较这 2 种网络结构性能的优劣。

本文筛选出 50 组数据作为 2 种不同网络的训练样本,10 组数据作为仿真时的检验样本。表 1 示出本文使用的部分数据。

表 1 部分原始数据

Tab.1 Partial raw data

马克隆值	上半部平均长度/mm	整齐度	短纤维指数	强度/ $cN \cdot dtex^{-1}$	断裂强力/ cN	条干 CV 值/%
4.4	29.7	83.3	14.3	29.9	714.6	12.4
4.4	29.8	83.3	14.2	30.1	689.5	12.0
4.5	29.8	83.3	14.3	30.1	699.3	12.3
4.4	29.5	82.6	16.4	28.8	679.6	12.6
4.3	29.4	82.6	16.1	29.0	685.8	12.7
4.3	29.4	82.6	16.1	29.0	683.6	12.8
4.4	29.4	82.8	15.8	29.0	671.6	13.0
4.3	29.3	83.0	15.9	28.6	673.7	13.2
4.4	29.3	83.0	15.9	28.6	652.4	12.7
4.3	29.1	82.7	16.4	28.5	676.3	12.9


1.1 三层 BP 神经网络的设计

本文在进行棉纱断裂强力和条干 CV 值预测实

验过程中 2 种模型下的三层 BP 神经网络均采用如图 2 所示的神经网络结构。输入层有 5 个神经元, 和 1 个网络输出单元, 网络隐含层的神经元的个数 S 可由经验公式^[9] 给出。

$$S = \sqrt{0.43is + 0.12s^2 + 2.54i + 0.77s + 0.35 + 0.51}$$

式中 s 为输出层神经元个数。通过上式最后可运算求得隐含层的神经元个数 S 为 4 个, 所以最后网络的结构为 5-4-1。



注: W 为网络中的各神经元权值矩阵; B 为网络的阈值。

图 2 三层网络结构

Fig.2 Three layer network structure

1.2 四层 BP 神经网络的算法与设计

1.2.1 四层神经网络的算法步骤

首先设定相关参数如下: P 为总体样本数; i 为输入层神经元数; n 为第 1 个隐含层的神经元数; m 为第 2 个隐含层的神经元数; s 为输出层神经元数; x 为网络的输入参数, x_1 为第 1 个隐含层的输出; x_2 为第 2 个隐含层的输出; y 为输出层的输出; d 为网络的期望输出; w_i 为输入层和第 1 个隐含层的连接权值; w_n 为第 1 个隐含层和第 2 个隐含层的连接权值; w_m 为第 2 个隐含层和输出层的连接权值; θ_1 为第 1 个隐含层的阈值; θ_2 为第 2 个隐含层的阈值; θ_3 为输出层的阈值; E 为网络的误差。具体算法步骤如下。

- 1) 初始化权值 w_i, w_n, w_m 。
- 2) 逐个输入 P 个样本。

- 3) 计算各层的输出: $x_1 = F(\sum_0^{i-1} w_i x - \theta_1)$; $x_2 = F(\sum_0^{n-1} w_n x_1 - \theta_2)$; $y = F(\sum_0^{m-1} w_m x_2 - \theta_3)$ 。

- 4) 计算各层的反传回来的误差: 输出层误差 $E_3 = (d - y) y(1 - y)$; 第 2 个隐含层的误差 $E_2 = \sum_0^{m-1} E_3 w_m x_2 (1 - x_2)$; 第 1 个隐含层的误差 $E_1 = \sum_0^{n-1} E_2 w_n x_1 (1 - x_1)$ 。

- 5) 学习训练完所有样本后依照权值修正公式进行各层权值的修正。

- 6) 输入新的权值重新进行各层输出和反传误差的计算, 直到满足设定的精度目标值或达到预定的最大学习步数即终止学习。

1.2.2 四层神经网络的设计

万能逼近定理虽然已经证明任意的 m 维到 n 维的映射只需要三层网络就可以完成, 但是针对具体的不同的模型, 就不能确定三层神经网络就是最合理有效的网络结构了。虽然层数的增加会使网络的结构变得冗杂, 但是其减小误差的能力也会随之提升, 因此可提高网络运算的精度, 甚至在解决诸如预测纱线强力此类的输入和输出单元数较少的简单问题中, 只要找到合理的隐含层单元数和恰当的训练函数, 就可以提高训练效率。

为此, 本文将设计含有 2 个隐含层的四层 BP 神经网络来构建棉纱的断裂强力和条干 CV 值的预测模型。依据选择隐含层神经元个数的经验公式^[10], 在经过多次的学习训练和对比分析, 得到较为合理高效的四层神经网络的结构, 其拓扑结构如图 3 所示。第 1 个隐含层由 3 个神经元组成, 第 2 个隐含层包含 2 个神经元, 最后的网络结构为 5-3-2-1。




图 3 四层网络结构

Fig.3 Four-layer network structure

2 训练与仿真

2.1 纱线断裂强力模型

在设定好三层神经网络和四层神经网络的参数和结构之后, 接下来将进行纱线断裂强力预测模型的训练和仿真实验。

2.1.1 三层网络

本文采用 MatLab 提供的神经网络工具箱来进行棉纱断裂强力模型和后面的条干 CV 值模型的学习和训练。相关参数确定如下。

第 1 层的传递函数: tansig 函数; 第 2 层传递函数: purelin 函数; 学习函数: traigdm 函数; 三层网络的训练步数设定为 10 000, 训练目标设定为 0.001, 2 次显示之间的训练步数为 50。

训练得到的误差变化曲线如图 4 所示。

从图 4 可看出, 该模型下三层网络的训练步数为 740 步, 也就是网络的误差在此处达到目标值。

2.1.2 四层网络

在同一个预测模型下, 为保证实验结果的可比




图 4 纱线断裂强力模型三层网络误差曲线

Fig.4 Three-layer network error curve of yarn breaking strength model

性,四层 BP 神经网络的相关参数与三层 BP 神经网络的参数设定保持一致。通过训练得到该神经网络的误差变化曲线,如图 5 所示。四层 BP 神经网络纱线断裂强力模型训练误差在第 533 步达到设定值。




图 5 纱线断裂强力模型四层网络误差曲线

Fig.5 Four-layer network error curve of yarn breaking strength model

2.2 条干 CV 值模型

条干 CV 值预测模型的训练和仿真同样是在设定好单隐层的三层 BP 神经网络和双隐层的四层 BP 神经网络的参数和结构之后进行的,考虑到本文实验比较分析的是隐含层的层数对网络性能的影响,所以在条干 CV 值模型下网络的输入参数可以与纱线断裂强力模型所使用的数据相同,只是此时网络的输出参数由纱线断裂强力值改变为棉纱的条干 CV 值。

2.2.1 三层网络

通过三层 BP 神经网络对该条干 CV 值模型进行仿真实验,得到的误差变化曲线如图 6 所示。可看出,该模型下的三层神经网络需要经过 929 步才能达到目标值。

2.2.2 四层网络

通过四层 BP 神经网络对该条干 CV 值模型进




图 6 条干模型三层网络误差曲线

Fig.6 Three-layer network error curve of yarn levelness

行仿真实验,得到误差变化曲线如图 7 所示。可看出,网络误差在训练的第 604 步达到目标值。




图 7 条干模型四层网络误差曲线

Fig.7 Four-layer network error curve of yarn levelness

2.3 仿真结果

通过三层 BP 神经网络和四层 BP 神经网络对棉纱断裂强力模型和条干 CV 值模型的预测和仿真,在设定好相同的误差精度目标后,得到各自的最大训练步数和最后的相对平均误差,其仿真结果如表 2 所示。显然,相比于三层 BP 神经网络,四层神经网络在效率和误差减小方面都有所提高。

表 2 仿真结果

Tab.2 Simulation results

网络模型	结构	精度目标	最大训练步数	相对平均误差/%
断裂强力模型	三层	0.001	740	9.6
	四层	0.001	533	7.5
条干 CV 值模型	三层	0.001	929	10.2
	四层	0.001	604	8.3

通常,在运用神经网络来进行质量预测模型的训练和仿真时,真实的实测数据和神经网络的预测值之间的接近程度会使用拟合度来进行标度。根据 2 组模型的仿真结果,利用 MatLab 工具箱对最终的数据进行相关性分析,结果如图 8 所示。

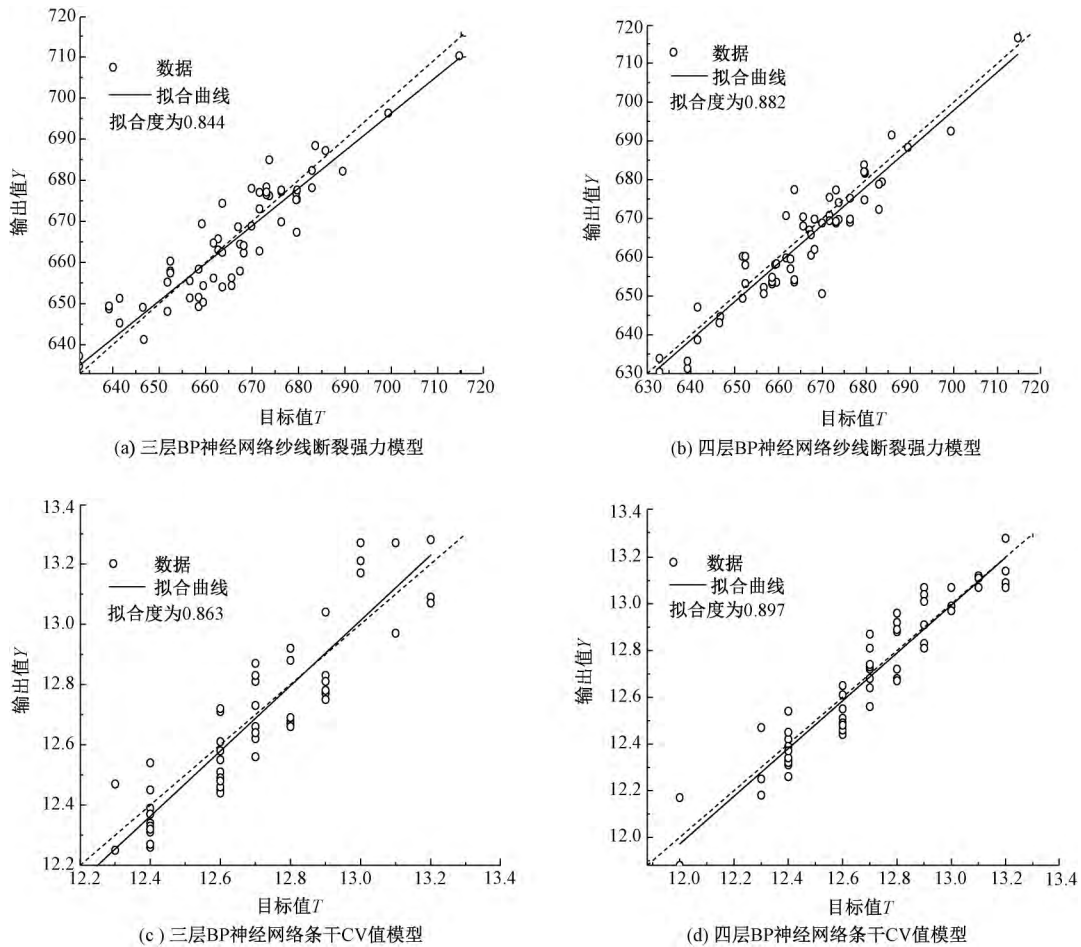


图 8 相关性分析图

Fig.8 Correlation analysis. (a) Three-layer BP neural network yarn breaking strength model; (b) Four-layer BP neural network yarn breaking strength model; (c) Three-layer BP neural network yarn levelness CV value model; (d) Four-layer BP neural network yarn levelness CV Value model

从图 8 可看出 ,三层 BP 神经网络纱线断裂强力模型的拟合度为 0.844 ,四层 BP 神经网络纱线断裂强力模型的拟合度为 0.882; 三层 BP 神经网络条干 CV 值模型的拟合度为 0.863 ,四层 BP 神经网络条干 CV 值模型的拟合度为 0.897。以上分析说明 ,具有双隐层的四层 BP 神经网络相比于三层的 BP 神经网络 ,其预测值与实测值的一致性更高。

3 结论

本文通过设计具有 2 个隐含层的四层 BP 神经网络对棉纱的断裂强力和条干 CV 值进行预测 ,并与三层网络的仿真结果进行比较 得到如下结论: 虽然层数的增加使得神经元总数增加 ,网络的结构变得更加复杂 ,但四层网络的训练步数反而比三层网络的少 ,而且平均相对误差也要小 ,网络也更加稳定。说明将四层 BP 神经网络用于纱线质量预测是合理可行的 ,可在实际的生产活动中具有指导意义。

FZXB

参考文献:

[1] 郝海涛,谢春萍.利用神经网络与 AFIS 纤维测试系统预测纱线质量[J]. 棉纺织技术,2003(8): 8-11.
HAO Haitao , XIE Chunping. Predicting yarn quality using neural network and AFIS fiber testing system [J]. Cotton Textile Technology , 2003(8): 8-11.

[2] 陈俊杰,谢春萍,郝海涛.神经网络纱线质量预报模型的实用化[J].天津纺织科技,2005(4): 17-19.
CHEN Junjie , XIE Chunping , HAO Haitao. Practicalization of artificial neural network yarn quality forecasting model [J]. Tianjin Textile Science and Technology , 2005(4): 17-19.

[3] GUO Daqi. Study on the linear primary function forward three layers neural network's architecture [J]. Journal of Computers , 2005 , 13(9) : 429-443.

[4] 史峰.MatLab 智能算法 30 个案例分析[M].北京:北京航空航天大学出版社,2011: 23-25.
SHI Feng. 30 Cases Analysis of MatLab Intelligent Algorithm [M]. Beijing: Beijing University of Aeronautics and Astronautics Press , 2011: 23-25.

(下转第 61 页)

- yarns[J]. Journal of the Textile Institute, 1994, 85(2): 173-190.
- [7] HU H, ZHU M. A study of the degree of breakage of glass filament yarns during the weft knitting process[J]. Autex Research Journal, 2005, 5(3): 41-148.
- [8] WILLIAMS D. New knitting methods offer continuous structures[J]. Engineering(London), 1987, 227(6): 12-13.
- [9] 刘晓明, 蒋金华, 陈建祥, 等. 玻璃纤维网格织物的编织与性能分析[J]. 东华大学学报(自然科学版), 2008(4): 391-395.
LIU Xiaoming, JIANG Jinhua, CHEN Jianxiang, et al. An investigation into the manufacture and mechanical property of glass net preform[J]. Journal of Donghua University (Natural Science Edition), 2008(4): 391-395.
- [10] RAMAKRISHNA S, HULL D. Tensile behaviour of knitted carbon - fibre-fabric/epoxy laminates: part I: experimental[J]. Composites Science and Technology, 1994, 50(2): 237-247.
- [11] KNAPTON J J F. Knitting performance of wool yarns: instrumentation studies [J]. Textile Research Journal, 1967, 37(7): 539-551.
- [12] SASAKI T, KURODA K. Evaluation and measurement of knittability [J]. Journal of the Textile Machinery Society of Japan, 1975, 21(1): 9-16.
- [13] PETERSON J, VEGBORN E, ANDERSSON C H. Knittability of fibers with high stiffness [C]//The 5th International Conference on Textile Composite. Riga: [s.n], 2000: 1-10.
- [14] COLLIER J R, TAO W Y, COLLIER B J. Bending of internally reinforced rayon fibers [J]. Journal of the Textile Institute, 1991, 82(1): 42-51.
- [15] LAU Y M, TAO X, DHINGRA R. Spirality in single-jersey fabrics [J]. Textile Asia, 1995(8): 95-102.
- [16] 杨昆, 陶肖明, 叶荫权, 等. 一种新型针织用环锭纱的研制及应用[J]. 纺织学报, 2004, 25(6): 58-60.
YANG Kun, TAO Xiaoming, YE Yinquan, et al. Investigation and application of a novel ring knitting yarn[J]. Journal of Textile Research, 2004, 25(6): 58-60.
- [17] 于伟东, 储才元. 纺织物理[M]. 上海: 东华大学出版社, 2002: 126-127, 341-342.
YU Weidong, CHU Caiyuan. Textile Physics [M]. Shanghai: Donghua University Press, 2002: 126-127, 341-342.

(上接第 56 页)

- [5] 焦李成. 神经网络系统理论[M]. 西安: 西安电子科技大学出版社, 1996: 47-55.
JIAO Licheng. Theory of Neural Network Systems [M]. Xi'an: Xidian University Press, 1996: 47-55.
- [6] 张思源, 包燕平, 张超杰, 等. BP 神经网络 IF 钢铝耗的预测模型[J]. 工程科学学报, 2017(4): 6-8.
ZHANG Siyuan, BAO Yanping, ZHANG Chaojie, et al. Prediction model for aluminum consumption of IF steel in BP neural network[J]. Journal of Engineering Sciences, 2017(4): 6-8.
- [7] 马发民, 吴红乐, 张林, 等. 基于 BP 神经网络的疲劳判定[J]. 计算机与数字工程, 2017(6): 24-30
MA Famin, WU Hongle, ZHANG Lin, et al. Fatigue determination based on BP neural network[J]. Computer and Digital Engineering, 2017(6): 24-30.
- [8] ABBASIAA, VOSSOUGH I G R, AHMADIAN M T. Deformation prediction by a feed forward artificial neural network during mouse embryo micromanipulation [J]. Animal Cells and Systems, 2012 (2): 114-123.
- [9] 李翔, 彭志勤, 金凤英, 等. 基于神经网络的精纺毛纱性能预测模型比较[J]. 纺织学报, 2011, 32(3): 27-31.
LI Xiang, PENG Zhiqin, JIN Fengying, et al. Comparison of performance prediction models of worsted wool yarns based on neural network [J]. Journal of Textile Research, 2011, 32(3): 27-31.
- [10] 沈花玉, 王兆霞, 高成耀, 等. BP 神经网络隐含层单元数的确定[J]. 天津理工大学学报, 2008, 24(5): 13-15.
SHEN Huayu, WANG Zhaoxia, GAO Chengyao, et al. Determination of hidden layer units in BP neural network [J]. Tianjin University of Technology, 2008, 24(5): 13-15.