

基于改进 BP 神经网络的中央空调冷负荷预测研究

王 蕾, 张九根, 李 腾, 陈 实

(南京工业大学 自动化与电气工程学院, 南京 211816; 江苏省建筑设计研究院有限公司, 南京 210019)

摘要: 针对中央空调系统冷负荷预测中 BP 神经网络预测收敛慢, 易陷入局部最优, 精度相对低的缺点, 采用了收敛速度快, 全部搜索能力强的粒子群优化算法进行改进, 同时对 BP 结构中的输入参数, 添加控制误差反馈参数, 形成了基于粒子群与控制误差反馈的 BP 神经网络预测技术; 其预测精度较 BP 神经网络和粒子群 BP 神经网络分别提高 5.94% 和 0.82%。

关键词: 负荷预测; BP 神经网络; 粒子群算法; 误差反馈

Prediction of Cooling Load of HVAC System Based on Improved BP Model

Wang Lei, Zhang Jiugen, Li Teng, Chen Shi

(Automation and Electrical Engineering Institute, Nanjing University of Technology, Nanjing 211816, China;
Jiangsu Provincial Architectural D&R Institute LTD, Nanjing 210019, China)

Abstract: Since the shortcomings of the BP neural network prediction method in predicting the building cooling load, such as slow convergence, easy to fall into local optimum and relatively low accuracy, the particle swarm optimization algorithm which has faster convergence and stronger global search capability is introduced to improve the prediction. By adding control error feedback parameters to the input parameters of the BP neural network structure, the BP neural network forecasting techniques based on particle swarm optimization and control error feedback is formed, applied in the central air conditioning system, and enhance the prediction accuracy.

Key words: load prediction; BP neural network; particle swarm optimization; deviation feedback

0 引言

对于空调节能, 如何使空调系统能耗和运行费用最小化, 提高空调系统经济效益, 是一个棘手又必须解决的问题。精确的冷负荷预测是空调系统运行管理的有效依据, 提高控制调节的可预见性及系统的稳定性。目前负荷预测包括静态预测和动态预测, 这些预测方法都需要建立数学模型, 且预测结果的准确性与所建立模型的精度有着密切的关系。

对于空调系统而言, 各房间热传递过程和众多因素有关。由于这些因素的多样性和不确定性, 用静态预测或动态预测所建立的过程模型和对象模型一般比较复杂, 并要处理大量数据。基于这些原因, 人工神经网络(ANN)越来越受到人们的关注。目前 BP 神经网络是其中应用最广泛的神经网络。然而通用的 BP 模型会存在收敛慢, 易陷入局部最优, 精度相对低的缺点^[1]。因此本文基于粒子群优化算法(PSO)的思想, 同时对 BP 结构中的输入参数, 添加控制误差反馈参数(CEF), 对 BP 模型的训练算法进行改进, 提高了收敛速度和预测精度^[2]。

1 空调系统负荷预测 BP 神经网络结构

ANN 以神经元为节点, 采用某种网络拓扑结构来模仿人脑神经系统, 具有记忆、自主学习、知识推理和优化计算等特点。BP 网络含有输入节点、输出节点、一层或多层的隐含节点, 采用多层结构, 输入层、多个隐含层、输出层, 各层之间使用全连接实现, 非常适用于复杂非线性对象的建模。

使用神经网络进行冷负荷预测, 输入参数的选择起着关键性的作用, 只有当那些对冷负荷影响较大的因素都包含在输入参数中时, 才能作出准确的预测^[3]。

建筑冷负荷是一个受多种因素影响的模型, 具有随机性、复杂性及非线性。由于受实际条件限制, 我们选择以下几个参数作为输入: 时刻(t)、室外温度(T_d)、室外湿度(RH)、室内温度(T_r)、室内人数(P)、 $t-1$ 时刻冷负荷(CL_{t-1})、 $t-24$ 时刻冷负荷(CL_{t-24})、 $t-48$ 时刻冷负荷(CL_{t-48})、 $t-1\tau$ 时刻冷负荷($CL_{t-1\tau}$)

对于 BP 神经网络的层数, 应优先考虑 3 层 BP 网络(即 1 个隐层)。隐含层节点数, 尚无确定的方法选择最佳隐含节点数, 本文用于预测的 BP 神经网络结构中, 经过多次试验, 确定隐含节点数为 12。激活函数使用常用的 Sigmoid 函数, 而神经元间的连接权值取值为 0~1 间的随机数据。而空调系统预测的是小时冷负荷值, 即得到 t 时刻的负荷预测值后, 再预测后一小时的负荷值, 由此循序渐进, 故它的输出层节点个数是 1。

2 空调系统 BP 神经网络预测模型的改进

2.1 PSO 优化 BP 神经网络

虽然现阶段 BP 神经网络的应用较为广泛, 但也存在网络初始值选取较繁琐、易陷入局部极小点及收敛速度慢等缺陷。使用粒子群算法(PSO)与 BP 神经网络进行结合, 充分利用它的全局收敛能力和较强的鲁棒性对神经网络进行训练, 由于可以不借助问题的特征信息, 即 BP 神经网络中的梯度信息, 少了复杂的梯度计算及相应的传播时间, 从而缩短了训练时间。既保留了神经网络的泛化映射能力, 还能够提高神经网络的收敛速度及学习能力^[4]。

2.2 控制误差反馈参数的引入

预测系统不是独立的, 需要考虑到其它与之相关联的系统

收稿日期: 2014-01-06; 修回日期: 2014-02-28。

作者简介: 王 蕾(1988-), 女, 硕士研究生, 主要从事建筑楼宇智能化方向的研究。

张九根(1963-), 男, 副教授, 硕士生导师, 主要从事自动化与电气工程方向的研究。

对它的影响。在本文中, 预测系统是与控制紧密相关, 控制过程中产生的误差对预测有重要的训练意义, 它应该作为一个反馈参数进入到神经网络的输入参数中, 因此, 输入参数应加入控制误差 (EC)。

本文所描述的建筑冷负荷预测的 BP 神经网络结构如图 1 所示:

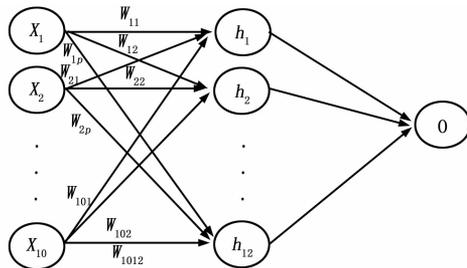


图 1 建筑冷负荷预测的 BP 神经网络结构

2.3 基于 PSO 优化 BP 神经网络流程

在描述 PSO 优化 BP 神经网络流程前, 先说明几个概念^[5]:

(1) 粒子数量: 一般取几十, 根据实际问题来定, 本文取 30; (2) 维度: $D=h \times (I+O+1) + O$, 式中, h 表示隐含层节点数, I 表示输入层节点数, O 表示输出层节点数, 即粒子的维度=输入层到隐含层的连接权值个数+隐含层至输出层的连接权值个数+隐含层的阈值个数+输出层的阈值个数; (3) 适应度函数: 即神经网络中的误差函数, $e = \frac{1}{2} \sum_{i=1}^I \sum_{o=1}^O (d_o(t) - o_o(t))^2$ 用于判断是否停止算法及如何更新粒子位置及速度。

PSO 优化 BP 神经网络流程如下:

- (1) 随机初始化粒子群中粒子位置与速度。
- (2) 对于粒子群中每一个微粒, 计算其适应值, 确定个体最优位置 p 。在所有粒子的最优位置 p 中, 选择最优个体位置 (即适应值最小) 作为全局最优位置 pg 。
- (3) 分别更新各粒子速度和位置。
- (4) 计算粒子群中所有粒子的适应值。
- (5) 对每个粒子, 比较当前粒子适应值与个体最优位置 p 适应值比较, 若适应值更优, 用当前位置及适应值更新 p 。
- (6) 比较当前所有 p 和 pg 的适应值, 更新 pg 。
- (7) 若终止准则满足, 则输出 pg 及适应值并停止算法, 否则转向步骤 (3)。
- (8) 最终输出的粒子位置就是最优权值, 此权值作为 BP 神经网络的连接权值。从而实现 BP 神经网络的训练。

3 基于 PSO 与 CEF 改进 BP 神经网络的空调负荷仿真研究

3.1 负荷预测建模仿真

根据采集的数据, 建立 $10 \times 12 \times 1$ 的 3 层结构模型, 模型如图 2 所示。通过 Matlab 进行仿真。输入层神经元与 BP 神经网络输入变量的选取相同。隐层节点转移函数选用 tansig 函数, 即 $y=f(u) = \frac{1}{1+e^{-u}}$ 。该层神经元数目有 12 个, 采用实际测试的方法对网络进行不断的调试, 综合反馈误差收敛快慢的程度以及预测精度等因素^[5]。输出层节点采用 purelin 函数, 其函数表达式为 $y=f(x) = ax+b$ ^[6]。

本文是以南京某商用建筑为实验对象, 该建筑采用区域集

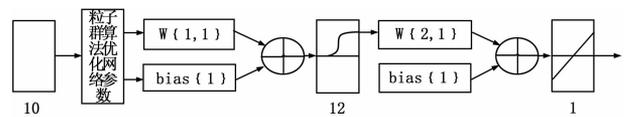


图 2 空调系统 PSO-CEF-BP 神经网络负荷预测模型

中供冷形式, 建筑供冷时间是每年 5~11 月, 工作日内 8:30~17:00, 在本实验中, 利用 2011 年以及 2012 年作为训练数据进行训练, 选取 2013 年 9 月 26 日的预测结果和实际值作比较, 曲线如图 3 所示。

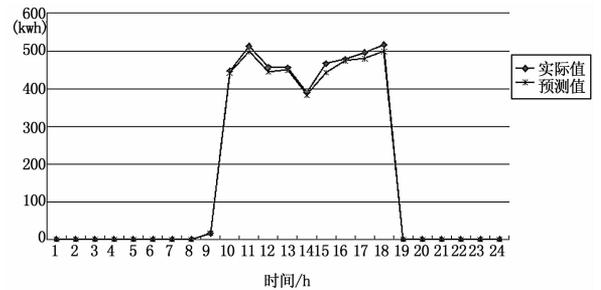


图 3 预测曲线图

可见, 预测结果与实际冷负荷趋势几乎一致, 曲线吻合程度较高。

预测值与实际值的绝对误差和相对误差如图 4、图 5 所示。

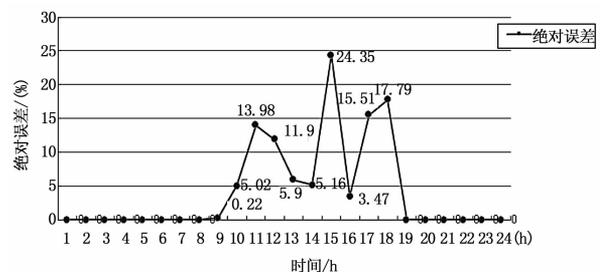


图 4 预测值与实际值的绝对误差

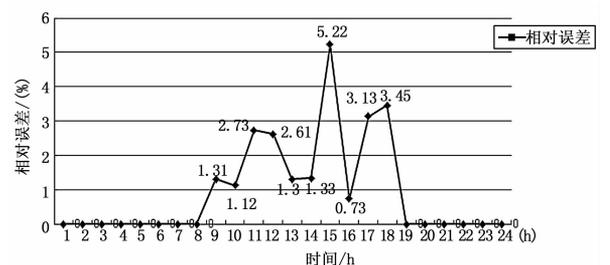


图 5 预测值与实际值的相对误差

计算可知, 使用 PSO-CEF-BPNN 进行预测, 它的最大相对误差是 5.22%, 最小误差是 0.73%, 平均误差为 2.29%, 平均绝对误差是 10.32 kWh, 相对比较小, 完全符合冷负荷预测的应用需求。

3.2 与其它神经网络比较分析

本文提出的同时使用 PSO 和 CEF 优化的预测方法 PSO-CEF-BPNN, 标准 BP 神经网络方法 BPNN, 添加了控制误差反馈的神经网络 CEF-BPNN, 使用 PSO 进行优化的神经网络 PSO-BPNN。使用这 4 种预测方法, 对前面的建筑 2013 年 9 月 26 日进行预测。

(1) 训练性能比较: 训练次数及训练时间比较如图 6 所示。

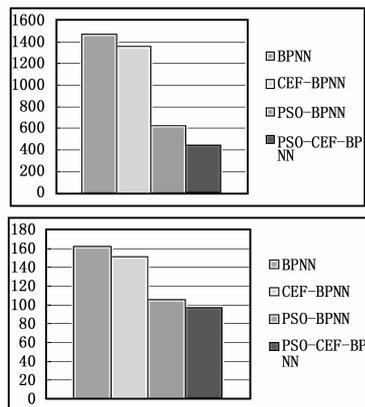


图 6 不同预测方法的训练次数及训练时间比较

由以上图表可知, 使用标准的 BPNN 相对训练次数比较大, 训练时间较长。当添加了控制误差反馈, 有了一定的优化效果, 使用 PSO 优化, 训练效果有了明显的改善, 而使用 PSO-CEF-BPNN 则比 PSO-BPNN 效果又有了少许的提高。

(2) 预测精度对比: 这里只通过平均相对误差 (MAPE) 和均方根误差 (RMSE) 进行比较, 如表 1 所示。

表 1 不同预测方法的预测精度对比

预测方法	平均相对误差 MAPE (%)	均方根误差 RMSE (%)
BPNN	8.23	28.34
CEF-BPNN	7.10	24.32
PSO-BPNN	3.11	14.21
PSO-CEF-BPNN	2.29	12.59

(上接第 1689 页)

仅用单一故障诊断方法的不足, 对于不确定性结果的故障诊断具有很好的融合效果, 因此, 具有很强的可行性。

5 结论

为了实现对飞机燃油系统进行故障诊断, 设计了一种基于禁忌神经网络和 DS 证据理论的飞机燃油系统故障诊断方法。首先建立 3 层 BP 神经网络故障诊断模型, 最后, 采用禁忌优化算法对 BP 神经网络进行结构参数优化, 得到多个并行的禁忌神经网络, 为了进一步提高故障诊断精度, 采用 DS 证据理论对多个并行运行的禁忌神经网络输出结果进行融合, 并通过仿真实验证明了文中方法对飞机燃油系统故障诊断准确率接近 100%, 是一种飞机燃油系统故障诊断的有效方法。

参考文献:

[1] 乔亚琼. 飞机燃油系统智能化故障诊断方法研究 [D]. 西安: 西北工业大学, 2007.
 [2] 魏锦洲, 吕美茜, 陈战斌. 某型飞机燃油系统低油面告警故障分析 [J]. 机械设计与制造, 2012, 4 (12): 137-139.
 [3] Wang D, Feng W Q, Li J W. A hybrid and hierarchy modeling approach to model-based diagnosis [J]. Electrical Engineering and Control, 2011, 98: 173-180.

由以上分析可知, 本文提出的 PSO-CEF-BPNN 预测方法相对其它预测方法有较快的训练速度, 同时预测结果表明, 此预测方法的预测精度也有所提高。

4 结束语

本文主要介绍了基于 PSO 与控制误差反馈改进 BP 神经网络模型的构建及实践。首先从 PSO 与 BP 神经网络结合的可行性进行分析, 提出 PSO 对 BP 神经网络具有优化作用, 且适用于 BP 神经网络的训练优化。接着为建筑冷负荷预测所要构建的 BP 神经网络的相关输入参数进行分析, 包括控制误差反馈的概念, 并将其作为 BP 神经网络的输入参数, 然后对 BP 神经网络结构进行确定, 最后提出基于 PSO 与控制误差反馈改进 BP 神经网络模型 (PSO-CEF-BPNN), 并将其运用于实际的建筑冷负荷预测当中, 并取得良好的效果, 使模型得到了有效的实践与应用。

参考文献:

[1] 陈文鼎, 赵哲身. 基于 BP 神经网络的空调负荷预测 [J]. 节能技术, 2010, (01): 15-17, 24.
 [2] 牛东晓, 赵磊, 张博, 等. 粒子群优化灰色模型在负荷预测中的应用 [J]. 中国管理科学, 2007, (01): 69-73.
 [3] 王雪梅, 李炎锋, 吕子强, 等. 基于负荷动态模拟的冰蓄冷系统优化控制分析 [J]. 沈阳建筑大学学报 (自然科学版), 2010, (03): 552-556.
 [4] 陆宁, 周建中, 何耀耀. 粒子群优化的神经网络模型在短期负荷预测中的应用 [J]. 电力系统保护与控制, 2010, (12): 65-68.
 [5] 李锦升. 基于粒子群与控制误差反馈的 BP 神经网络冷负荷预测及动态目标控制 [D]. 广州: 华南理工大学, 2012.
 [6] 王钰, 郭其一. 基于改进 BP 神经网络的预测模型及其应用 [J]. 计算机测量与控制, 2005, 13 (1): 39-42.
 [7] 杨颖涛, 王跃钢, 邓卫强. 基于 Fisher 准则函数的相关向量机模拟电路故障诊断 [J]. 计算机应用研究, 2011, 28 (6): 2085-2112.
 [8] 张梦云, 潘剑锋, 薛宏, 等. 柴油机燃油供给系统故障诊断研究 [J]. 农机化研究, 2011, 5 (1): 211-214.
 [9] Liu Sen, Chan F T S, Chung S H. A study of distribution center location based on the rough sets and interactive multi-objective fuzzy decision theory [J]. Robotics and Computer-integrated Manufacturing, 2011, (27): 426-433.
 [10] 焦爱红, 袁力哲, 陈燕生. 基于 AGA-BP 算法的智能故障诊断技术研究 [J]. 机床与液压, 2011, 39 (5): 121-124.
 [11] Jiang Z Y, Han J T, Liu X H. Neural network based expert system for steel bar pipeline fault diagnosis [J]. Advanced Materials Research, 2012, 421: 590-594.
 [12] 万凤琴, 许静. 小波神经网络故障诊断法在飞机燃油系统中的仿真研究 [J]. 航空精密制造技术, 2011, 1 (47): 41-46.
 [13] 张鹏, 俞利明, 王婷婷. 基于 PSO-RBF 的飞机燃油系统故障诊断 [J]. 2011, (1): 38-40.
 [14] Palubeckis G. Multistart tabu search strategies for the unconstrained binary quadratic optimization problem [J]. Annals of Operations Research, 2004, 131 (1): 259-282.