

基于改进 BP 神经网络的建筑用电量预测

许 慧¹, 黄世泽², 郭其一¹, 屠瑜权³

(1. 同济大学 电子与信息工程学院, 上海 200331;

2. 同济大学 交通运输工程学院, 上海 201804;

3. 浙江中凯科技股份有限公司, 浙江 乐清 325604)



许 慧(1988—), 女, 硕士研究生, 研究方向为能耗管理系统。

摘 要: 在建立城市层面的建筑用电量预测模型时, 对 BP 神经网络结构及其训练算法进行了研究。针对常规 BP 网络算法收敛速度慢、易陷入局部最小点的缺点, 采用了具有较快收敛速度及稳定性的 L-M 算法进行了改进, 建立了基于改进 BP 神经网络的建筑预测模型。最后通过上海市某栋公共建筑原始用电能耗统计数据作为样本对该预测模型进行了验证, 验证结果表明, 基于改进 BP 神经网络的预测模型适合建筑的用电量预测。

关键词: 非线性; BP 神经网络; 建筑用电能耗; L-M 算法; 预测模型

中图分类号: TM 715⁺.1 **文献标志码:** A **文章编号:** 2095-8188(2014)18-0054-05

Prediction of Building Electricity Consumption Based on Improved BP Neural Network

XU Hui¹, HUANG Shize², GUO Qiyi¹, TU Yuquan³

(1. College of Electronics and Information Engineering, Tongji University, Shanghai 200331, China;

2. School of Transportation Engineering, Tongji University, Shanghai 201804, China;

3. Zhejiang JONK Technology Co., Ltd., Yueqing 325604, China)

Abstract: According to the complex nonlinear characteristics of the building energy consumption, the structure of BP neural networks and its training algorithm were studied. In the study, as the traditional BP algorithm has some unavoidable disadvantages such as the slow training speed and being easily plunged into local minimums, an optimized L-M algorithm was applied, which has a quicker training speed and better stability, to set up a predictive model of the building based on improved BP neural networks. With the statistical data of the public building electricity consumption in Shanghai as a sample, the prediction model was testified. The test result shows the predictive model based on improved BP neural networks is suited to the prediction of building electricity consumption.

Key words: nonlinear; BP neural networks; building electricity consumption; L-M algorithm; prediction model

0 引 言

建筑节能在我国能源政策和能源科技中占据相当重要的地位。它与能源结构调整、开发可再生能源利用组成能源战略的重点^[1]。建筑能耗

预测方法, 可以为城市建筑能耗发展进行很好预测。结合预测可以进行科学合理的能源规划和合理布局。

BP 神经网络训练是一种非线性拟合的方法, 经过训练的神经网络, 对于不在样本集中的样本

黄世泽(1983—), 博士后, 研究方向为智能配电、虚拟样机技术在低压电器中应用。

郭其一(1961—), 教授, 博士, 研究方向为智能化低压电器。

附近的输入也能给出合适的输出。由于 BP 神经网络的强非线性拟合能力,学习规则简单,便于计算机实现,因此目前多利用 BP 学习算法来进行神经网络的训练^[2]。研究表明,人工神经网络具有非常好的非线性映射能力、泛化能力和容错能力,而建筑能耗系统本身可看作是关于时间序列的一个高度非线性系统,故可用一个多层的 BP 神经网络来对建筑能耗进行模拟。

目前,建筑设备大部分以电力为驱动,电能消耗是建筑能耗的主体^[3]。本文以建筑的用电量预测代表建筑能耗预测来进行分析。当前建筑用电量主要采用线性模型进行预测,而建筑用电量是一个非常复杂的非线性系统,因此预测结果不是很理想。文章首先介绍了建筑用电量的影响因素, BP 神经网络的基本概念,并针对传统神经网络算法的缺点用 L-M 算法进行改进,最后用 Matlab 对上海某栋大型办公建筑原始用电量的数据进行分析,根据分析结果构建了基于改进的 BP 神经网络的建筑物用电量预测模型,仿真及实践结果表明,该预测模型是可行的。

1 建筑用电量影响因素分析

办公类建筑能耗按用能系统的主次关系分类,主要包括制冷通风能耗、采暖能耗、照明能耗、室内办公设备能耗和其他综合能耗。其中空调采暖能耗包括电耗和冷热源能耗,其他综合能耗主要包括电梯以及生活水泵等设备电耗^[4]。国内的学者在影响国内建筑能耗的因素方面做了许多研究工作,例如杨晓敏^[1]、王海勇^[5]等都研究了建筑能耗的影响因素,其中杨晓敏在上海地区公共建筑能耗现状与节能分析中研究了上海地区三栋典型的公共建筑,对其能耗进行了夏季逐时实测,分析了其运营方式、建筑能耗及空调能耗的特点及关系,找出了影响各类建筑能耗的主要因素。杨晓敏根据三栋公共建筑不同的建筑特性对数据进行了典型日与全年能耗分析,对于办公建筑得出如下结论:工作日内,办公建筑的逐时能耗与员工的作息时间表直接相关;休息日内,由于人员较少,办公建筑逐时能耗受室外温度条件影响较大。对于办公建筑全年能耗,影响最大的因素为室外气温。由于当天的办公人员和温度波动较大且具有较大的不确定性,因此适合采取连续预测的

方法。

办公类建筑用电量由于受到各种因素的影响,具有时变性、复杂性、随机性、非线性等特点,所以其预测是一个难点。

2 BP 神经网络基本理论

BP 神经网络预测方法不需事先预知模型的映射关系,能以任意精度逼近任意连续的函数,适用于影响因素复杂、因素之间关系复杂的高度非线性系统及对预测速度要求不高的场合。

研究表明,当 BP 神经网络的隐含层神经元数目增加到足够多时,可以以任意精度逼近任何一个具有有限间断点的非线性函数。BP 神经网络是一种具有三层或三层以上的神经网络,包括输入层、隐含层和输出层;上下层之间实现全连接,每层神经元之间无连接^[6]。BP 算法的网络结构示意图如图 1 所示。




图 1 BP 算法的网络结构示意图

隐含层节点的输出:

$$y_h^k = f\left(\sum_{i=1}^{N_1} \omega_{ih} x_i^k + \theta_h\right) \quad (1)$$

输出节点的输出:

$$z_j^k = f\left(\sum_{h=1}^{N_2} \omega_{hj} y_h^k + \gamma_j\right) = f\left[\sum_{h=1}^{N_2} \omega_{hj} f\left(\sum_{i=1}^{N_1} \omega_{ih} x_i^k + \theta_h\right) + \gamma_j\right] \quad (2)$$

式中: θ ——隐含层节点的阈值;

γ_j ——输出节点 j 的阈值。

定义误差函数 $E(\mathbf{w})$:

$$E(\mathbf{w}) = \frac{1}{2} \sum_{i=1}^n \|Y_i - \hat{Y}_i\|^2 = \frac{1}{2} \sum_{i=1}^p e_i^2(\mathbf{w}) \quad (3)$$

式中: $E(w)$ —— 误差函数;

Y_i —— 学习样本的输出值;

Y_i' —— 网络训练后的实际输出值;

n —— 学习样本的个数;

w —— 网络权值和阈值所组成的向量。

对于 BP 网络的训练过程,可以分为三个阶段: ① 由训练样本构成的信息流向输入层,经过逐层的计算流向输出端的过程; ② 根据实际输出与理想输出之间的误差得到的调整信息流,由输出端逐层向输入端反馈的过程; ③ 根据调整后的网络进行训练样本的再训练过程。

3 建筑能耗 BP 神经网络预测模型建立

BP 神经网络预测最重要的是选择训练样本。训练样本的选择主要受两个因素的影响: 其一是训练样本的长度。样本长度并非越长越好,过长的训练样本不仅影响计算速度,还会导致拟合精度的下降。其二是训练样本的代表性。这一问题受原始资料的约束较大。有的研究对象本身就缺少数据,样本的代表性必然受到影响。

由于能耗系统的复杂性,电量消耗的影响因素又是方方面面的,所以应根据实际情况考虑影响因素。根据历史记录对网络进行训练,训练好的网络再通过另外的已知数据进行检验。

3.1 原始数据分析

本预测模型采用上海某公司建筑大楼 2011 年 12 个月每日的用电、气温组成了神经网络训练数据库。

在建立 BP 神经网络预测模型之前需要分析所研究的样本的数据规律,根据统计分析来确立模型的输入和输出。这样可以使得预测结果更加精确。所得到的数据有一年中每天的峰电、谷电、平电和平均气温。利用 Matlab 将所要研究的这几个变量用曲线的形式表示出来进行对比分析,以初步确定预测模型的输入和输出量以及样本的组织。各个变量和气温的周平均值如图 2、图 3 所示。

由图 2 可知,所有数据整体可看成连续的、具有一定规律的非线性函数,因此可以用 BP 神经网络进行预测;通过分析发现,在一周内数据变化




图 2 各变量的周平均值对比




图 3 气温的周平均值

趋势较平缓且没有跳跃现象,因此考虑以周为单位进行预测;峰电、谷电和平电的基本趋势相同,因此可以同时进行预测。通过图 2 各变量的变化与图 3 温度的变化对比易可知,电量的消耗与温度变化关系很大。又由上述分析结果可知,办公建筑大楼能耗适合连续性预测,可以把峰电、谷电、平电和温度这 4 个变量建立一个 BP 神经网络模型以周为单位进行连续性预测。

3.2 输入数据的预处理

由于输入的数据变化范围大,而神经网络要求输入和输出应限制在一定的范围内,这样做在提高网络训练速度的同时还可以减小奇异样本对神经网络性能的影响,故训练前要对网络进行标准化处理。采用 Matlab 中的 mapminmax 函数^[7]为网络的训练进行初始化预处理,使得所有值限制在 $[-1, 1]$ 。

$$\begin{aligned} [pn, ps] &= \text{mapminmax}(p) \\ [tn, ts] &= \text{mapminmax}(t) \end{aligned} \quad (4)$$

式中: p, t —— 标准前的输入和目标样本;

pn, tn —— 标准化后的输入和目标样本;

ps, ts —— 对 p 和 t 的信息解释。

$$pn = 2 \times (p - p_{\min}) / (p_{\max} - p_{\min}) - 1$$

式中: p_{\max}, p_{\min} —— 输入样本的最大值、最小值。

网络训练后得到的输出是变换后的输出,需

要用 mapminmax 函数进行逆变换。

$$a = \text{mapminmax}('reverse', a_n, ts) \quad (5)$$

式中: a_n ——训练好的网络仿真输出;

a ——逆变换后的仿真输出。

使用训练好的网络对新数据进行检验时也应
对新数据进行初始化预处理,这里采用函数
mapminmax。

$$p_{newn} = \text{mapminmax}('apply', p_{new}, ps) \quad (6)$$

式中: p_{new} ——新样本数据;

p_{newn} ——处理后的新数据。

3.3 改进的 BP 神经网络算法步骤

传统的 BP 算法采用的是最速梯度下降法修正权。该方法容易陷入局部最小且影响收敛速度,因此需要对传统的 BP 神经网络算法进行改进。

针对传统 BP 神经网络的算法的缺点,采用 Levenberg-Maquardt 优化算法^[8]来调整权值,减小网络误差。其基本思想是使其每次迭代不再沿着单一的负梯度方向,而是允许误差沿着恶化的方向进行搜索,同时通过在最速梯度下降法和高斯-牛顿法之间自适应调整来优化网络权值,使网络能够有效收敛,大大提高了网络的收敛速度和泛化能力。

设 w^k 表示第 k 次迭代的权值和阈值所组成的向量,新的权值和阈值所组成的向量 w^{k+1} 为

$$w^{k+1} = w^k + \Delta w$$

则其权值调整公式为

$$\Delta w = [J^T(w) J(w) + \mu I]^{-1} J^T(w) e(w) \quad (7)$$

$$J(w) = \begin{bmatrix} \frac{\partial e_1(w)}{\partial w_1} & \frac{\partial e_1(w)}{\partial w_2} & \dots & \frac{\partial e_1(w)}{\partial w_n} \\ \frac{\partial e_2(w)}{\partial w_1} & \frac{\partial e_2(w)}{\partial w_2} & \dots & \frac{\partial e_2(w)}{\partial w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N(w)}{\partial w_1} & \frac{\partial e_N(w)}{\partial w_2} & \dots & \frac{\partial e_N(w)}{\partial w_n} \end{bmatrix} \quad (8)$$

式中: e ——误差向量;

J ——误差对权值微分的雅可比矩阵;

I ——单位向量;

μ ——用户自定义的学习率。

μ 是一个标量,当 μ 增加时,它接近于具有较小的学习速率的最速梯度下降法,当 μ 下降到 0

时,该算法就变成了高斯-牛顿法了。

具体训练步骤为

(1) 计算出网络的输出和误差平方和;

(2) 用 Levenberg-Maquardt 优化算法求出 Δw ,用 $w + \Delta w$ 重复计算误差的平方和。如果新的和小于第一步中计算的和,则用 μ 除以 θ ($\theta > 1$),并有 $w = w + \Delta w$,再重新计算网络的输出和误差平方和;否则用 μ 乘以 θ 求 Δw ,再重复计算误差的平方和。当误差平方和减小到某一目标误差时,算法即被认为收敛。

3.4 网络结构

如前所述,将本模型的数据样本每 8 天组成一个组。数据共 357 个,以 8 天一个组,即前 7 天的平均气温、峰电、平电、谷电为输入,第 8 天的峰电、谷电、平电为输出建立非线性关系,其中取其前面 240 个样本数据作为训练数据,后面 117 个数据作为检验数据。基于此,训练样本输入为 $[28 \times 240]$ 的矩阵,输出为 $[3 \times 240]$ 的矩阵。检验样本输入为 $[28 \times 117]$ 输出为 $[3 \times 117]$ 。

现有的神经网络理论表明,三层前馈神经网络可以任意接近任何非线性模型,故选择三层神经网络进行建筑用电量的预测。三层神经网络结构输入层和隐含层之间的传递函数选用 tansig 函数^[9];输出层神经元传递函数选用 purelin 函数。在 Matlab 中利用 newff 函数产生神经网络,同时建立网络的结构和训练函数,Matlab 工具箱中带有 Levenberg-Maquardt 优化方法的训练函数 trainlm。

隐含层节点的选取是一个较为复杂的问题,隐含层节点太少,可能造成网络训练不足,不能识别以前没有学习过的样本,容错性能差;而节点太多,又使得学习时间过长,误差也不一定能保证最佳。如上所述已选择了网络的输入节点数为 28,输出节点数为 3,设输入节点数为 n ,则隐含层节点数可以根据 Hecht-Nielsen 理论设为 $2n + 1$,同时通过反复的试验并综合考虑收敛速度及精度,设隐含层节点数为 57。最后网络的拓扑结构为 $28 \times 57 \times 3$ 。

3.5 网络训练

利用 Matlab 自带的软件进行数据训练,当网络训练的误差为 10^{-5} 认为收敛。下面为网络训练过程及训练误差。训练过程如图 4 所示。

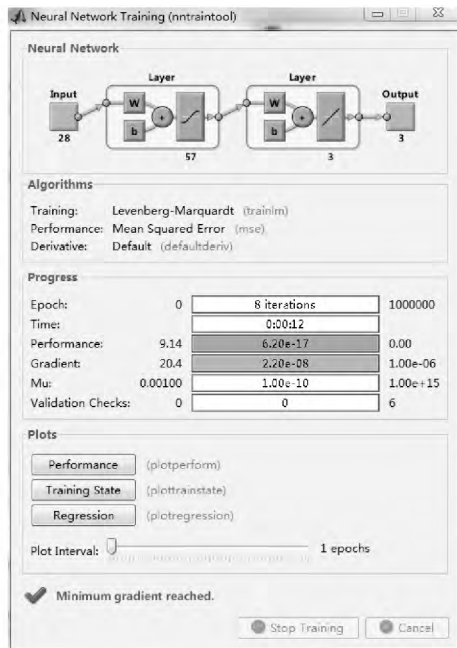


图4 训练过程

训练误差如图5所示。




图5 训练误差

从训练过程和训练误差可以看出训练收敛，且收敛结果较理想。

3.6 结果分析

预测误差如图6所示。




图6 预测误差

从图6可以看出,有95%的数据的误差在8%以内,误差在可接受的范围。如果极度减小误差会造成训练过度,局部最优。总之,预测结果是令人满意的,预测模型的建立也符合要求。可知神经网络预测模型适合建筑用电量的预测。

4 结 语

从以上试验结果可知,利用BP神经网络模型来建立建筑能耗预测模型是完全可行的。神经网络作为分析建筑物能耗的一个新的方法,具有强大的学习功能,只需通过输入建筑物的少量参数就可快速预测该建筑物的用电能耗。改进的神经网络算法克服了传统神经网络的不足,使得该算法更适用于建筑能耗的预测。该预测方法依然存在不足,需要进一步的改善,一方面,可以采取措进一步提高该预测模型的精度;另一方面,这里是短期预测,以天为单位,以后可以考虑长期预测,如以月为单位进行预测,相信可以更有实际意义。

【参考文献】

- [1] 杨晓敏. 上海地区公共建筑能耗现状与节能分析[D]. 上海: 同济大学, 2007.
- [2] 王钰, 郭其一, 李维刚. 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(1): 39-42.
- [3] 李然然, 张永坚, 刘畅, 等. 基于BP神经网络的建筑物用电能耗预测[J]. 山东建筑大学学报, 2011(2): 162-165.
- [4] 张硕鹏, 李锐. 办公类建筑能耗影响因素与节能潜力[J]. 北京建筑工程学院学报, 2013(1): 33-37.
- [5] 王海勇, 鞠泽清. 建筑能耗制约因素与节能设计分析[J]. 中国住宅设施, 2010(2): 20-21.
- [6] 何磊. 基于BP神经网络的建筑能耗预测[J]. 浙江建筑, 2008(12): 47-50.
- [7] 王小川. MATLAB神经网络43个案例分析[M]. 北京: 北京航空航天大学出版社, 2013.
- [8] LERA G, PINZOLAS M. Neighborhood based Levenberg-Marquardt algorithm for neural network training[J]. Neural Networks, IEEE Transactions on, 2002, 13(5): 1200-1203.
- [9] 飞思科技产品研发中心. 神经网络理论与MATLAB7实现[M]. 北京: 电子工业出版社, 2005, 259-264.

收稿日期: 2014-06-28