

引用格式:黄晓一,赵田,楚纪正. 基于 AP-BP 神经网络的建筑能耗分析与预测[J]. 北京化工大学学报(自然科学版), 2020, 47(4):101-107.

HUANG XiaoYi, ZHAO Tian, CHU JiZheng. Analysis and prediction of the energy consumption of buildings based on a back propagation-affinity propagation (AP-BP) neural network[J]. Journal of Beijing University of Chemical Technology (Natural Science), 2020, 47(4):101-107.

# 基于 AP-BP 神经网络的建筑能耗分析与预测

黄晓一<sup>1</sup> 赵 田<sup>2</sup> 楚纪正<sup>1\*</sup>

(1. 北京化工大学 信息科学与技术学院, 北京 100029; 2. 北京航天飞行控制中心, 北京 100094)

**摘 要:** 建筑行业对能源的节约是当前节约能耗的重要途径之一, 在对能源浪费现状和建筑物能源绩效调研和分析的基础上, 提出了一种基于 affinity propagation (AP) 聚类的 back propagation (BP) 神经网络建筑能耗分析与预测方法。通过 AP 聚类算法对影响建筑能耗的多维因素进行聚类分析, 得到影响建筑能耗的主要因素并作为 BP 神经网络的输入, 然后将建筑能耗指标热负荷和冷负荷作为 BP 神经网络的输出, 建立建筑能耗分析与预测模型。均方根误差 (RMSE) 和平均相对泛化误差 (ARGE) 评价指标分析结果表明, 本文所提方法对能耗值预测的拟合程度优于经典的 BP 神经网络, 且通过建筑能耗输入输出的结构调整能够节约能耗, 提高能效。

**关键词:** BP 神经网络; AP 聚类; 能耗分析; 能耗预测; 建筑行业

**中图分类号:** TP3 **DOI:** 10.13543/j.bhxbzr.2020.04.015

## 引 言

随着世界经济的飞速发展, 对能源的需求量也急速增长。然而传统能源的利用效率比较低, 新能源还不能作为主要能源使用, 且随着工业生产体系的日益完善和工业生产水平的日益提高, 其中的节能潜力也变得越来越低。随着城乡一体化建设中大面积住宅建筑规划的兴起, 住宅建筑能耗节约已成为国民经济发展的主要目标之一。目前, 很多国家的建筑能耗占总能源使用的比例已达到 40%, 其中欧盟国家建筑能耗的二氧化碳排放量达到了欧盟二氧化碳排放总量的 36%<sup>[1]</sup>。欧洲在实行 2020 年欧洲战略时, 在建筑能耗方面制定了一系列节能减排的目标<sup>[2]</sup>, 同时东欧也面临着大量多户型公寓建筑恶化从而需要翻新带来的一系列建筑节能的问题<sup>[3]</sup>。美国在 1996—2006 年间, 用电量以每年

1.7% 的速度上升, 预计到 2030 年总增长率甚至可以达到 26%<sup>[4]</sup>, 而其中建筑能源消耗占到了 70% 以上<sup>[5]</sup>。据统计, 在我国商业能源消耗总量中, 建筑能耗占 25.5% 且逐年增长<sup>[6]</sup>。在 2004 年, 我国提出了《建筑节能测试和标签技术指南》, 但是该指南很难全面地评估建筑能效<sup>[7]</sup>。

针对建筑能耗高、能效利用率低的问题, 学者们研究了一系列建筑节能降耗的方法。Wang 等<sup>[8]</sup>提出相变储能建筑围护结构, 可更好地利用可再生能源, 增加了室内温度的稳定性, 提高了居住者的舒适度, 同时又降低了建筑物的运行能耗。Guo 等<sup>[9]</sup>通过实验发现仅对外墙和窗户采用节能措施, 即可达到降低能耗 25% 的节能目标, 此外, 在保持室内舒适度的前提下墙体保温性能对建筑节能有较大的影响。近年来随着神经网络的发展和其自学习能力优势的显现, Rivard 等<sup>[10]</sup>将两种自适应人工神经网络 (ANN) 模型应用于建筑能耗预测, 通过累计训练和滑动窗口训练, 发现二者在合成数据中有几乎相同的性能, 但在实际测量的情况下滑动窗口技术有着更好的预测结果。意大利政府曾用人工神经网络算法对建筑的热需求指标进行预测和分析<sup>[11]</sup>, 香港政府也曾用人工神经网络算法对建筑的日常能源消耗进行预测<sup>[12]</sup>。一些研究人员用人工神经网络预测

收稿日期: 2020-02-22

基金项目: 国家自然科学基金(21676012); 中央高校基本科研业务费(XK1802-4)

第一作者: 男, 1983 年生, 博士

\* 通信联系人

E-mail: chujz@mail.buct.edu.cn

了建筑的冷负荷<sup>[13-14]</sup>、年总耗能<sup>[15]</sup>和相关建筑设施的能耗<sup>[16-17]</sup>。但传统的人工神经网络算法收敛速度较慢,而且会出现局部过拟合现象<sup>[18]</sup>。

本文提出了一种基于 affinity propagation (AP) 聚类的 back propagation (BP) 神经网络算法 (AP-BP) 用于预测和分析建筑能耗, 以为建筑管理者提供相应的节能建议。首先, 通过 AP 聚类算法对影响建筑能耗的多维因素进行聚类分析, 得到影响建筑能耗的主要因素, 并作为 BP 神经网络的输入; 然后, 将建筑能耗指标热负荷和冷负荷作为 BP 神经网络的输出, 建立建筑能耗分析与预测模型。通过均方根误差 (RMSE) 和平均相对泛化误差 (ARGE) 来衡量预测模型的训练和预测精确度, 实验结果表明本文所提方法对能耗值的预测优于经典的 BP 神经网络, 且通过建筑能耗输入输出的合理调整分配可实现节约能耗和能效的提高。

## 1 算法模型及构建

AP 聚类不需要提前指定聚类个数, 且能准确地找到主要影响特征, 进而减少 BP 神经网络的输入, 提高训练和泛化的精确度。

### 1.1 AP 聚类算法

AP 聚类算法属于无监督聚类算法<sup>[19-20]</sup>, 不需要提前指定聚类质心的个数, 能够直接得到合适的聚类质心个数及位置。假设  $\mathbf{x}$  为输入矩阵, 其大小为  $n \times m$ 。首先对  $n$  个输入矩阵  $\mathbf{x}$  进行聚类, 得到输出矩阵为  $\mathbf{Z}$ , 大小为  $k \times m$ , 则  $k$  就是得到的聚类质心个数。AP 聚类算法的具体步骤如下。

(1) 数据归一化处理 将输入数据归一化到一个较小范围可以减小异常值的影响, 有更好的迭代效果。常用的归一化公式为

$$\mathbf{y} = (y_{\max} - y_{\min}) \frac{\mathbf{x} - x_{\min}}{x_{\max} - x_{\min}} + y_{\min} \quad (1)$$

式中,  $\mathbf{y}$  为归一化后的矩阵,  $y_{\max}$  与  $y_{\min}$  则是规定好的归一化后的最大值和最小值。当  $x_{\max}$  与  $x_{\min}$  相等时, 采用公式

$$\mathbf{y} = y_{\min} \quad (2)$$

为了使 AP 聚类算法有更好的聚类效果, 选用  $y_{\max}$  为 0.9,  $y_{\min}$  为 0.1。

(2) 构建相似度矩阵  $\mathbf{s}$   $\mathbf{s}$  矩阵初始化为  $n \times n$  的零矩阵。在相似度矩阵中两个数据点的相似度通常用欧氏距离的负值表示。 $s(i, j)$  ( $i = 1, \dots, n; j = 1, \dots, n$ ) 的值越小, 则可以理解为点  $i$  与  $j$  的距离越

远; 两个数据点的相似度值可以理解为数据点  $j$  作为数据点  $i$  的聚类中心的能力。具体公式为

$$s(i, j) = s(j, i) = - \sqrt{\sum_{k=1}^m (y(i, k) - y(j, k))^2} \quad (3)$$

(3) 设置参考度 参考度指的是相似度矩阵  $\mathbf{s}$  中对角线上的值, 即  $s(i, i)$ 。相似度表示数据点  $i$  可以成为聚类质心的适合度, 因此其值不取 0。在迭代开始前默认所有数据点都有相同的潜在可能性成为聚类质心。设相似度矩阵中所有节点的相似度为其中位数值, 则相似度矩阵中的参考度越大, 起始数据点成为最终迭代出的质心的适合程度越高, 进而导致最终质心的个数越多。本文中  $s(i, i)$  为所有值的中位数。

(4) 设置阻尼系数 由于 AP 聚类算法在吸引信息矩阵和归属信息矩阵迭代过程中会引起数据震荡, 所以设定阻尼系数 ( $\lambda$ )。在迭代过程中吸引度矩阵中的值和归属度矩阵中的值为上一次迭代求得的吸引信息值或归属信息值的  $\lambda$  倍与此次迭代得到值的  $1 - \lambda$  倍之和, 则  $\lambda$  的取值范围为  $0 \sim 1$ , 本文中  $\lambda$  值记为  $L$ ,  $L$  的值为 0.4。

(5) 吸引信息矩阵 (Responsibility)  $\mathbf{r}$  和归属信息矩阵 (Availability)  $\mathbf{a}$   $r(i, j)$  为两个数据点的吸引信息, 即  $j$  成为  $i$  的聚类质心的适合度;  $a(i, j)$  则为两个点之间的归属信息, 即  $i$  有意向选  $j$  作为  $i$  的质心的认可程度。使用式 (4) 可得出吸引信息矩阵

$$r(i, j) = s(i, j) - \max \{a(i, j') + s(i, j')\} \quad (4)$$

式中,  $j'$  表示除当前  $j$  以外的其他点 ( $j' = 1, \dots, j-1, j+1, \dots, n$ );  $a(i, j') + s(i, j')$  得到数据点  $j'$  作为数据点  $i$  的质心的适合度。此时, 在其他节点  $j'$  中, 找出最大的  $a(i, j') + s(i, j')$ , 即  $\max \{a(i, j') + s(i, j')\}$ , 再用  $s(i, j) - \max \{a(i, j') + s(i, j')\}$  得到  $j$  对  $i$  的吸引度。然后用阻尼系数将前一次计算得到的值与此次计算得到的值进行加权求和, 最后得到此次迭代中的矩阵  $\mathbf{r}$

$$\mathbf{r} = (1 - L)\mathbf{r} + L\mathbf{r}_{\text{old}} \quad (5)$$

式中,  $\mathbf{r}_{\text{old}}$  为前一次迭代得到的矩阵  $\mathbf{r}$ , 初始化为零矩阵。

(6) 归属度  $a(i, j)$  由式 (6) 得到

$$a(i, j) = \min \left\{ 0, r(j, j) + \sum \max \{0, r(i', j)\} \right\} \quad (6)$$

$$a(j, j) = \sum \max \{0, r(i', j)\} \quad (7)$$

$$\mathbf{a} = (1 - L)\mathbf{a} + L\mathbf{a}_{\text{old}} \quad (8)$$

若数据点  $j$  成为其余数据点  $i'$  ( $i' = 1, \dots, j-1, j+1, \dots, n$ ) 的质心具有较高的适合度, 则数据点  $j$  成为数据点  $i$  的质心的适合度也将提高, 所以应该首先计算数据点  $j$  对其他数据点  $i'$  的吸引度  $r(i', j)$ , 接着累加求和得到数据点  $j$  对其他数据点  $i'$  的吸引度

$$\sum \max \{0, r(i', j)\} \quad (9)$$

在  $r(i', j)$  和 0 中取较大的值是因为相似度矩阵  $\mathbf{s}$  会初始化成负值, 所以通过计算得出的  $r(i', k)$  有一定概率是小于 0 的, 这样处理更容易在完成全部计算过程后得到位置较好的聚类质心。

吸引度  $r(j, j)$  表示数据点  $j$  有多大概率不被归属到其他聚类质心下, 其中将  $k$  作为其余数据点的聚类质心的适合程度为  $\sum \max \{0, r(i', j)\}$ 。不适合被归属到除自身以外的质心下的值表示为  $r(j, j)$ 。两者相加最终的取值范围小于等于零, 因为这样可以减小数值太大对最终结果产生的误差。最后直至迭代结束。

(7) 筛选出适合成为聚类质心的点 将吸引度信息矩阵  $\mathbf{r}$  与归属度信息矩阵  $\mathbf{a}$  相加, 取对角线的值大于 0 的点为聚类质心, 得到最终结果。

根据上述算法过程的描述得到的 AP 聚类算法有以下特点: ①在算法执行前可不指定聚类质心个数, 由算法自动计算得到; ②得到的簇中心一定可以在输入的原始数据集中找到, 并不会生成新的数据点; ③AP 聚类算法对初始值不敏感, 因为开始时默认所有数据点都有同样的概率成为聚类质心, 所以运行多次得出的结果一致。

## 1.2 基于 AP 聚类的 BP 神经网络算法 (AP-BP)

由于三层神经网络可以实现任意非线性映射<sup>[21]</sup>, 四层网络的结果比三层网络更易陷入局部极小点, 且过多的网络节点会使网络的泛化能力减弱, 网络预测能力下降, 所以一个隐层的神经网络只需足够多的节点, 就可以以任意精度逼近一个非线性函数<sup>[22]</sup>。因此本文采用三层前向神经网络, 其典型的 BP 神经网络结构如图 1 所示, 它包含 1 个输入层、1 个输出层和 1 个隐含层。输入信号从输入层节点依次传过各隐含层节点, 然后传到输出节点, 每一层节点的输出只影响下一层节点的输出。

在图 1 中, 输入向量  $\mathbf{X} = (x_1, x_2, \dots, x_i, \dots, x_n)^T$ , 输




图 1 BP 神经网络模型图

Fig. 1 BP neural network model diagram

入层到隐层之间的权值矩阵  $\mathbf{V} = (v_1, v_2, \dots, v_j, \dots, v_m)^T$ , 隐含层到输出层之间的权值矩阵  $\mathbf{W} = (w_1, w_2, \dots, w_k, \dots, w_l)^T$ 。

隐含层隶属度函数  $f(x)$  为 sigmoid 函数

$$f(x) = \frac{1}{1 + e^{-x}} \quad (10)$$

这种函数输入参数可以是正负区间的任意值, 在 BP 网络中, 其输出值限定在 0 ~ 1 之间。

隐含层输出向量  $\mathbf{Y} = (y_1, y_2, \dots, y_j, \dots, y_m)^T$ , 其中

$$y_j = f(\text{net}_j), j = 1, 2, \dots, m \quad (11)$$

$$\text{net}_j = \sum_{i=0}^n v_{ij}x_i, j = 1, 2, \dots, m \quad (12)$$

输出层输出向量  $\mathbf{O} = (o_1, o_2, \dots, o_k, \dots, o_l)^T$ , 其中

$$o_k = f(\text{net}_k), k = 1, 2, \dots, l \quad (13)$$

$$\text{net}_k = \sum_{j=0}^m w_{jk}y_j, k = 1, 2, \dots, l \quad (14)$$

期望输出向量  $\mathbf{d} = (d_1, d_2, \dots, d_k, \dots, d_l)^T$ ; 设定期望误差为  $\xi$ , 训练次数为  $T$ 。

由于 BP 神经网络容易陷入局部最优, 所以这里采用一种应用较为广泛的改进的 BP 学习算法, 通过引入动量因子来减小学习过程的振荡趋势, 改善收敛性, 进而使 BP 算法找到更优的解。同时动量因子降低了网络对于误差曲面局部细节的敏感性, 有效地抑制了网络陷入局部极小。

通常在 BP 网络中隐含层  $m$  的初始值可先由式 (15) 确定<sup>[23]</sup>

$$m = \sqrt{0.43nl + 0.12l^2 + 2.54n + 0.77l + 0.35} + 0.51 \quad (15)$$

然后利用逐步增长法进行隐含层的选取, 进而缩短训练时间。

改进的 BP 算法实现步骤如下:

1) 通过式 (16) 计算期望输出和网络输出的误

差值

$$E = \frac{1}{2}(\mathbf{d} - \mathbf{O})^2 = \frac{1}{2} \sum_{k=1}^l (d_k - o_k)^2 \quad (16)$$

2) 将误差值展开到隐含层得到式(17)

$$E = \frac{1}{2} \sum_{k=1}^l [d_k - f(\text{net}_k)]^2 = \frac{1}{2} \sum_{k=1}^l \left[ d_k - f\left(\sum_{j=0}^m w_{jk} y_j\right) \right]^2 \quad (17)$$

3) 将  $y_j$  值展开到输入层得到式(18)

$$E = \frac{1}{2} \sum_{k=1}^l \left[ d_k - f\left(\sum_{j=0}^m w_{jk} y_j\right) \right]^2 = \frac{1}{2} \sum_{k=1}^l \left\{ d_k - f\left[\sum_{j=0}^m w_{jk} f\left(\sum_{i=0}^n v_{ij} x_i\right)\right] \right\}^2 \quad (18)$$

4) 调整权值,使误差不断减小

$$\Delta w_{jk} = -\eta \frac{\partial E}{\partial w_{jk}}, j=0,1,2,\dots,m; k=1,2,\dots,l \quad (19)$$

$$\Delta v_{ij} = -\eta \frac{\partial E}{\partial v_{ij}}, i=0,1,2,\dots,n; j=1,2,\dots,m \quad (20)$$

式中,  $\eta$  为学习速率,即步长,取值在  $0 \sim 1$ 。

$$\Delta w_{jk} = -\eta \left[ (1-\alpha) \frac{\partial E}{\partial w_{jk}} + \alpha \frac{\partial E}{\partial w_{j(k-1)}} \right], j=0,1,2,\dots,m; k=1,2,\dots,l \quad (21)$$

$$\Delta v_{ij} = -\eta \left[ (1-\alpha) \frac{\partial E}{\partial v_{ij}} + \alpha \frac{\partial E}{\partial v_{i(j-1)}} \right], i=0,1,2,\dots,n; j=1,2,\dots,m \quad (22)$$

式中,  $\alpha$  为动量因子,一般取  $0 \leq \alpha < 1$  [5]。

$$\mathbf{W}(t+1) = \mathbf{W}(t) + \Delta \mathbf{W} \quad (23)$$

$$\mathbf{V}(t+1) = \mathbf{V}(t) + \Delta \mathbf{V} \quad (24)$$

5) 如果  $E < \xi$  或训练次数  $t = T$  或权值达到要求则停止,否则转入步骤 2)。

基于 AP 聚类的 BP 神经网络算法流程图如图 2 所示。对训练数据的网络输出矩阵  $\mathbf{O}$  进行反归一化处理,得到最终的网络输出矩阵  $\mathbf{P}$ ,并且计算与期望输出矩阵  $\mathbf{Q}$  的误差。用式(25)和式(26)分别计算训练数据的均方根误差  $E_{\text{RMS}}$  和平均相对泛化误差  $E_{\text{ARG}}$ 。

$$E_{\text{RMS}} = \sqrt{\frac{\sum_{i=1}^N (P(i) - Q(i))^2}{N}} \quad (25)$$

$$E_{\text{ARG}} = \frac{\sum_{i=1}^N \left| \frac{P(i) - Q(i)}{Q(i)} \right|}{N} \times 100 \quad (26)$$

式中,  $N$  为训练数据总输出个数。式(26)中若期望输出为 0,由于分母为 0 无意义,则只计算求和公式中的分子,忽略分母即可。可根据 RMSE 和 ARGE 对算法模型的拟合程度作出判断。

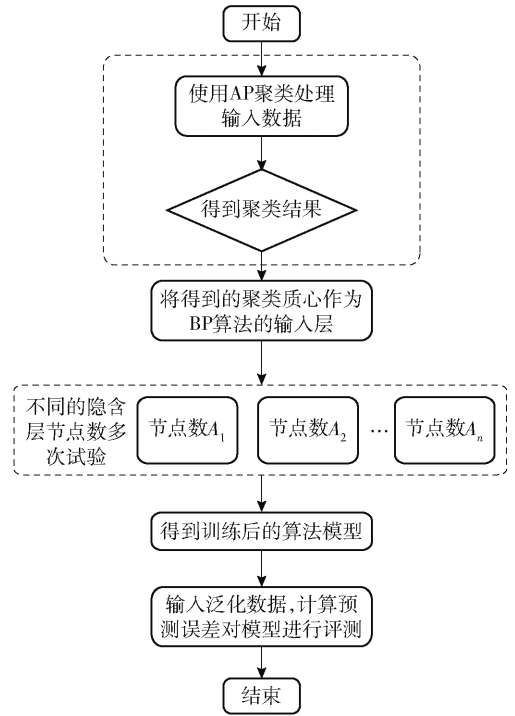


图 2 AP-BP 算法流程

Fig. 2 AP-BP algorithm flow

最后计算泛化数据的预测结果输出及其误差,即用泛化数据重复上一步计算训练误差,得出泛化数据的预测结果及误差。

## 2 实例分析

### 2.1 数据来源

本文使用的模拟建筑物数据是由 Ecotect 生成的输入不同的建筑物及室内外信息 [24], 主要特征包括墙壁的组成材料、地板的材料及厚度、屋顶材料、窗户材料以及模拟有 7 人居住。尽管模拟结果无法保证能够完全反映真实世界的实际数据,但可以较好地展示实际数据的占比变化和潜在趋势,从而实现建筑物的能效分析。该数据集一共包括 315 条样本数据,其中每条数据有 8 个输入变量和 2 个输出变量。数据集中的 8 个输入变量包括相对紧密度、表面积、墙面积、屋顶面积、总高度、房屋朝向、玻璃窗面积及玻璃窗面积分布。两个输出变量为住宅建筑的热负荷 (HL,  $\text{kW} \cdot \text{h}/(\text{m}^3 \cdot \text{a})$ ) 和住宅建筑的冷负荷 (CL,  $\text{kW} \cdot \text{h}/(\text{m}^3 \cdot \text{a})$ ) [25]。具体的输入数据和



输出数据的说明见表 1。

表 1 输入及输出数据说明

Table 1 Data description of input and output		
数学表示	输入或输出变量	可能值
$X_1$	相对紧密度	12
$X_2$	表面积	12
$X_3$	墙面积	7
$X_4$	屋顶面积	4
$X_5$	总高度	2
$X_6$	房屋朝向	4
$X_7$	玻璃窗面积	4
$X_8$	玻璃窗面积分布	6
$Y_1$	热负荷	586
$Y_2$	冷负荷	636

2.2 仿真结果

基于数据模型进行研究和对比分析,本文采用 RMSE 和 ARGE 来计算算法模型的输出结果与期望输出结果之间的拟合效果,其中包括 244 条训练数据,71 条泛化数据,并且将本文提出的基于 AP 聚类的 BP 神经网络算法模型与经典的 BP 神经网络算法模型进行比较。

首先通过 AP 聚类算法对建筑主要输入进行聚类得到聚类结果如表 2 所示。

表 2 AP 聚类结果

Table 2 Results of AP clustering	
聚类中心	聚类中心包含的点
$x_1$	$X_1、X_5、X_7$
$x_2$	$X_2、X_3、X_4、X_6$
$x_8$	$X_8$

由表 2 可知,8 个变量在经过 AP 聚类算法处理后得到了 3 个聚类中心分别为  $x_1、x_2、x_8$ 。这 3 个聚类中心将作为 BP 算法的输入变量,并且与不将 8 个变量进行 AP 聚类算法处理的 BP 方法进行比较。分别计算隐含层节点数为 6、8、10、12、14 时最终的期望值和预测值的误差,并找出最佳隐含层节点数。表 3 为训练数据和泛化数据的预测输出和期望输出的最终误差值。

在没有出现训练误差和泛化误差相差过多的过拟合的情况下,泛化误差是评价算法模型优劣的更重要的标准。由表 3 可知基于 AP 聚类的 BP 神经网络算法模型的误差值总体上要小于经典的 BP 神经网络算法模型。当隐含层节点数为 10 时,两个算法模型的误差均达到最小,而随着隐含层节点数增多,误差反而变大,说明出现过拟合现象,所以最终选择隐含层节点数 10。图 3 是当隐含层节点数为

10 时的误差对比图。

表 3 不同隐含层节点数时 AP-BP 和经典 BP 的最终误差值

Table 3 Final error values of AP-BP and classical BP for different numbers of hidden layer nodes					
算法	隐含层节点数	最终误差值			
		训练 RMSE	训练 ARGE	泛化 RMSE	泛化 ARGE
AP-BP	6	1.54	4.88	1.69	5.39
	8	1.53	4.47	1.71	4.97
	10	1.50	4.37	1.60	4.68
	12	1.54	5.21	1.59	5.23
	14	1.53	5.15	1.71	5.31
BP	6	1.53	5.05	1.87	5.91
	8	1.53	4.95	1.88	6.41
	10	1.52	4.87	1.83	6.00
	12	1.52	4.79	1.97	6.30
	14	1.53	4.62	1.97	6.27




图 3 隐含层节点数为 10 时 AP-BP 和 BP 的输出误差值  
Fig. 3 Output error values of AP-BP and BP with 10 hidden layer nodes

由图 3 可看出,本文提出的基于 AP 聚类的 BP 神经网络算法模型的训练数据和泛化数据的 RMSE 和 ARGE 均要小于经典 BP 神经网络算法模型。进而基于 AP-BP 算法得到建筑能耗泛化数据的热负荷和冷负荷的预测输出和期望输出,如图 4 和图 5 所示。

从图 4 和图 5 可以看出,泛化数据的期望输出和预测输出拟合度均较高。该建筑第 35 个样本  $X_1 \sim X_8$  的值分别 0.76、661.6、416.5、122.5、7、4、0.12;而热负荷和冷负荷分别为 33.12 kW·h/(m³·a) 和 34.17 kW·h/(m³·a),基于 AP 的 BP 神经网络预测值为 36.02 kW·h/(m³·a) 和 35.47 kW·h/(m³·a),说明该时刻建筑未达到要求的热/冷需求,即该建筑为低负荷生产,能效较低。在以后生产中应该调整




图4 AP-BP 算法泛化数据的热负荷期望输出与预测输出

Fig. 4 Expected output (heating load) and algorithm predictive output (heating load) of AP-BP generalized data




图5 AP-BP 算法泛化数据的冷负荷期望输出与预测输出

Fig. 5 Expected output (cooling load) and algorithm predictive output (cooling load) of AP-BP generalized data

投入产出,提高能效。又如第4个样本中 $X_1 \sim X_8$ 的值分别0.98、514.5、294、110.25、7、3、0.25、4;而热负荷和冷负荷分别为 $28.55 \text{ kW} \cdot \text{h}/(\text{m}^3 \cdot \text{a})$ 和 $29.59 \text{ kW} \cdot \text{h}/(\text{m}^3 \cdot \text{a})$ ,基于AP的BP神经网络预测值为 $28.85 \text{ kW} \cdot \text{h}/(\text{m}^3 \cdot \text{a})$ 和 $30.5 \text{ kW} \cdot \text{h}/(\text{m}^3 \cdot \text{a})$ ,表明本月该建筑满负荷运行,在后续生产中该建筑可维持该生产状况。通过对建筑多输入和多输出预测建模,能够得到不同投入下不同的能耗情况,进而指导投入配置,提高能效。

### 3 结论

本文提出了一种基于AP聚类的BP神经网络算法(AP-BP)用于建筑能耗的分析与预测建模,并通过ARGE和RMSE对算法模型的预测能力进行评价分析。案例结果表明,基于AP聚类的BP神经网络算法对热负荷和冷负荷的预测能力明显强于经典的BP神经网络算法模型,同时能够准确地对建筑的热负荷和冷负荷进行预测,进而为建筑管理者提供建议,合理配置影响热负荷和冷负荷的投入因素,

实现建筑能耗的节约,从而提高能效。下一步将继续对BP算法的改进进行研究,同时考虑极限学习机(ELM)等方法的改进并应用在建筑节能降耗领域。

### 参考文献:

- [1] MOGA L, MOGA I. Building design influence on the energy performance [J]. Journal of Applied Engineering Sciences, 2015, 5(1): 37-46.
- [2] SKIBA M, RZESZOWSKA N. Analysis of the dependence between energy demand indicators in buildings based on variants for improving energy efficiency in a school building [J]. Civil and Environmental Engineering Reports, 2017, 26(3): 31-41.
- [3] MIEZIS M, ZVAIGZNITIS K, STANCIOFF N, et al. Climate change and buildings energy efficiency-the key role of residents [J]. Environmental and Climate Technologies, 2016, 17(1): 30-43.
- [4] PARKS N. Energy efficiency and the smart grid [J]. Environmental Science & Technology, 2009, 43(9): 2999-3000.
- [5] FRIEDMAN H. Wiring the smart grid for energy savings: integrating buildings to maximize investment [M]. Oregon: Portland Energy Conservation Inc. (PECI), 2009.
- [6] 清华大学建筑节能研究中心. 中国建筑节能年度发展报告(2008) [R]. 北京: 中国建筑工业出版社, 2008. Building Energy Research Center of Tsinghua University. 2008 annual report on China building energy efficiency [R]. Beijing: China Architecture Press, 2008. (in Chinese)
- [7] CHEN Z, CLEMENTS-CROOME D, HONG J, et al. A multicriteria lifespan energy efficiency approach to intelligent building assessment [J]. Energy and Buildings, 2006, 38: 393-409.
- [8] WANG X, ZHANG Y P, XIAO W, et al. Review on thermal performance of phase change energy storage building envelope [J]. Chinese Science Bulletin, 2009, 54(6): 920-928.
- [9] WANG H H, GUO R, XIAO Q L. Energy saving effect of building envelope in summer [J]. Journal of Central South University, 2012, 19(5): 1370-1376.
- [10] YANG J, RIVARD H, ZMEUREANU R. On-line building energy prediction using adaptive artificial neural networks [J]. Energy and Buildings, 2005, 37(12): 1250-1259.
- [11] KHAYATIAN F, SARTO L, DALL'O' G. Application of neural networks for evaluating energy performance certificates of residential buildings [J]. Energy and Buildings, 2016, 125: 45-54.
- [12] WONG S L, WAN K K W, LAM T N T. Artificial neural networks for energy analysis of office buildings with daylighting [J]. Applied Energy, 2010, 87(2): 551-557.

- [13] HOU Z J, LIAN Z W, YAO Y, et al. Cooling-load prediction by the combination of rough set theory and an artificial neural-network based on data-fusion technique [J]. *Applied Energy*, 2006, 83(9): 1033 – 1046.
- [14] LI Q, MENG Q L, CAI J J, et al. Predicting hourly cooling load in the building: a comparison of support vector machine and different artificial neural networks [J]. *Energy Conversion and Management*, 2009, 50(1): 90 – 96.
- [15] AYDINALP-KOKSAL M, UGURSAL V I. Comparison of neural network, conditional demand analysis, and engineering approaches for modeling end-use energy consumption in the residential sector [J]. *Applied Energy*, 2008, 85(4): 271 – 296.
- [16] KALOGIROU S A. Applications of artificial neural-networks for energy systems [J]. *Applied Energy*, 2000, 67(1): 17 – 35.
- [17] BEN-NAKHI A E, MAHMOUD M A. Energy conservation in buildings through efficient A/C control using neural networks [J]. *Applied Energy*, 2002, 73(1): 5 – 23.
- [18] ZHONG B C, LU K, LV D H, et al. Short-term prediction of building energy consumption based on GALM neural network [C] // International Conference on Advances in Mechanical Engineering and Industrial Informatics. Zhengzhou, 2015.
- [19] FREY B J, DUECK D. Clustering by passing messages between data points [J]. *Science*, 2007, 315(5814): 972 – 976.
- [20] MÉZARD M. Where are the exemplars? [J]. *Science*, 2007, 315(5814): 949 – 951.
- [21] LIPPMANN R P. An introduction to computing with neural nets [J]. *IEEE ASSP Magazine*, 1987, 4(2): 4 – 22.
- [22] HECHT-NIELSEN R. Theory of the backpropagation neural network [C] // International Joint Conference on Neural Networks. Washington, D. C., 1989: 593 – 605.
- [23] 高大启. 有教师的线性基本函数前向三层神经网络结构研究 [J]. *计算机学报*, 1998, 21(1): 80 – 86.  
GAO D Q. Research on the structure of a forward three-layer neural network with linear basic functions for teachers [J]. *Chinese Journal of Computers*, 1998, 21(1): 80 – 86. (in Chinese)
- [24] TSANAS A, XIFARA A. Accurate quantitative estimation of energy performance of residential buildings using statistical machine learning tools [J]. *Energy and Buildings*, 2012, 49: 560 – 567.
- [25] PESSENLEHNER W, MAHDAVI A. Building morphology, transparency, and energy performance [C] // Proceedings of Eighth International IBPSA Conference. Eindhoven, 2003: 1025 – 1032.

## Analysis and prediction of the energy consumption of buildings based on a back propagation-affinity propagation (AP-BP) neural network

HUANG XiaoYi<sup>1</sup> ZHAO Tian<sup>2</sup> CHU JiZheng<sup>1\*</sup>

(1. College of Information Science and Technology, Beijing University of Chemical Technology, Beijing 100029;

2. Beijing Aerospace Command Center, Beijing 100094, China)

**Abstract:** Energy saving is one of the most important ways to reduce the energy consumption of buildings. Based on an analysis and investigation of energy waste and the energy efficiency of buildings, a back propagation (BP) neural network based on the affinity propagation (AP) clustering algorithm (AP-BP) for analysis and prediction of the energy consumption of buildings is proposed. By means of the AP clustering algorithm, the key factors affecting the energy consumption of buildings can be obtained, and these are used as inputs of the BP neural network. The thermal load and the cold load of buildings are used as outputs of the BP neural network. Finally, a model for analyzing and predicting the energy consumption of the building is obtained. By evaluating the root mean square error (RMSE) and the mean relative generalization error (ARGE), the experimental results show that the proposed method is better than the classical BP neural network in terms of the degree of fitting of the energy consumption prediction. Using the AP-BP can save energy and improve energy efficiency by adjusting the inputs and outputs of buildings.

**Key words:** BP neural network; affinity propagation (AP) clustering; energy consumption analysis; energy consumption prediction; building