

1-4-2019

Improved BP Neural Network of Heat Load Forecasting Based on Temperature and Date Type

Li Qi

College of Information Engineering, University of Science and Technology of Inner Mongol, Baotou 014000, China;

Zhao Feng

College of Information Engineering, University of Science and Technology of Inner Mongol, Baotou 014000, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research, Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Improved BP Neural Network of Heat Load Forecasting Based on Temperature and Date Type

Abstract

Abstract: The heat load forecasting provides data support for urban district heating systems, which is the basis of need-based heating. The change of heat load is greatly influenced by various exterior factors, especially the outdoor temperature. *To meet demand of heating system, save energy and balance the comfort of human body, a kind of improved BP neural network method is proposed by temperature and date type. The temperature and date type are quantified and the heat load forecasting model is established by using BP neural network.* To guarantee prediction accuracy, the genetic algorithm is used to optimize the weights and thresholds of the neural network, and from which the predicted value of the heat load in the next 24 hours is obtained. The predicted results from the model show that the proposed method can accurately predict the future heat load;and the goals of on-demand heating, energy conservation and environmental protection are achieved.

Keywords

heat load forecasting, genetic algorithm, temperature, date type

Recommended Citation

Li Qi, Zhao Feng. Improved BP Neural Network of Heat Load Forecasting Based on Temperature and Date Type[J]. Journal of System Simulation, 2018, 30(4): 1464-1472.

基于气温与日期类型的改进BP网络热负荷预测

李琦, 赵峰

(内蒙古科技大学 信息工程学院, 内蒙古 包头 014000)

摘要: 热负荷预测为城市集中供热系统提供数据支持, 是实现按需供热的基础。热负荷的变化受外界各项因素特别是室外温度影响较大, 为在满足供热系统需求量的同时做到节能与兼顾人体舒适度, 提出基于气温与日期类型的热负荷预测方法。该方法将气温与日期类型进行量化并利用BP神经网络建立供热系统的热负荷预测模型。为保证预测精度采用遗传算法对神经网络连接权值和阈值进行优化, 得到未来24小时的热负荷预测值。预测结果表明, 此方法可以较准确地预测未来的热负荷, 并达到按需供热和节能环保的目的。

关键词: 热负荷预测; 气温; 遗传算法; 日期类型

中图分类号: TP301.6 文献标识码: A 文章编号: 1004-731X(2018)04-1464-09

DOI: 10.16182/j.issn1004731x.joss.201804031

Improved BP Neural Network of Heat Load Forecasting Based on Temperature and Date Type

Li Qi, Zhao Feng

(College of Information Engineering, University of Science and Technology of Inner Mongol, Baotou 014000, China)

Abstract: The heat load forecasting provides data support for urban district heating systems, which is the basis of need-based heating. The change of heat load is greatly influenced by various exterior factors, especially the outdoor temperature. To meet demand of heating system, save energy and balance the comfort of human body, a kind of improved BP neural network method is proposed by temperature and date type. The temperature and date type are quantified and the heat load forecasting model is established by using BP neural network. To guarantee prediction accuracy, the genetic algorithm is used to optimize the weights and thresholds of the neural network, and from which the predicted value of the heat load in the next 24 hours is obtained. The predicted results from the model show that the proposed method can accurately predict the future heat load; and the goals of on-demand heating, energy conservation and environmental protection are achieved.

Keywords: heat load forecasting; genetic algorithm; temperature; date type

引言

在热源热能的生产和热力站的热量分配中, 热

负荷都起到决定性的作用。合理精确的热负荷值可以实现热源产热量的准确预估并达到节能环保的目的, 同时也为热力站处热量的分配提供依据。热负荷值的大小既关系到热用户的热需求也与当前所提倡的节能要求息息相关。由于我国当前集中供热的控制发展不够完善, 经常出现气温高的时候用户端过热, 低温天气热量不足的情况。所以合理地



收稿日期: 2016-04-21 修回日期: 2016-06-23;
基金项目: 国家自然科学基金(61463040);
作者简介: 李琦(1973-), 男, 陕西米脂, 硕士, 教授, 研究方向为智能优化控制和工业远程控制; 赵峰(1988-), 男, 山东新泰, 硕士生, 研究方向为控制算法。

<http://www.china-simulation.com>

• 1464 •

热量生产是解决该类问题的基础。针对集中供热系统的短期热负荷预测学者们提出过多种不同的方法。文献[1]采用 BP 神经网络实现热负荷的短期预测; 文献[2]给出一种小波神经网络的热负荷预测方法; 文献[3]利用 Elman 型神经网络对热负荷进行预测。但是由于单一的神经网络预测精度不高, 同时天气特别是温度对热负荷的大小有着较大影响, 根据文献[4]可知室外温度对热负荷的影响占到 60%左右, 所以在进行热负荷预测时需要考虑温度因素。由于本实验中热用户均为城市居民, 因此在不同的时间相同供热面积下热用户的人数也是不同的, 所以根据节能和用户舒适度考虑需要将日期类型作为考虑因素之一。

1 BP 神经网络预测模型

为保证所得到的预测热负荷既可以满足供热需求同时又能兼顾节能和人体舒适度的要求, 需要对 BP 神经网络的输入变量、隐含层数、输出变量、连接方式进行合理选择。

1.1 确定输入输出变量

由于温度对热负荷的影响最为明显, 所以需要将 24 小时的室外温度作为输入之一。在不同的温度条件下热量需求也会不同, 所以需要将 24 小时的温度与相对应的热负荷一一对应作为 BP 神经网络训练样本的输入数据。根据热量的计算公式 1 可得到相应时刻的热负荷值。

$$Q = c \cdot m \cdot (T_g - T_h) \quad (1)$$

式中: m 为循环水的流量质量, 单位为 t/h, 计算时换算为 kg/h; c 为水的比热容, 一般可取 4.187 kJ/kg·°C; T_g 、 T_h 为热力站一次侧的供回水温度, 单位为°C。由于所需的是未来 24 h 的热负荷, 所以应得到未来 24 h 的温度信息。相应温度信息由气象局所提供, 保证信息的准确性。

本文中所用到的热量数据来源于包头某热力公司下的某小区热力站, 供热面积约为 7.8 万平方米。考虑到主要的热用户为普通家庭用户, 所以在

不同的时间对热负荷的要求也不同。例如工作日家中的人数较少, 所以对热负荷的要求也相对较少。周末家中的人数较多, 因此对热负荷的需求也就更多。而节假日居家的人数会介于工作日和周末之间, 其对热负荷的要求也介于二者之间。为满足基础的供热需求, 该情况下的热负荷不能有较大的变化。

对于日期类型因素可利用归一化思想, 将不同时间的影响效果量化为 0~1 的数值来作为网络的输入。根据居家人数的不同将工作日量化为 0.4, 周末量化为 0.8, 节假日量化为 0.7。如表 1 所示。

表 1 日期类型量化值
Tab. 1 Quantized value of date type

日期类型	工作日	节假日	周末
量化值	0.4	0.7	0.8

将热用户居家人数作为影响因素可以保证工作日时可以适当降低供热负荷。当然, 考虑到其影响作用相对于温度因素^[5]还是较小的, 所以不会造成得到的预测热负荷值大幅降低, 依然能够满足基本的供热需求, 同时可以降低供热耗能。由于我国北方地区城市普遍实行集中供热, 如果将能耗降低 1%所产生的经济效益与环境效益也十分巨大。

综上所述, BP 网络输入端为第 K 天的温度、热负荷、日期类型, 以及第 $K+1$ 天温度预报。网络的输出为第 $K+1$ 天的热负荷。

1.2 BP 神经网络的结构和参数

由于隐含层数没有固定的公式、理论来确定, 本文采用经验法选定隐含层数为一层, 隐含层单元数确定为 5 个。所以神经网络结构为 4:5:1 结构。如图 1, 经过多次试验, 确定 BP 神经网络的学习率为 0.1, 训练目标为 0.000 001, 迭代次数为 1 000 次。

1.3 数据预处理

本文计算热负荷的数据来源于热力公司, 由于当前集中供热系统还存在控制方法不够完善、设备

误差、人为错误等问题，导致个别时间点的数据出现异常情况。为保证预测精度需剔除不合理的数据。本文中提前对数据进行甄别，找出不良数据。将数据组成矩阵 $X(i,j), i=1,2,\dots,24$ 表示记录当天 24 个时刻； $j=1,2,\dots,7$ ，表示一共记录了 7 天的数据。计算出每一行的平均值 $E(n)$ 、方差 $V(n)$ 和偏离率 $P(i,n)$ 。设定辨别值 $\delta=1.1$ ，比较二者的大小。当偏离率小于所设的辨别值时，该数据便可以作为样本数据；否则数据便是错误数据。对于出现错误数据的时刻，可以用前后 10 min 的数据求平均值代替，原数据如表 2 所示。

本文选用连续 7 天每天 24 h 共 168 组热负荷数据作为训练样本，同时选取对应时刻的温度和后

一天的预报温度，以及当天的工作日休息日情况作为训练样本的输入，选取对应天数后一天的热负荷数据作为训练样本的输出。经过处理后的数据如表 3 所示。

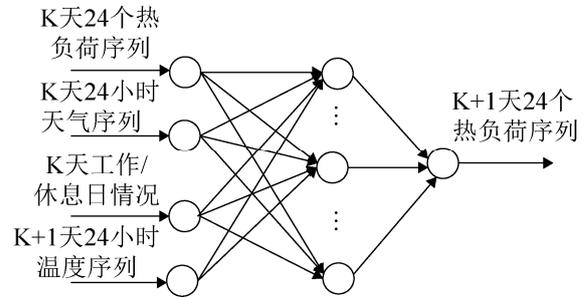


图1 BP神经网络热负荷预测模型
Fig. 1 Heat load forecast model based on BP neural network

表2 热负荷原始值
Tab. 2 Original value of heat load

时间/h	第1天 热负荷(GJ)	第2天 热负荷(GJ)	第3天 热负荷(GJ)	第4天 热负荷(GJ)	第5天 热负荷(GJ)	第6天 热负荷(GJ)	第7天 热负荷(GJ)
1	9.46	12.1	11.6	11.1	11.5	10.0	9.31
2	9.67	10.9	11.2	11.3	9.47	10.8	9.76
3	10.2	10.5	11.5	9.89	9.37	10.0	10.4
4	10.7	9.81	11.2	11.2	10.1	10.5	11.3
5	10.8	11.4	11.7	10.2	11.3	9.09	12.0
6	11.0	<u>14.9</u>	11.6	10.0	12.0	10.3	12.2
7	10.7	10.5	12.1	10.9	11.6	11.5	11.3
8	12.5	12.3	11.5	11.7	11.5	10.5	11.4
9	12.7	10.9	10.3	11.4	10.3	<u>18.1</u>	11.2
10	12.1	12.3	10.2	<u>16.8</u>	9.15	10.8	10.0
11	9.62	11.2	11.3	10.3	9.41	11.5	9.83
12	9.53	10.4	10.9	9.62	9.73	12.1	9.58
13	9.13	11.1	10.5	12.3	10.5	10.1	9.58
14	9.12	10.6	10.2	11.3	11.4	10.6	<u>14.8</u>
15	9.97	10.4	10.1	9.63	10.8	11.1	11.7
16	10.3	10.6	11.3	10.7	10.7	<u>18.7</u>	10.6
17	10.3	10.9	11.7	11.8	10.4	10.4	11.3
18	9.63	9.34	10.3	10.3	10.3	10.8	10.4
19	10.1	9.64	<u>16.4</u>	<u>21.2</u>	10.5	9.93	11.7
20	12.1	11.2	10.7	12.2	9.92	10.0	11.7
21	10.6	11.7	10.9	10.9	10.1	11.7	11.6
22	10.1	10.6	11.4	11.9	11.3	10.7	12.3
23	11.7	10.7	11.3	12.0	11.7	9.91	12.5
24	10.8	11.0	11.6	11.7	9.97	9.98	14.8

表 3 热负荷预测训练样本
Tab. 3 Training sample of heat load forecasting

编号	热负荷(GJ)	实时温度(°C)	预报温度(°C)	工作日/休息日情况
1	9.460 9	-5.5	-9.2	0.4
2	9.675 1	-8.6	-8.8	0.4
3	10.154 6	-10.1	-9.2	0.4
4	10.740 3	-10.7	-9.3	0.4
5	10.812 1	-11.2	-9.6	0.4
7	10.963 2	-13	-10.2	0.4
⋮				
161	10.283 4	-7.1	-6.9	0.4
162	10.412 1	-7.6	-7.4	0.4
163	11.710 4	-10.7	-8.8	0.4
164	11.726 4	-10.9	-9.7	0.4
165	11.611 2	-10.9	-10.7	0.4
166	12.336 6	-13.6	-11.9	0.4
167	12.507 9	-13.7	-12.2	0.4
168	14.828 1	-16.2	-12.9	0.4

表 2 中添加下划线的数据为预处理时甄别出的错误数据。这些热负荷值出现了较大的起伏, 超出了的辨别值给定的范围, 同时当时的温度并未出现较大的变化。从而确定这些数据是错误的。对于这些错误数据选用文中所提到的方法, 即用前后 10min 时刻的数据的平均值代替。

1.4 仿真实验验证

从图 2 中可以看出, BP 神经网络的预测输出可以跟随实际热负荷的变化趋势, 但是在部分时间点预测值与输出值的差值偏大, 影响预测精度。

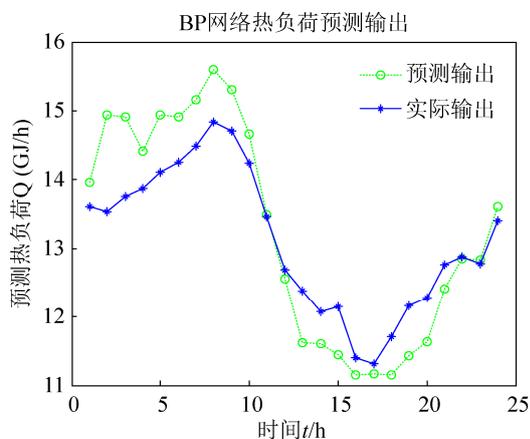


图 2 BP 神经网络热负荷预测输出图

Fig. 2 Heat load forecast based on BP neural network

考虑到供热系统自身的特点以及根据其他学者所进行的热负荷预测工作^[6-9], 单一的 BP 神经网络很难达到准确的预测。本文选择遗传算法 GA(genetic algorithm)优化 BP 神经网络(GABP)的方法, 通过遗传操作为 BP 神经网络确定最优的连接权值和阈值, 保证预测模型的精度。

2 遗传算法的优化原理

遗传算法与神经网络二者的结合方式有合作式与辅助式。在求解问题时同时利用二者的结合方式称之为合作式结合。对于辅助式即利用遗传算法确定神经网络的连接权值、阈值、网络结构, 构造出更合理的网络结构或参数, 然后再通过 BP 神经网络求解。本文中选用的是辅助式结合的方式。

2.1 优化流程

通过遗传算法对 BP 神经网络的权值、阈值优化, 为神经网络的训练提供合理的参数支持, 实现步骤见图 3。第一步: 通过实数编码对连接权值、阈值进行编码, 产生初始种群; 第二步: BP 网络计算误差作为初始适应度值; 第三步: 通过选择、交叉、变异遗传操作寻找最优个体组成的最优种

群，即最优权值、阈值；第四步：将最优种群赋与BP网络，实现训练和预测功能。

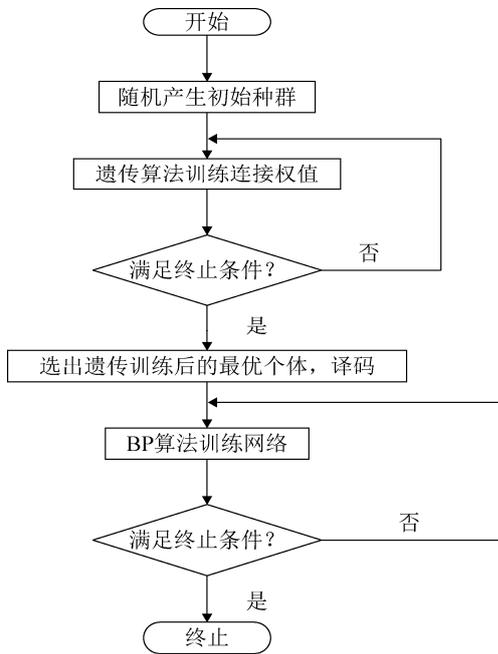


图3 遗传算法优化BP网络流程图

Fig. 3 The optimization flow chart of BP network based on genetic algorithm to optimize

2.2 编码方式

遗传算法常用的编码方式主要有二进制编码和实数编码。由于解的精度会受到编码长度的影响，所以当编码长度较长时二进制编码会造成遗传算法的搜索空间急剧扩大，计算量过大，算法性能变差。实数编码直接对解空间编码，可降低串长，不必反复编码和解码，提高计算效率。所以本文采用实数编码方案，将连接权值、阈值编码为实数串。

在本文中输入层有4个节点(考虑日期类型时)，隐含层有15个节点，输出层有1个节点。共有 $4 \times 15 + 15 \times 1 = 75$ 个权值， $15 + 1 = 16$ 个阈值。所以遗传算法编码长度为 $75 + 16 = 91$ 。在编码时首先产生1行91列的全1数组作为初始染色体。然后利用随机产生的编码率结合线性插值法产生一串实数即为初始的编码。

2.3 适应度函数

适应度函数^[10]是对个体适应力的描述，其数

值的大小关系到该染色体被选择的概率。适应度值与被选择几率成正比。在进行热负荷预测时，距离预测时刻越近的训练样本对预测值的影响越大，所以应当设置加权系数提高临近样本的权重。本文采用公式2所示的适应度函数。

$$f = \frac{1}{\frac{1}{N} \sum_{n=1}^N \frac{1}{t} \left(\frac{1}{2} \sum_{j \in c} (d_{j(n)} - y_{j(n)})^2 \right)} \quad (2)$$

式中： N 为训练样本总数； $1/t$ 为加权系数，增强临近时刻样本对预测值的影响； $d_{j(n)}$ 、 $y_{j(n)}$ 为第 n 次迭代第 j 个单元的期望输出和实际输出。

2.4 遗传操作

2.4.1 选择操作

本文的选择策略^[11]为：保留最优个体，不予交叉，直接复制到下一代，防止最优解被后续的遗传操作破坏。选择算子采用轮盘赌法： f_i 为个体适应度值， N 为种群个体数目，选择率 p_i 的计算如式(3)。在本文中将预测所得热负荷值与实际值的差值作为个体适应度，即预测精度高的神经网络参数值得到保留，进入下一次迭代过程。对于预测精度低的个体则进行交叉变异操作，改善适应度，提高网络的预测精度。

$$p_i = f_i / \sum_{j=1}^N f_j \quad (3)$$

2.4.2 交叉操作

由于本文采用的编码为实数编码，所以交叉操作采用实数交叉法，方法如式5：

$$\left. \begin{aligned} a_{kj} &= a_{kj}(1-b) + a_{lj}b \\ a_{lj} &= a_{lj}(1-b) + a_{kj}b \end{aligned} \right\} \quad (4)$$

选择第 k 个染色体 a_k 和第 l 个染色体 a_l 在 j 位进行交叉操作。交叉概率 P_c 是进行交叉操作的依据。交叉概率越高，种群更新越快，优良解也更易丢失，如果交叉概率过低又会导致无法产生新的种群。通常交叉概率取0.6~1.0。文中采用单点交叉的方式见图4，图中数字组成的字符串即表示连接权值、阈值组成的染色体。



图 4 染色体单点交叉示意图

Fig. 4 The single point cross diagram of chromosomes

2.4.3 变异操作

变异操作就是将染色体上的某些基因位上的基因值以相应的变异概率 $P_m d_{j(n)}$ 改变为其他的等位基因, 以此产生新的子代。当子代的性能评价高于父代时则用子代代替父代, 否则对父代再次进行变异操作。变异方法如式(5):

$$a_{ij} = \begin{cases} a_{ij} + (a_{ij} - a_{\max}) * f(g) & r \geq 0.5 \\ a_{ij} + (a_{\min} - a_{ij}) * f(g) & r \leq 0.5 \end{cases} \quad (5)$$

a_{\max} 为基因位 a_{ij} 的上界; a_{\min} 为基因位 a_{ij} 的下界; $f(g) = r_2(1 - g / G_{\max})$ $r \geq 0.5$; r_2 为一个随机数; g 为当前迭代次数; G_{\max} 是最大进化次数; r 是[0 1]间的随机数; P_m 一般取[0.005 0.05]。

图 5 中染色体在第 8 基因位出现变异, 染色体上基因位对应的基因值发生变化, 在本文中即对应的连接权值、阈值出现变异。遗传算法将权值、阈值作为字符串, 从串集开始搜索, 利于全局择优。遗传操作采用随机方法进行最优解搜索, 选择操作体现了向最优解逼近, 交叉体现了最优解的产生, 变异体现了全局最优解的覆盖。同时随着进化代数的增加, 遗传算法的寻优时间也会不断增加, 在本实验中选定进化代数为 20, 兼顾精度与时间效益。



图 5 变异操作示意图

Fig. 5 The diagrammatic sketch of mutation operation

3 供热负荷预测模型验证

3.1 GABP 预测验证

本文选用两种 BP 神经网络结构, 分别为 3-5-1 结构和 4-5-1 结构。二者的主要区别就是有无考虑日期类型的不同。进化代数为 20; 种群规模为 20;

交叉概率确定为 0.3; 变异概率选定为 0.001; BP 网络的学习率为 0.2, 迭代次数为 100, 目标值为 0.0000 1。根据选定的参数对遗传算法和 BP 神经网络进行设定, 通过对 168 个训练样本训练学习, 得到最终的预测结果。其中 3-5-1 结构的神经网络经过遗传算法可以得到相应连接权值和阈值, 如图 6 所示。 w_1 为输入层到隐层连接权值, w_2 为隐层到输出层连接权值, b_1 为隐层单元阈值, b_2 为输出层单元阈值。

$$\begin{aligned} b_1 &= -0.7063 \quad 2.5092 \quad 1.2853 \quad -0.4395 \quad -1.4309 \\ b_2 &= -0.6914 \\ w_1 &= \begin{matrix} 0.9737 & 0.9130 & 1.3637 & -2.4639 & -0.3302 & -0.2583 \\ 2.5532 & 1.2564 & 1.8628 & 2.8813 & -1.8912 & -2.8290 \\ 2.6087 & -2.8653 & 2.2888 & & & \end{matrix} \\ w_2 &= -0.9646 \quad -2.4023 \quad -2.7344 \quad 2.3901 \quad -1.2380 \end{aligned}$$

图 6 遗传算法优化得到的权值、阈值

Fig. 6 The value of weights and thresholds based on genetic algorithm

图 7、图 8 为经过遗传算法优化的 3-5-1 结构 BP 神经网络的预测输出和预测误差。在训练时设置 $\text{validation check}=20$, 可以得到图 9 所示的误差曲线。从图中可以看出在第 5 次迭代时达到误差最小。当取消 validation check 功能时, 算法以所设定的迭代次数和目标值运行得到的预测效果相对较差, 最终经试验确定 $\text{validation check}=20$ 。

由于所选的测试样本天气在上午 9 时左右达到最低温, 所以其所对应的热负荷值也最高。从图 2 与图 7 中可以看出, 遗传算法优化过的 BP 神经网络与未优化过的 BP 神经网络所预测的热负荷都可以跟随着实际的热负荷曲线变化。但从图 8 中可以看出, 经过遗传算法优化的 BP 网络预测精度有着较为明显的提高, 绝对误差基本控制在 0.4 以内。误差最大点出现在下午三点, 此时气温为一天中最高时刻, 也是天中气温变化的转折点, 因此对应的热负荷变化最为剧烈, 此时的预测误差最大。但是总体上预测值与实际值之间的误差处于合理范围内, 说明该算法的预测结果是可用的。

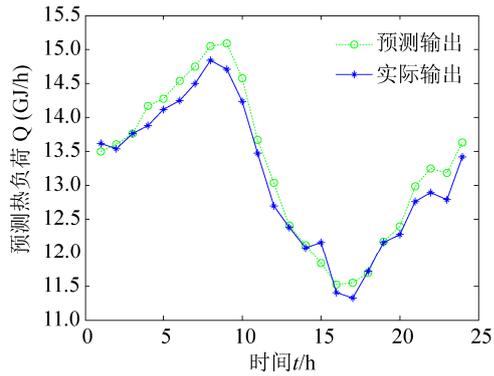


图7 GABP热负荷预测输出图
Fig. 7 Heat load forecast based on GABP

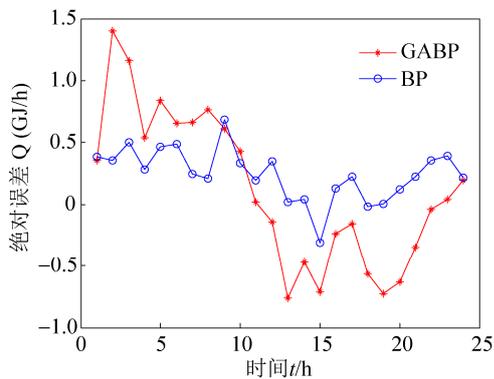


图8 BP与GABP热负荷预测误差对比图
Fig. 8 The comparison diagram of heat load forecast error between BP and GABP

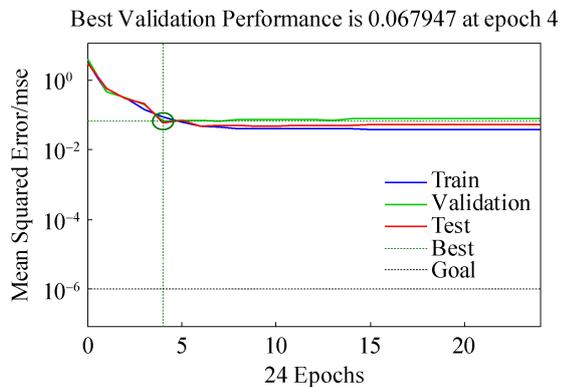


图9 GABP算法误差变化图
Fig. 9 The error change diagram of GABP algorithm

3.2 预测方法对比分析

为找出更合理准确的热负荷预测方法,本实验分别增加了 GABP 神经网络与引言中提到的经典方法的对比。使用相同的数据利用 RBF 神经网络与 Elman 神经网络进行预测。从图 10~11 中可以看出 Elman 神经网络与 RBF 神经网络热负荷的预测

输出都能跟随实际热负荷的变化趋势。Elman 网络的预测输出在 0~7 时刻与 16 时左右误差较大。RBF 网络同样在这些时间段出现了较大的预测误差。即这两种预测算法在热负荷波动较大时预测精度出现下降的情况。图 12 中对比了 BP 网络、GABP 网络、RBF 网络、Elman 网络的预测误差,从中可以看出通过遗传算法的优化 BP 网络的预测精度在这几种网络中是最高的。

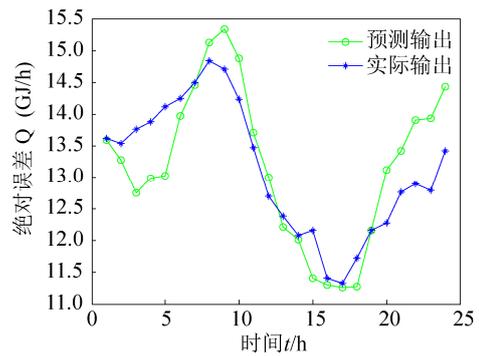


图10 Elman神经网络热负荷预测图
Fig. 10 Heat load forecast based on Elman neural network

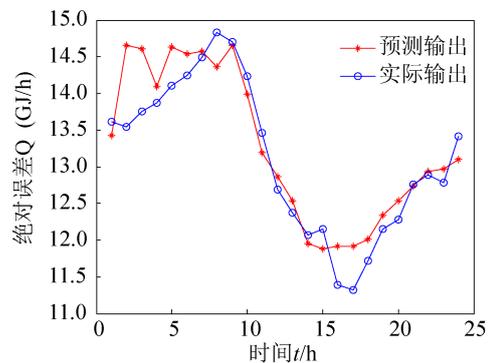


图11 RBF神经网络热负荷预测图
Fig. 11 Heat load forecast based on RBF neural network

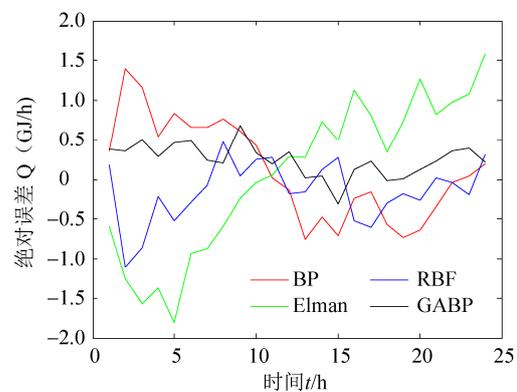


图12 多种预测算法误差对比图
Fig. 12 Error contrast diagram of multiple forecast algorithms

3.3 添加日期类型验证算法

将日期类型加到预测模型的输入端, 构造 4-5-1 结构的 BP 神经网络, 利用上述算法进行预测训练得到图 13 所示的预测输出。

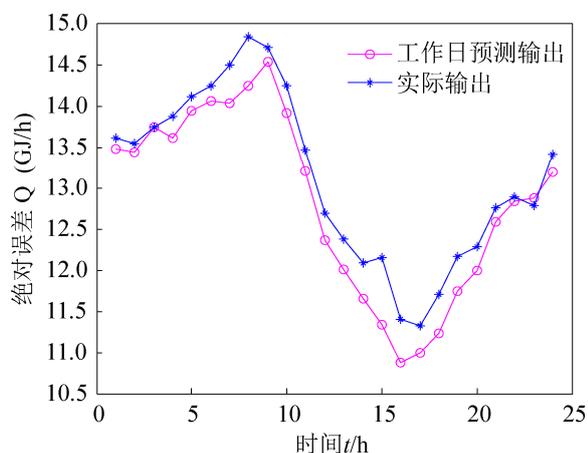


图 13 工作日 GABP 热负荷预测输出图
Fig. 13 Heat load forecast of GABP on weekdays

图 13 中实际输出选择工作日数据作为测试样本, 日期类型量化为 0.4。从图 8 和图 13 可以看出无论是否考虑日期类型, 预测值都可以跟随实际热负荷的需求变化。从图 13 中可以看出, 日期类型为工作日时预测热负荷值比实际的热负荷值整体上偏低一些, 同时在早晚温度较低时二者的差值较小, 此时可以满足供热需求; 而在午后 15 点左右差值较大, 考虑到此时气温为一天中最高, 通常会产生供热过多的情况, 此时预测差值较大仍可满足供热需求。经计算可知工作日的热负荷预测输出差值最多为 6.7%, 多数时刻的差值在 4% 以内。误差的期望值为 0.291 7, 方差为 0.040 28, 均方差为 0.200 1。也可以说明预测值的可用性。综合来看, 当考虑日期类型时既可以满足热需求又可以相应地降低供热能耗。

当选择的预测日期类型为周末时, 此时可将日期量化为 0.8, 本文中仍选择上述的预测日期, 只是将时间因素进行调整得到预测输出。从图 14 中可以看出更改日期类型为周末时, 得到的热负荷预测值仍能够跟随实际热负荷的变化, 预测值基本上

会高于实际值, 计算得知高出的范围主要集中在 0.2~0.6, 差值百分比主要在 2%~4% 之间, 误差的期望值为 0.359 4, 方差为 0.035 44, 均方差为 0.192 3。通过结果说明, 当预测日期类型为周末时可以小幅提高供热量, 提高热用户舒适度。

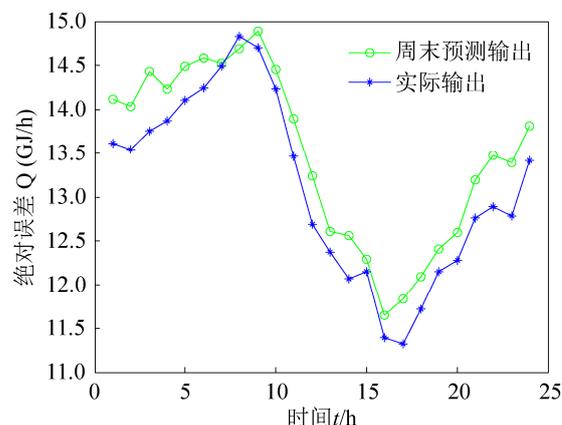


图 14 GABP 周末热负荷预测输出图
Fig. 14 Heat load forecast of GABP on Weekend

综合所得到的预测结果来看, 当日期类型不同时预测所得到的热负荷值能均能随着日期类型的变化而变化, 且二者的方差较小、大小相近, 期望值同样很小, 说明算法的稳定性、和精确性较好。综合来看工作日时可以在保证供热需求的同时适当降低供热量兼顾节能, 在周末用户居家较多时可小幅增加供热量, 提高用户的舒适度。

4 结论

在建立热负荷预测模型时考虑到温度是热负荷最大的影响因素, 热负荷跟随温度的变化是满足供热的必要条件。日期因素则是提高用户舒适度和节能降耗的保证。将这两种因素综合考虑时得到的热负荷更加符合按需供热的要求。

参考文献:

- [1] 王庆峰. 集中供热系统运行调节优化及热负荷预测方法研究[D]. 济南: 山东大学, 2010.
Wang Qingfeng. Research on heat Load forecasting and optimization of operation and regulation of district heating system[D]. Ji'nan: Shangdong University, 2010.

- [2] Ma Tao, Xu Xiangdong. Load predictions for district heating systems based on a WNN model[J]. Journal of Tsinghua University (Science and Technology) (S1000-0054), 2005, 45(5): 708-710.
- [3] 崔高健, 凡东生, 曲永利. 基于Elman型神经网络集中供热负荷预测模型的研究[J]. 建筑节能, 2011(3): 9-11.
Cui Gaojian, Fan Dongsheng, Qu Yongli. Load Prediction of District Heating System Based on Elman Neural Network[J]. Building Energy Efficiency, 2011(3): 9-11.
- [4] L Pedersen, J Stang, R Ulseth. Load Prediction Method for Heat and Electricity Demand in Buildings for the Purpose of Planning for Mixed Energy Distribution Systems[J]. Energy&Buildings (S0378-7788), 2008, 40(7): 1124-1134.
- [5] 王美萍, 张佼, 田琦. 基于影响因素分析和小波神经网络的供热量预测[J]. 暖通空调, 2014(3): 113-118.
Wang Meiping, Zhang J, Tian Q. Heating Load Prediction Based on Analysis of Influence Factors and Wavelet Neural Network[J]. Heating Ventilating & Air Conditioning, 2014(3): 113-118.
- [6] 李胜涛. 集中供热系统的热负荷预测方法研究[D]. 西安: 长安大学, 2014.
Li Shengtao. Research on Heating Load Forecasting of District Heating System[D]. Xi'an: Chang'an University 2014.
- [7] 韩颖. 集中供热系统总供热量 ADP 优化控制策略研究[D]. 包头: 内蒙古科技大学 2015.
Han Ying. Research of ADP Strategy for Heat Supply Optimal Control of District Heating System[D]. Baotou: Inner Mongolia University of Science&Technology 2015.
- [8] 介鹏飞. 集中供热系统热负荷预测及运行优化[D]. 天津: 天津大学, 2013.
Jie Pengfei. Heating load prediction and operation optimization of district heating System[D]. Tianjin: Tianjin University, 2013.
- [9] 张经博, 郭凌, 王朝霞, 等. 基于遗传算法优化 BP 神经网络的供暖系统热负荷预测模型[J]. 四川兵工学报, 2014 (4): 152-156.
Zhang Jingbo, Guo ling, Wang zhaoxia, et al. Thermal Load Forecasting Model of Heating System Based on Genetic Algorithm Optimization BP Neural Network[J]. Journal of Sichuan Ordnance, 2014 (4): 152-156.
- [10] 王东亚, 张琳, 赵国材. 神经网络遗传算法在供热负荷预测中应用[J]. 辽宁工程技术大学学报(自然科学版), 2005, 24(4): 161-163.
Wang Dongya, Zhang Lin, Zhao Guocai. Application of Neural Network and Genetic Algorithm in Heating Load Forecasting[J]. Journal of Liaoning Technical University: Natural Science, 2005, 24(4): 161-163.
- [11] MATLAB中文论坛. MATLAB神经网络30个案例分析[M]. 北京: 北京航空航天大学出版社, 2010.
MATLAB Chinese Forum. Analysis of 30 cases of MATLAB neural network[M]. Beijing: Beihang University press, 2010.