



(12) 发明专利申请

(10) 申请公布号 CN 104484715 A

(43) 申请公布日 2015.04.01

(21) 申请号 201410709145.9

(22) 申请日 2014.11.28

(71) 申请人 江苏大学

地址 212013 江苏省镇江市京口区学府路
301号

(72) 发明人 胡程磊 李康吉 薛文平 梅从立
江辉 丁煜函 刘国海

(51) Int. Cl.

G06Q 10/04(2012.01)

G06Q 50/08(2012.01)

G06N 3/00(2006.01)

G06N 3/02(2006.01)

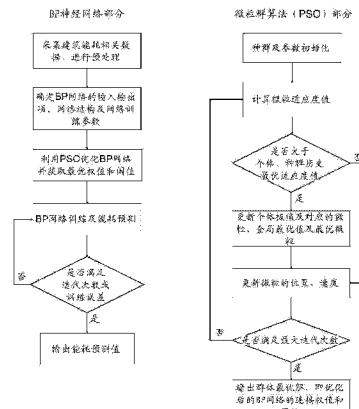
权利要求书2页 说明书6页 附图2页

(54) 发明名称

一种基于神经网络和微粒群优化算法的建筑
能耗预测方法

(57) 摘要

本发明公开了一种基于神经网络和微粒群优
化算法的建筑能耗预测方法，包括以下四个主要
步骤：采集建筑能耗相关数据，并对数据进行预
处理；确定具有误差反向传播学习功能的多层前
馈神经网络模型的输入输出项及网络结构；利用
微粒群算法优化BP网络的连接权值和阈值；利用
优化得到的神经网络模型对建筑电力能耗进行短
期预测。本发明利用统计产品与服务解决方案软
件对预输入变量进行主成分分析，选择符合主成
分提取要求的变量，从而降低了输入维度；利用
微粒群算法的全局优化能力对神经网络模型的结
构和参数进行优化，相对于目前的建筑能耗预测
方法，本发明提出的预测模型具有结构简单，预测
精度高等优点。



1. 一种基于神经网络和微粒群优化算法的建筑能耗预测方法, 其特征在于, 具体包括如下步骤:

步骤 1, 采集建筑能耗相关数据, 包括建筑电力能耗历史数据和建筑物当地气象数据, 并对数据进行预处理;

步骤 2, 确定具有误差反向传播学习功能的多层前馈神经网络 (BP 神经网络) 模型的输入输出项、神经网络结构及网络训练参数;

步骤 3, 利用微粒群算法 (PSO) 优化 BP 网络的连接权值和阈值, 具体过程包括:

a、种群初始化, 包括: 各微粒的初始位置在定义域 $[-x_{\max}, x_{\max}]$ 中随机选择, 各微粒的初始速度在定义域 $[-v_{\max}, v_{\max}]$ 中随机选择; 参数初始化, 包括: 设置惯性权重 w 的定义域 $[w_{\min}, w_{\max}]$, 认知系数 c1, 社会系数 c2, 最大迭代次数 iter_{max};

b、计算微粒群中各微粒的适应度值, 其公式为:

$$\sum_{i=1}^K (|y_{pred,i} - y_{data,i}|)$$

式中, $y_{pred,i}$ 表示预测的能耗值, $y_{data,i}$ 表示实际能耗值, K 表示训练数据集的数量;

c、判断计算的微粒适应度值是否大于个体或种群历史最优适应度值, 是则更新个体或种群历史最优值并记录最优位置, 否则更新微粒的位置和速度; 微粒的位置和速度更新公式为:

$$\begin{cases} v_j(t+1) = wv_j(t) + c1r1(p_j(t) - x_j(t)) + c2r2(p_g(t) - x_j(t)) \\ x_j(t+1) = v_j(t+1) + x_j(t) \end{cases}$$

式中, $v_j(t)$ 为微粒 j 在第 t 代的速度; $r1, r2$ 为服从均匀分布的随机数; $x_j(t)$ 为微粒 j 在第 t 代的位置; $p_j(t)$ 为微粒 j 的个体历史最优位置; $p_g(t)$ 为群体历史最优位置; w 为惯性权重, 其表达式:

$$w = w_{\max} - \frac{w_{\max} - w_{\min}}{iter_{\max}} \times k$$

式中, w_{\max} 为初始权重值, w_{\min} 为最终权重值, k 为当前迭代次数;

d、判断是否满足终止条件: 若当前迭代次数达到最大迭代次数或网络的训练误差达到精度要求, 则停止迭代, 输出优化结果, 否则返回到第 (2) 步继续迭代;

e、输出优化结果, 即优化后的 BP 网络的连接权值和阈值;

步骤 4, 利用优化得到的神经网络预测模型对建筑电力能耗进行短期预测。

2. 根据权利要求 1 所述的一种基于神经网络和微粒群优化算法的建筑能耗预测方法, 其特征在于: 所述步骤 1 中, 建筑能耗历史数据由能耗监控系统监测得到, 气象数据获取自网络公开资料, 能耗数据的预处理主要包括: 噪声数据剔除和数据归一化, 其中:

剔除的噪声数据通过均值法填补, 由公式表示为:

$$\hat{y}_t = \frac{y_{t-1} + y_{t+1}}{2}$$

式中, \hat{y}_t 为填补的数据估计值, y_{t-1} 为前一周期数据, y_{t+1} 为后一周期数据。

能耗数据的归一化由公式表示为:

$$y = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$$

式中, x 为需要归一化的数据, x_{\min} 、 x_{\max} 表示需归一化数据的最小值和最大值, y 表示归一化输出值。

3. 根据权利要求 1 所述的一种基于神经网络和微粒群优化算法的建筑能耗预测方法, 其特征在于 :所述步骤 2 中, BP 网络的输入项由统计产品与服务解决方案软件 (SPSS) 通过主成分分析来确定 ;BP 网络的结构包括网络的输入神经元个数、输出神经元个数及隐含层神经元个数 ;所述输入项包括 :室外平均干球温度 $T(t)$ 、建筑物的小时级太阳辐射值 $S(t)$ 、当地的节假日标志 s 、每天时间 (小时级) 的正弦值 sh 、每天时间 (小时级) 的余弦值 ch 、一小时前的建筑电力能耗值 $y(t-1)$ 、二小时前的建筑电力能耗值 $y(t-2)$;所述输出项为预测目标为建筑物的小时级电力需求 WBE ;隐含层神经元个数根据映射神经网络存在定理 (Kolmogorov) 进行合理选择, 公式为 :

$$\text{隐含层神经元个数} = \sqrt{\text{输入神经元个数} + \text{输出神经元个数} + 1} + a$$

式中, a 为定义在 $[1, 10]$ 之间的一个整数常量。

4. 根据权利要求 3 所述的一种基于神经网络和微粒群优化算法的建筑能耗预测方法, 其特征在于 :所述 BP 网络的隐含层神经元个数为 5 个。

5. 根据权利要求 1 所述的一种基于神经网络和微粒群优化算法的建筑能耗预测方法, 其特征在于 :所述步骤 3 中种群初始化过程, 种群规模设置为 20, 惯性权重 w 的定义域设置为 $[0.4, 0.9]$, 认知系数 c_1 设置为 2, 社会系数 c_2 设置为 1.8, 最大迭代次数设置为 100。

6. 根据权利要求 1 所述的一种基于神经网络和微粒群优化算法的建筑能耗预测方法, 其特征在于 :所述步骤 4 中, 将归一化后得到的建筑能耗相关数据划分为训练数据集和测试数据集两部分, 其中, 训练数据集用来进行 BP 网络训练, 测试数据集用来估计能耗预测误差 ;为了评价建筑能耗预测精度, 采用标准差率 (CV) 作为衡量指标, 表达式为 :

$$CV = \frac{\sqrt{\sum_{i=1}^N (y_{pred,i} - y_{data,i})^2 / N}}{y_{data}}$$

式中, $y_{pred,i}$ 表示预测的能耗值, $y_{data,i}$ 表示测试数据集中的实际能耗值, \bar{y}_{data} 表示实际能耗值的平均值, N 表示测试数据集的数量。

一种基于神经网络和微粒群优化算法的建筑能耗预测方法

技术领域

[0001] 本发明涉及一种基于神经网络和微粒群优化算法的建筑能耗预测方法，属于建筑能量管理领域。

背景技术

[0002] 随着社会生产力的不断发展和人民物质生活水平的稳步提高，建筑能耗将持续快速增长，这对能源的供给和生态环境的保持构成很大的挑战。结合我国实情，实现建筑能量的科学、优化管理，需要以建筑能耗的科学预测为前提和基础。近十年来，随着各种智能优化技术的不断提出和广泛应用，建筑能耗的预测方法得到了快速发展。在建筑能量领域，如何结合先进控制手段对目前的建筑能耗预测方法进行改进和完善，对于建筑能耗的准确估计和科学管理，对于相关政策法规的制定具有重要意义。

[0003] 多年来，国内外众多研究人员对建筑能耗预测的方法进行了广泛研究，从最简单的线性回归法到专业的模拟软件方法等等。若已知建筑能耗的历史数据，则BP神经网络方法是典型的预测方法之一。BP网络具有自学习、自组织、联想记忆及并行处理等功能。作为一种基于梯度的自适应算法，BP网络的学习过程存在易陷入局部极值、收敛速度慢等缺陷，无法保证网络参数的全局最优。而微粒群算法、遗传算法等智能优化算法具有良好的全局搜索能力和很好的收敛性，且易于与其他算法结合，这给单一神经网络结构及参数的优化改良带来了契机。另外，由于影响建筑能耗的相关因素较多，除了外界天气环境之外，节假日、地理位置、建筑物自身的结构都对建筑能量消耗产生影响，如何合理选择预测模型的输入项，确定合适的网络结构也是神经网络方法需要进一步改善的问题。

发明内容

[0004] 针对现有的建筑能耗预测方法所存在的上述缺陷，本发明提出了一种基于神经网络和微粒群优化算法的建筑能耗预测方法，与单一的神经网络相比，具有更高的预测精度。其特点在于利用微粒群算法优化BP神经网络的连接权值和阈值，发挥了微粒群算法具有的实现简单、寻优速度快及全局搜索能力强等优点，弥补了BP网络自身连接权值和阈值选择问题上存在的随机性缺陷，从而使BP网络具有较强的收敛性，提高了BP网络的学习能力和泛化能力。

[0005] 在建立建筑能耗预测模型的过程中，选取合理的输入变量是一个重要的环节，本发明利用主成分分析法对预输入变量进行筛选，降低了输入维度，减小了网络规模，对建筑能耗相关数据的分析和预处理具有重要意义。

[0006] 本发明所采用的技术方案是：

[0007] 一种基于神经网络和微粒群优化算法的建筑能耗预测方法，具体包括如下步骤：

[0008] 步骤1，采集建筑能耗相关数据，包括建筑电力能耗历史数据和建筑物当地气象数据，并对数据进行预处理；

[0009] 步骤2，确定具有误差反向传播学习功能的多层前馈神经网络(BP神经网络)模型

的输入输出项、神经网络结构及网络训练参数；

[0010] 步骤 3, 利用微粒群算法 (PSO) 优化 BP 网络的连接权值和阈值, 具体过程包括：

[0011] a、种群初始化, 包括 : 各微粒的初始位置在定义域 $[-x_{\max}, x_{\max}]$ 中随机选择, 各微粒的初始速度在定义域 $[-v_{\max}, v_{\max}]$ 中随机选择 ; 参数初始化, 包括 : 设置惯性权重 w 的定义域 $[w_{\min}, w_{\max}]$, 认知系数 c1, 社会系数 c2, 最大迭代次数 $iter_{\max}$;

[0012] b、计算微粒群中各微粒的适应度值, 其公式为 :

$$[0013] \sum_{i=1}^K (|y_{pred,i} - y_{data,i}|)$$

[0014] 式中, $y_{pred,i}$ 表示预测的能耗值, $y_{data,i}$ 表示实际能耗值, K 表示训练数据集的数量 :

[0015] c、判断计算的微粒适应度值是否大于个体或种群历史最优适应度值, 是则更新个体或种群历史最优值并记录最优位置, 否则更新微粒的位置和速度 ; 微粒的位置和速度更新公式为 :

$$[0016] \begin{cases} v_j(t+1) = wv_j(t) + c1r1(p_j(t) - x_j(t)) + c2r2(p_g(t) - x_j(t)) \\ x_j(t+1) = v_j(t+1) + x_j(t) \end{cases}$$

[0017] 式中, $v_j(t)$ 为微粒 j 在第 t 代的速度 ; $r1, r2$ 为服从均匀分布的随机数 ; $x_j(t)$ 为微粒 j 在第 t 代的位置 ; $p_j(t)$ 为微粒 j 的个体历史最优位置 ; $p_g(t)$ 为群体历史最优位置 ; w 为惯性权重, 其表达式 :

$$[0018] w = w_{\max} - \frac{w_{\max} - w_{\min}}{iter_{\max}} \times k$$

[0019] 式中, w_{\max} 为初始权重值, w_{\min} 为最终权重值, k 为当前迭代次数 ;

[0020] d、判断是否满足终止条件 : 若当前迭代次数达到最大迭代次数或网络的训练误差达到精度要求, 则停止迭代, 输出优化结果, 否则返回到第 (2) 步继续迭代 ;

[0021] e、输出优化结果, 即优化后的 BP 网络的连接权值和阈值 ;

[0022] 步骤 4, 利用优化得到的神经网络预测模型对建筑电力能耗进行短期预测。

[0023] 进一步, 所述步骤 1 中, 建筑能耗历史数据由能耗监控系统监测得到, 气象数据获取自网络公开资料, 能耗数据的预处理主要包括 : 噪声数据剔除和数据归一化, 其中 :

[0024] 剔除的噪声数据通过均值法填补, 由公式表示为 :

$$[0025] \hat{y}_t = \frac{y_{t-1} + y_{t+1}}{2}$$

[0026] 式中, \hat{y}_t 为填补的数据估计值, y_{t-1} 为前一周期数据, y_{t+1} 为后一周期数据。

[0027] 能耗数据的归一化由公式表示为 :

$$[0028] y = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$$

[0029] 式中, x 为需要归一化的数据, x_{\min}, x_{\max} 表示需归一化数据的最小值和最大值, y 表示归一化输出值。

[0030] 进一步, 所述步骤 2 中, BP 网络的输入项由统计产品与服务解决方案软件 (SPSS) 通过主成分分析来确定 ; BP 网络的结构包括网络的输入神经元个数、输出神经元个数及隐含层神经元个数 ; 所述输入项包括 : 室外平均干球温度 T(t)、建筑物的小时级太阳辐射值

S(t)、当地的节假日标志 s、每天时间（小时级）的正弦值 sh、每天时间（小时级）的余弦值 ch、一小时前的建筑电力能耗值 y(t-1)、二小时前的建筑电力能耗值 y(t-2)；所述输出项为预测目标为建筑物的小时级电力需求 WBE；隐含层神经元个数根据映射神经网络存在定理 (Kolmogorov) 进行合理选择，公式为：

[0031]

$$\text{隐含层神经元个数} = \sqrt{\text{输入神经元个数} + \text{输出神经元个数} + 1} + a$$

[0032] 式中，a 为定义在 [1, 10] 之间的一个整数常量。

[0033] 进一步，所述 BP 网络的隐含层神经元个数为 5 个。

[0034] 进一步，所述步骤 3 中种群初始化过程，种群规模设置为 20，惯性权重 w 的定义域设置为 [0.4, 0.9]，认知系数 c1 设置为 2，社会系数 c2 设置为 1.8，最大迭代次数设置为 100。

[0035] 进一步，所述步骤 4 中，将归一化后得到的建筑能耗相关数据划分为训练数据集和测试数据集两部分，其中，训练数据集用来进行 BP 网络训练，测试数据集用来估计能耗预测误差；为了评价建筑能耗预测精度，采用标准差率 (CV) 作为衡量指标，表达式为：

$$[0036] CV = \frac{\sqrt{\sum_{i=1}^N (y_{pred,i} - y_{data,i})^2 / N}}{y_{data}}$$

[0037] 式中， $y_{pred,i}$ 表示预测的能耗值， $y_{data,i}$ 表示测试数据集中的实际能耗值， y_{data} 表示实际能耗值的平均值，N 表示测试数据集的数量。

[0038] 本发明是一种基于神经网络和微粒群优化算法的建筑能耗预测方法，充分考虑了预输入变量之间的相关性，并且将微粒群算法和 BP 神经网络相结合，因此该能耗预测方法具有结构简单和预测精度高等优点。

[0039] 相对目前的能耗预测方法，本发明的优点表现在：

[0040] 1) 模型结构简单。本发明通过主成分分析方法，降低了输入维数，很好的解决了由于庞大的训练数据造成的 BP 网络训练时间过长，网络冗余过大等缺陷；

[0041] 2) 预测精度高。本发明利用微粒群算法 (PSO) 优化了 BP 神经网络的连接权值和阈值，改善了 BP 神经网络的学习能力和泛化能力，使得建筑能耗的预测精度明显提高。

[0042] 3) 实时性强。由于本发明中采用的微粒群优化算法的寻优速度较快，能够满足建筑能耗的实时性要求，因此可应用于建筑能量的在线分析与管理领域。

[0043] 4) 应用范围广。本发明提出的建筑能耗预测方法是基于数据驱动的，对于不同的建筑结构以及能量使用分布不一的建筑物同样适用，因而其应用范围广。

附图说明

[0044] 图 1 为本发明所述的一种基于神经网络和微粒群优化算法的建筑能耗预测方法的流程图；

[0045] 图 2 为未利用微粒群算法优化 BP 网络前的仿真图；

[0046] 图 3 为利用微粒群算法优化 BP 网络后的仿真图。

具体实施方式

[0047] 为了更为具体地描述本发明，下面结合附图和具体实施例对本发明进行详细说明。

[0048] 图 1 为本发明所述的一种基于神经网络和微粒群优化算法的建筑能耗预测方法的流程图，分为微粒群 (PSO) 算法及 BP 神经网络两部分。

[0049] 下面利用美国采暖、制冷与空调工程师学会提供的建筑能耗数据及相应的气象资料详细描述本发明方法的实施步骤：

[0050] 步骤 0. 采集建筑能耗相关数据，并对数据进行预处理。

[0051] 步骤 0.1 获取美国 ASHRAE 于 1993 年举办的第一届建筑能耗预测竞赛 (The Great Energy Predictor Shootout I) 提供的建筑能耗数据及相应的气象数据，数据类型包括：室外平均干球温度、太阳辐射值、相对湿度、风速以及整栋建筑电力能耗、热水能耗和冷水能耗。相关气象数据以小时为间隔，数据集共 4208 组数据；

[0052] 步骤 0.2 由于建筑能耗数据在短期内具有较明显的周周期性和日周期性，即休息日的能耗低于正常工作日能耗，每天早晚的能耗较少，中午相对于上午和下午能耗较少，根据此周期性剔除噪声数据，并对剔除的数据通过均值法填补，由公式表示为：

$$[0053] \hat{y}_t = \frac{y_{t-1} + y_{t+1}}{2}$$

[0054] 这里， \hat{y}_t 为填补的数据估计值， y_{t-1} 为前一周期数据， y_{t+1} 为后一周期数据；根据当地的节假日信息，用数字“1”代表正常工作日，数字“0”代表休息日，得到节假日标志 s；计算每天时间（小时级）的正弦值 sh 和余弦值 ch，公式为：

$$[0055] sh = \sin \frac{2\pi h(t)}{24}$$

$$[0056] ch = \cos \frac{2\pi h(t)}{24}$$

[0057] 这里， $h(t)$ 为小时值；对能耗数据集进行归一化处理，公式表示为：

$$[0058] y = \frac{x - x_{min}}{x_{max} - x_{min}}$$

[0059] 这里， x 为需要归一化的数据， x_{min} 、 x_{max} 表示需归一化数据的最小值和最大值， y 表示归一化输出值。

[0060] 步骤 1. 确定 BP 神经网络模型的输入输出项及神经网络结构。具体方法为：利用 SPSS 软件，对预输入变量进行主成分分析，预输入变量包括：室外平均干球温度 T(t)、小时级太阳辐射值 S(t)、相对湿度 humid、风速 wind、节假日标志 s、每天时间（小时级）的正弦值 sh、每天时间（小时级）的余弦值 ch、一小时前的建筑能耗值 y(t-1)、二小时前的建筑能耗值 y(t-2)，选择符合主成分提取要求（主成分对信息的累积贡献率 $\geq 97\%$ ）的变量作为输入项，最终确定七个输入变量，包括：室外平均干球温度 T(t)、建筑物的小时级太阳辐射值 S(t)、当地的节假日标志 s、每天时间（小时级）的正弦值 sh、每天时间（小时级）的余弦值 ch、一小时前的建筑电力能耗值 y(t-1)、二小时前的建筑电力能耗值 y(t-2)；输出项即预测目标为建筑物的小时级电力需求 WBE(Whole

building electrical energy) ; 根据映射神经网络存在定理 (Kolmogorov), BP 神经网络模型的隐含层神经元个数 = $\sqrt{\text{输入神经元个数} + \text{输出神经元个数} + 1} + a$, a 为定义在 [1, 10] 之间的一个整数常量, 本例中隐含层神经元个数介于 4 至 15 之间, 结合实际应用, 确定隐含层神经元个数为 5。

[0061] 步骤 2. 微粒群算法优化 BP 神经网络的连接权值和阈值。具体步骤如下：

[0062] 步骤 2.1 种群初始化 : 本例中, 微粒的位置定义域设置为 [-1, 1]、速度定义域设为 [-1, 1], 个体历史最优位置 $p_j(t)$ 等于各微粒的初始位置 (微粒的初始位置及速度在其定义域中随机选择); 参数初始化 : 本例中, 种群规模设置为 20, 惯性权重 w 的定义域设置为 [0.4, 0.9], 认知系数 c1 设置为 2, 社会系数 c2 设置为 1.8, 最大迭代次数设置为 100;

[0063] 步骤 2.2 计算微粒群中各微粒的适应度值, 其公式为 :

$$[0064] \sum_{i=1}^K (|y_{pred,i} - y_{data,i}|)$$

[0065] 这里, $y_{pred,i}$ 表示预测的能耗值, $y_{data,i}$ 表示实际能耗值, K 表示训练数据集的数量 (本例为 3208) ;

[0066] 步骤 2.3 判断计算的微粒适应值是否大于个体或种群历史最优适应值, 是则更新个体或种群历史最优值并记录最优位置, 否则更新微粒的位置和速度, 并判断更新后的位置和速度是否在各自的定义域内, 若超出定义域, 则取定义域的边界值, 否则保持不变; 微粒的位置和速度更新公式为 :

$$[0067] \begin{cases} v_j(t+1) = wv_j(t) + c1r1(p_j(t) - x_j(t)) + c2r2(p_g(t) - x_j(t)) \\ x_j(t+1) = v_j(t+1) + x_j(t) \end{cases}$$

[0068] 这里, $v_j(t)$ 为微粒 j 在第 t 代的速度; $c1, c2$ 为学习因子, 分别代表微粒的认知系数和社会系数; $r1, r2$ 为服从均匀分布的随机数; $x_j(t)$ 为微粒 j 在第 t 代的位置; $p_j(t)$ 为微粒 j 的个体历史最优位置; $p_g(t)$ 为群体历史最优位置; w 为惯性权重, 其表达式 :

$$[0069] w = w_{max} - \frac{w_{max} - w_{min}}{iter_{max}} \times k$$

[0070] 这里, w_{max} 为初始权重值, w_{min} 为最终权重值, k 为当前迭代次数, $iter_{max}$ 为最大迭代次数;

[0071] 步骤 2.4 判断是否满足终止条件 : 若当前迭代次数达到最大迭代次数或网络的训练误差达到精度要求, 则停止迭代, 输出优化结果, 否则, 返回到第 (2) 步继续迭代;

[0072] 步骤 2.5 输出优化结果, 即优化后的 BP 网络的连接权值和阈值。

[0073] 步骤 3. 将归一化后得到的建筑能耗相关数据划分为训练数据集和测试数据集两部分。其中, 训练数据集用来进行 BP 网络训练, 得到输入项到输出项的映射结果, 测试数据集用来表征能耗预测误差 (本例中, 能耗数据共有 4208 组数据, 选取前 76% 的数据, 即 3208 组数据用于 BP 网络训练, 后 24% 的数据, 即 1000 组数据用于网络测试; BP 神经网络的最大迭代数设置为 100, 学习速率设置为 0.001); 使用训练及测试数据对优化前后的 BP 网络分别进行十二次训练和测试, 取其中预测结果最好的五次; 采用标准差 (CV) 作为衡量指标来评价建筑能耗预测精度, 其表达式为 :

$$[0074] CV = \frac{\sqrt{\sum_{i=1}^N (y_{pred,i} - \bar{y}_{data})^2 / N}}{\bar{y}_{data}}$$

[0075] 这里, $y_{pred,i}$ 表示预测的能耗值, $y_{data,i}$ 表示实际能耗值, \bar{y}_{data} 表示测试数据集中的实际能耗值, N 表示测试数据集的数量 (本例为 1000)。

[0076] 为了对比建筑电力能耗预测效果, 选择单一的 BP 网络预测模型为基准。应用本发明提出的能耗预测模型, 建筑电力能耗短期预测的标准差率最多可提高 28.7%, 平均 (预测结果最好五次的平均值) 可提高 15.8%。

[0077] 图 2、图 3 分别为优化前后 BP 网络经仿真得到的建筑能耗预测值与实际能耗值的对比图。图 2 描述了未利用微粒群算法优化 BP 网络前的仿真图, 图 3 描述了利用微粒群算法优化 BP 网络后的仿真图。由图可见, 本发明利用微粒群算法 (PSO) 优化 BP 神经网络的连接权值和阈值, 能够明显改善 BP 网络的结构, 提高建筑能耗的预测精度。

[0078] 上面已经结合具体实施步骤说明了本发明, 然而对于本领域的技术人员来说, 可以在不背离本发明的精神和范围的前提下, 对本发明做出不同的改进和变型。因而落入本发明的权利要求范围内的各种改进和变型, 都应属于本发明的保护范围之内。

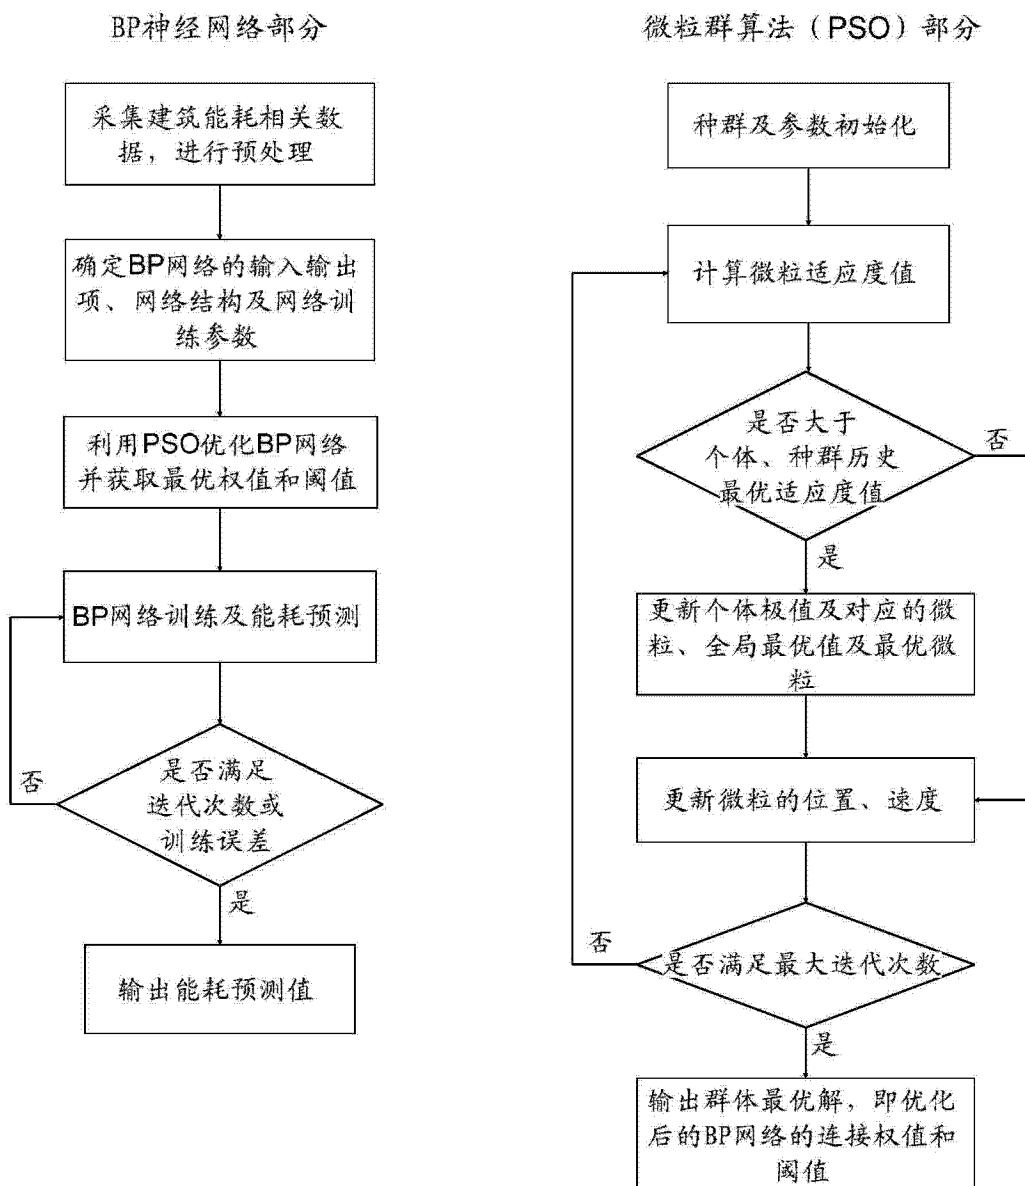


图 1

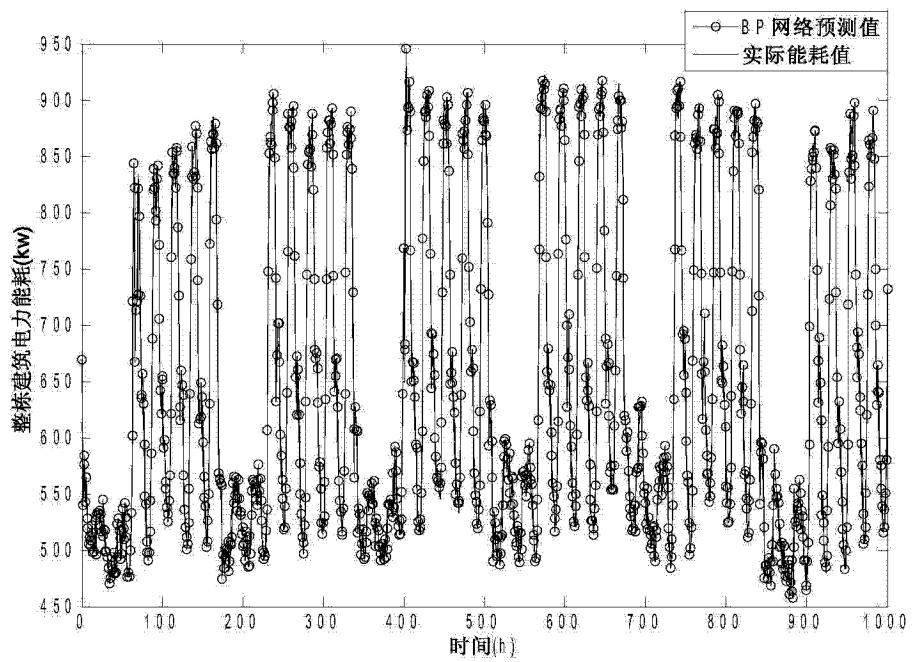


图 2

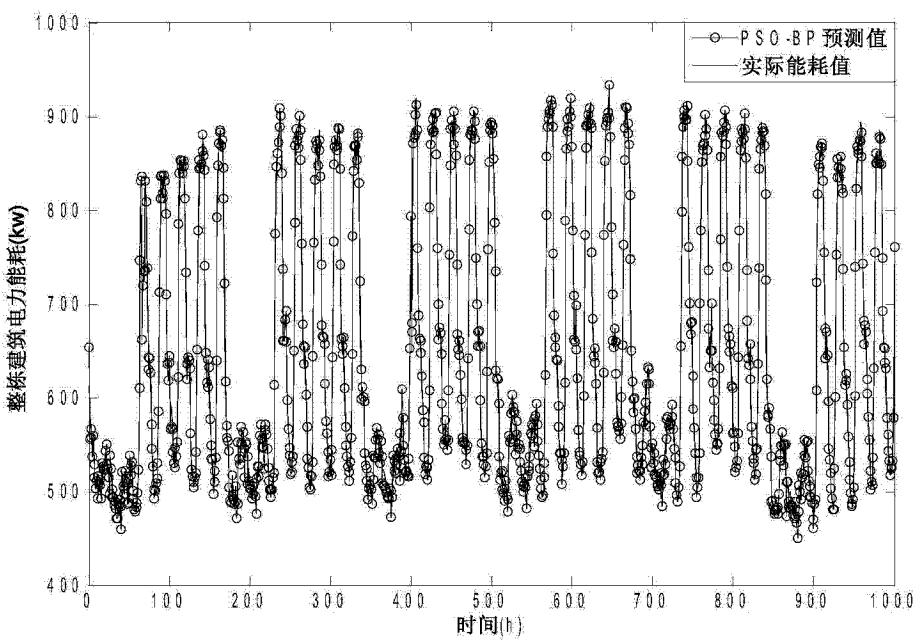


图 3