

基于神经网络的负荷预测方法及装置

技术领域

本发明涉及通信领域，具体而言，涉及一种基于神经网络的负荷预测方法及装置。

背景技术

现有技术中，能源（如蒸汽）供应用户分为工业、商业、居民、办公等，不同用户的蒸汽负荷、负荷量级、负荷特点都不尽相同，负荷预测的准确性关乎优化调度、关乎运营策略。提前进行能源预测可以保证用户的实际用户，同时减少能源的浪费。

现有技术中负荷预测的方法很多，比如指数平滑、Arima、神经网络等，但是单一的负荷预测算法预测准确性欠佳，预测偏差较大，不利于后期调度优化。

针对现有技术中存在的上述问题，目前尚未发现有效的解决方案。

发明内容

本发明实施例提供了一种基于神经网络的负荷预测方法及装置。

根据本发明的一个实施例，提供了一种基于神经网络的负荷预测方法，包括：

接收待预测的时间段；

将所述时间段输入至用于预测能源负荷的神经网络模型，其中，所述神经网络模型是基于混合粒子群算法训练得到的径向基神经网络 RBF；

使用所述神经网络模型预测在所述时间段的能源负荷值。

可选地，在将所述时间段输入至用于预测能源负荷的神经网络模型之前，所述方法还包括：

从第三方获取所述神经网络模型；

使用样本数据训练得到所述神经网络模型。

可选地，使用样本数据训练得到所述神经网络模型包括：

确定初始模型的拓扑结构，其中，所述拓扑结构包括：输入层，隐藏层，输出层；

对所述初始模型的参数进行编码，得到初始粒子种群，其中，所述参数包括：径向基函数的中心参数，方差参数，隐藏层的权重参数，以及输出层的权重参数，每个参数为一个粒子；

解码初始粒子种群，得到所述初始模型的初始参数；

将所述初始参数赋值给所述初始模型，得到 RBF 网络模型；

使用训练样本和测试样本优化所述 RBF 网络模型。

可选地，使用训练样本和测试样本优化所述 RBF 网络模型包括：

将训练样本和测试样本分别输入至所述 RBF 网络模型，得到测试值和期望值；

选择由所述预测值和所述期望值组成的误差矩阵的范数作为适应度值；

使用所述适应度值对种群中的粒子进行更新。

可选地，使用所述适应度值对种群中的粒子进行更新包括：

对种群中的粒子的速度和位置进行更新；

使用所述适应度值对种群中的粒子的个体极值进行更新，使用所述适应度值对种群中的粒子的群体极值进行更新；

对种群中的粒子进行变异操作，当新粒子的适应度值好于旧粒子时才更新粒子时，对粒子进行更新。

可选地，对种群中的粒子的速度和位置进行更新包括：

使用以下公式对种群中的粒子的速度和位置进行迭代更新：

$$V_{id}^{k+1} = wV_{id}^k + c_1r_1(P_{id}^k - X_{id}^k) + c_2r_2(P_{gd}^k - X_{id}^k);$$

$$X_{id}^{k+1} = X_{id}^k + V_{k+1,id};$$

其中, $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ 表示含有 D 维的一个种群粒子, $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ 表示含有 D 维的一个种群粒子的速度, $P_i = (p_{i1}, p_{i2}, \dots, p_{iD})$ 表示含有 D 维的个体粒子极值, $P_g = (p_{g1}, p_{g2}, \dots, p_{gD})$ 表示含有 D 维的群体极值, w 为惯性权重, $d=1, 2, \dots, D$, $i=1, 2, \dots, n$, k 为当前迭代次数, V_{id} 为粒子的速度, c_1, c_2 是非负的常数, 为加速度因子, r_1, r_2 是分布在 $[0,1]$ 的随机数。

根据本发明的另一个实施例, 提供了一种基于神经网络的负荷预测装置, 包括:

接收模块, 用于接收待预测的时间段;

输入模块, 用于将所述时间段输入至用于预测能源负荷的神经网络模型, 其中, 所述神经网络模型是基于混合粒子群算法训练得到的径向基神经网络 RBF;

预测模块, 用于使用所述神经网络模型预测在所述时间段的能源负荷值。

可选地, 所述装置还包括:

确定模块, 用于在所述输入模块将所述时间段输入至用于预测能源负荷的神经网络模型之前, 确定初始模型的拓扑结构, 其中, 所述拓扑结构包括: 输入层, 隐藏层, 输出层;

编码模块, 用于对所述初始模型的参数进行编码, 得到初始粒子种群, 其中, 所述参数包括: 径向基函数的中心参数, 方差参数, 隐藏层的权重参数, 以及输出层的权重参数, 每个参数为一个粒子;

解码模块, 用于解码初始粒子种群, 得到所述初始模型的初始参数;

赋值模块, 用于将所述初始参数赋值给所述初始模型, 得到 RBF 网络模型;

优化模块, 用于使用训练样本和测试样本优化所述 RBF 网络模型。

根据本发明的又一个实施例，还提供了一种存储介质，所述存储介质中存储有计算机程序，其中，所述计算机程序被设置为运行时执行上述任一项方法实施例中的步骤。

根据本发明的又一个实施例，还提供了一种电子装置，包括存储器和处理器，所述存储器中存储有计算机程序，所述处理器被设置为运行所述计算机程序以执行上述任一项方法实施例中的步骤。

通过本发明，采用基于混合粒子群算法训练得到的径向基神经网络预测能源负荷值，通过引入混合粒子群和径向基神经网络的泛化能力强和网络逼近精度高等优点，从而优化出神经网络模型最佳的初始权值和偏置，解决了现有技术中采用单一的负荷预测算法预测能源负荷时准确率低的技术问题，缩小了预测偏差，提高了预测能源负荷的准确率。

附图说明

此处所说明的附图用来提供对本发明的进一步理解，构成本申请的一部分，本发明的示意性实施例及其说明用于解释本发明，并不构成对本发明的不当限定。在附图中：

图1是本发明实施例的一种基于神经网络的负荷预测网络终端的硬件结构框图；

图2是根据本发明实施例的基于神经网络的负荷预测方法的流程图；

图3是根据本发明实施例的基于神经网络的负荷预测装置的结构框图。

具体实施方式

为了使本技术领域的人员更好地理解本发明方案，下面将结合本发明实施例中的附图，对本发明实施例中的技术方案进行清楚、完整地描述，显然，所描述的实施例仅仅是本发明一部分的实施例，而不是全部的实施例。基于本发明中的实施例，本领域普通技术人员在没有做出创造性劳动前提下所获得的所有其他实施例，都应当属于本发明保护的范围。

需要说明的是，本发明的说明书和权利要求书及上述附图中的术语“第一”、“第二”等是用于区别类似的对象，而不必用于描述特定的顺序或先后次序。应该理解这样使用的数据在适当情况下可以互换，以便这里描述的本发明的实施例能够以除了在这里图示或描述的那些以外的顺序实施。此外，术语“包括”和“具有”以及他们的任何变形，意图在于覆盖不排他的包含，例如，包含了一系列步骤或单元的过程、方法、系统、产品或设备不必限于清楚地列出的那些步骤或单元，而是可包括没有清楚地列出的或对于这些过程、方法、产品或设备固有的其它步骤或单元。

实施例 1

本申请实施例一所提供的方法实施例可以在服务器，网络终端、计算机终端或者类似的运算装置中执行。以运行在网络终端上为例，图 1 是本发明实施例的一种基于神经网络的负荷预测网络终端的硬件结构框图。如图 1 所示，网络终端 10 可以包括一个或多个（图 1 中仅示出一个）处理器 102（处理器 102 可以包括但不限于微处理器 MCU 或可编程逻辑器件 FPGA 等的处理装置）和用于存储数据的存储器 104，可选地，上述网络终端还可以包括用于通信功能的传输设备 106 以及输入输出设备 108。本领域普通技术人员可以理解，图 1 所示的结构仅为示意，其并不对上述网络终端的结构造成限定。例如，网络终端 10 还可包括比图 1 中所示更多或者更少的组件，或者具有与图 1 所示不同的配置。

存储器 104 可用于存储计算机程序，例如，应用程序的软件程序以及模块，如本发明实施例中的基于神经网络的负荷预测方法对应的计算机程序，处理器 102 通过运行存储在存储器 104 内的计算机程序，从而执行各种功能应用以及数据处理，即实现上述的方法。存储器 104 可包括高速随机存储器，还可包括非易失性存储器，如一个或者多个磁性存储装置、闪存、或者其他非易失性固态存储器。在一些实例中，存储器 104 可进一步包括相对于处理器 102 远程设置的存储器，这些远程存储器可以通过网络连接至网络终端 10。上述网络的实例包括但不限于互联网、企业内部网、

局域网、移动通信网及其组合。

传输装置 106 用于经由一个网络接收或者发送数据。上述的网络具体实例可包括网络终端 10 的通信供应商提供的无线网络。在一个实例中，传输装置 106 包括一个网络适配器（Network Interface Controller，简称为 NIC），其可通过基站与其他网络设备相连从而可与互联网进行通讯。在一个实例中，传输装置 106 可以为射频（Radio Frequency，简称为 RF）模块，其用于通过无线方式与互联网进行通讯。

在本实施例中提供了一种基于神经网络的负荷预测方法，图 2 是根据本发明实施例的基于神经网络的负荷预测方法的流程图，如图 2 所示，该流程包括如下步骤：

步骤 S202，接收待预测的时间段；

步骤 S204，将时间段输入至用于预测能源负荷的神经网络模型，其中，神经网络模型是基于混合粒子群算法训练得到的径向基神经网络（Radial Basis Function，RBF）；

步骤 S206，使用神经网络模型预测在时间段的能源负荷值。

通过上述步骤，采用基于混合粒子群算法训练得到的径向基神经网络预测能源负荷值，通过引入混合粒子群和径向基神经网络的泛化能力强和网络逼近精度高等优点，从而优化出神经网络模型最佳的初始权值和偏置，解决了现有技术中采用单一的负荷预测算法预测能源负荷时准确率低的技术问题，缩小了预测偏差，提高了预测能源负荷的准确率。

可选地，上述步骤的执行主体可以为数据处理设备，服务器，终端等，具体可以是处理器，算法模块等，但不限于此。

本实施例的应用场景，可以应用在能源预测、流量预测等人工智能的场景中，能源具体可以是热能源，也可以是水、电、气等消耗性能源。本实施例的模型假设如下：

不考虑天气、温度、启停状态等对负荷的影响；

负荷数据为时间序列，变量 1 为时间（输入），变量 2 为负荷值（输出）。

在本实施例中，在将时间段输入至用于预测能源负荷的神经网络模型之前，还需要设置该神经网络模型，包括：从第三方获取神经网络模型，如从供应商购买；使用样本数据训练得到神经网络模型。

在本实施例的一个可选实施方式，使用样本数据训练得到神经网络模型包括：

S11，确定初始模型的拓扑结构，其中，拓扑结构包括：输入层，隐藏层，输出层；

S12，对初始模型的参数进行编码，得到初始粒子种群，其中，参数包括：径向基函数的中心参数，方差参数，隐藏层的权重参数，以及输出层的权重参数，每个参数为一个粒子，用 8bit 二进制码表示，并初始一个在 $[-0.5, 0.5]$ 的随机值。初始模型的参数也叫学习参数。

S13，解码初始粒子种群，得到初始模型的初始参数；

S14，将初始参数赋值给初始模型，得到 RBF 网络模型；

此时的 RBF 网络模型是初级的网络模型，可以进一步训练和优化；

S15，使用训练样本和测试样本优化 RBF 网络模型。先使用训练样本训练 RBF 网络模型，再使用测试样本测试 RBF 网络模型。

神经网络算法的权值和偏置是通过随机初始化 $[-0.5, 0.5]$ 区间的随机数，这个初始化参数对网络训练的影响很大，如何恰当而又准确的获得或设置这些参数是本实施例的一个实施方式。本实施例通过引入混合粒子群和径向基神经网络，具有泛化能力强、网络逼近精度高等优点，从而优化出最佳的初始权值和偏置。

可选的，使用训练样本和测试样本优化 RBF 网络模型包括：将训练样本和测试样本分别输入至 RBF 网络模型，得到测试值和期望值；选择由预测值和期望值组成的误差矩阵的范数作为适应度值；使用适应度值对

种群中的粒子进行更新。

在本实施例中，粒子算法更新涉及到的参数为：速度，位置，个体极值，种群的群体极值等。使用适应度值对种群中的粒子进行更新包括：

S21，对种群中的粒子的速度和位置进行更新；

在一个可选的实施方案中，对种群中的粒子的速度和位置进行更新包括：使用以下公式对种群中的粒子的速度和位置进行迭代更新：

$$V_{id}^{k+1} = wV_{id}^k + c_1r_1(P_{id}^k - X_{id}^k) + c_2r_2(P_{gd}^k - X_{id}^k);$$

$$X_{id}^{k+1} = X_{id}^k + V_{k+1,id};$$

其中， $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ 表示含有 D 维的一个种群粒子， $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ 表示含有 D 维的一个种群粒子的速度， $P_i = (p_{i1}, p_{i2}, \dots, p_{iD})$ 表示含有 D 维的个体粒子极值， $P_g = (p_{g1}, p_{g2}, \dots, p_{gD})$ 表示含有 D 维的群体极值，w 为惯性权重， $d=1, 2, \dots, D$, $i=1, 2, \dots, n$, k 为当前迭代次数， V_{id} 为粒子的速度， c_1, c_2 是非负的常数，为加速度因子， r_1, r_2 是分布在[0,1]的随机数。

S22，使用适应度值对种群中的粒子的个体极值进行更新，使用适应度值对种群中的粒子的群体极值进行更新；

对种群中个体进行最优交叉，个体粒子通过和个体极值粒子进行交叉更新，交叉方法采用整数交叉法，首先选定两个交叉位置，然后把个体和个体极值进行交叉，对得到的新个体采用了保留优秀个体策略，只有当新粒子适应度值大于旧粒子适应度值时才更新粒子。在另一方面，使用适应度值对种群中的粒子的群体极值进行更新时，对种群进行最优交叉，此步骤和第八操作相似，只是将个体极值换成群体极值。

S23，对种群中的粒子进行变异操作，当新粒子的适应度值好于旧粒子时才更新粒子时，对粒子进行更新。

对种群中的粒子操作进行变异操作，变异操作采用个体内部两位互换方法，首先随机选择变异位置 pos1 和 pos2，然后把两个变异位置互换。对得到的新个体采用了保留优秀个体策略，只有当新粒子适应度值好于旧

粒子时才更新粒子。

在得到新种群后，判断是否满足终止条件，如，是否达到最大迭代次数，满足小于限定的误差。

在实际作业中，为了验证本实施例的能源预测模型，选取 30 天的热负荷预测值（一天 24 小时，每小时对应一个热负荷值，共计 720 个点作为实验数据，其中 20 天的数据作为训练集数据，后 10 天的数据作为测试数据集。实验效果的衡量指标我们选取了平均相对误差 MAPE，均方根误差 RMSE 和偏差率 DR（deviation rate）

平均相对误差 MAPE:

$$MAPE = \frac{1}{n} \sum_{i=1}^n |(y_d(i) - y_t(i)) / y_t(i)| \times 100\%$$

均方根误差 RMSE:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_d(i) - y_t(i))^2}$$

偏差率 DR:

$$DR = \frac{y_d - y_t}{y_t}$$

其中，y_t 代表真实值，y_d 代表预测值，n 代表样本数。

得到的指标数据如表 1 所示:

表 1

评价指标	采用本实施例 算法的指标	采用径向基神经网络指标
RMSE	0.78	1.23
MAPE	3.2%	5.1%
DR	6.7%	9.2%

从上面数据指标可以看出，本实施例的算法模型的效果明显，优于仅采用径向基神经网络算法的方案。

需要说明的是，对于前述的各方法实施例，为了简单描述，故将其都表述为一系列的动作组合，但是本领域技术人员应该知悉，本发明并不受所描述的动作顺序的限制，因为依据本发明，某些步骤可以采用其他顺序或者同时进行。其次，本领域技术人员也应该知悉，说明书中所描述的实施例均属于优选实施例，所涉及的动作和模块并不一定是本发明所必须的。

通过以上的实施方式的描述，本领域的技术人员可以清楚地了解到根据上述实施例的方法可借助软件加必需的通用硬件平台的方式来实现，当然也可以通过硬件，但很多情况下前者是更佳的实施方式。基于这样的理解，本发明的技术方案本质上或者说对现有技术做出贡献的部分可以以软件产品的形式体现出来，该计算机软件产品存储在一个存储介质（如ROM/RAM、磁碟、光盘）中，包括若干指令用以使得一台终端设备（可以是手机，计算机，服务器，或者网络设备等等）执行本发明各个实施例的方法。

实施例 2

在本实施例中还提供了一种基于神经网络的负荷预测装置，该装置用于实现上述实施例及优选实施方式，已经进行过说明的不再赘述。如以下所使用的，术语“模块”可以实现预定功能的软件和/或硬件的组合。尽管以下实施例所描述的装置较佳地以软件来实现，但是硬件，或者软件和硬件的组合的实现也是可能并被构想的。

图 3 是根据本发明实施例的基于神经网络的负荷预测装置的结构框图，如图 3 所示，该装置包括：

接收模块 30，用于接收待预测的时间段；

输入模块 32，用于将所述时间段输入至用于预测能源负荷的神经网络模型，其中，所述神经网络模型是基于混合粒子群算法训练得到的径向基神经网络 RBF；

预测模块 34，用于使用所述神经网络模型预测在所述时间段的能源负

荷值。

可选的，所述装置还包括：确定模块，用于在所述输入模块将所述时间段输入至用于预测能源负荷的神经网络模型之前，确定初始模型的拓扑结构，其中，所述拓扑结构包括：输入层，隐藏层，输出层；编码模块，用于对所述初始模型的参数进行编码，得到初始粒子种群，其中，所述参数包括：径向基函数的中心参数，方差参数，隐藏层的权重参数，以及输出层的权重参数，每个参数为一个粒子；解码模块，用于解码初始粒子种群，得到所述初始模型的初始参数；赋值模块，用于将所述初始参数赋值给所述初始模型，得到 RBF 网络模型；优化模块，用于使用训练样本和测试样本优化所述 RBF 网络模型。

需要说明的是，上述各个模块是可以通过软件或硬件来实现的，对于后者，可以通过以下方式实现，但不限于此：上述模块均位于同一处理器中；或者，上述各个模块以任意组合的形式分别位于不同的处理器中。

实施例 3

本发明的实施例还提供了一种存储介质，该存储介质中存储有计算机程序，其中，该计算机程序被设置为运行时执行上述任一项方法实施例中的步骤。

可选地，在本实施例中，上述存储介质可以被设置为存储用于执行以下步骤的计算机程序：

S1，接收待预测的时间段；

S2，将所述时间段输入至用于预测能源负荷的神经网络模型，其中，所述神经网络模型是基于混合粒子群算法训练得到的径向基神经网络 RBF；

S3，使用所述神经网络模型预测在所述时间段的能源负荷值。

可选地，在本实施例中，上述存储介质可以包括但不限于：U 盘、只读存储器（Read-Only Memory，简称为 ROM）、随机存取存储器（Random Access Memory，简称为 RAM）、移动硬盘、磁碟或者光盘等各种可以存

储计算机程序的介质。

本发明的实施例还提供了一种电子装置，包括存储器和处理器，该存储器中存储有计算机程序，该处理器被设置为运行计算机程序以执行上述任一项方法实施例中的步骤。

可选地，上述电子装置还可以包括传输设备以及输入输出设备，其中，该传输设备和上述处理器连接，该输入输出设备和上述处理器连接。

可选地，在本实施例中，上述处理器可以被设置为通过计算机程序执行以下步骤：

S1，接收待预测的时间段；

S2，将所述时间段输入至用于预测能源负荷的神经网络模型，其中，所述神经网络模型是基于混合粒子群算法训练得到的径向基神经网络RBF；

S3，使用所述神经网络模型预测在所述时间段的能源负荷值。

可选地，本实施例中的具体示例可以参考上述实施例及可选实施方式中所描述的示例，本实施例在此不再赘述。

显然，本领域的技术人员应该明白，上述的本发明的各模块或各步骤可以用通用的计算装置来实现，它们可以集中在单个的计算装置上，或者分布在多个计算装置所组成的网络上，可选地，它们可以用计算装置可执行的程序代码来实现，从而，可以将它们存储在存储装置中由计算装置来执行，并且在某些情况下，可以以不同于此处的顺序执行所示出或描述的步骤，或者将它们分别制作成各个集成电路模块，或者将它们中的多个模块或步骤制作成单个集成电路模块来实现。这样，本发明不限制于任何特定的硬件和软件结合。

以上所述仅为本发明的优选实施例而已，并不用于限制本发明，对于本领域的技术人员来说，本发明可以有各种更改和变化。凡在本发明的原则之内，所作的任何修改、等同替换、改进等，均应包含在本发明的保护范围之内。

权 利 要 求 书

1. 一种基于神经网络的负荷预测方法，其特征在于，包括：

接收待预测的时间段；

将所述时间段输入至用于预测能源负荷的神经网络模型，其中，所述神经网络模型是基于混合粒子群算法训练得到的径向基神经网络RBF；

使用所述神经网络模型预测在所述时间段的能源负荷值。

2. 根据权利要求1所述的方法，其特征在于，在将所述时间段输入至用于预测能源负荷的神经网络模型之前，所述方法还包括：

从第三方获取所述神经网络模型；

使用样本数据训练得到所述神经网络模型。

3. 根据权利要求2所述的方法，其特征在于，使用样本数据训练得到所述神经网络模型包括：

确定初始模型的拓扑结构，其中，所述拓扑结构包括：输入层，隐藏层，输出层；

对所述初始模型的参数进行编码，得到初始粒子种群，其中，所述参数包括：径向基函数的中心参数，方差参数，隐藏层的权重参数，以及输出层的权重参数，每个参数为一个粒子；

解码初始粒子种群，得到所述初始模型的初始参数；

将所述初始参数赋值给所述初始模型，得到RBF网络模型；

使用训练样本和测试样本优化所述RBF网络模型。

4. 根据权利要求3所述的方法，其特征在于，使用训练样本和测试样本优化所述RBF网络模型包括：

将训练样本和测试样本分别输入至所述RBF网络模型，得到测试值和期望值；

选择由所述预测值和所述期望值组成的误差矩阵的范数作为适应度值；

使用所述适应度值对种群中的粒子进行更新。

5. 根据权利要求4所述的方法，其特征在于，使用所述适应度值对种群中的粒子进行更新包括：

对种群中的粒子的速度和位置进行更新；

使用所述适应度值对种群中的粒子的个体极值进行更新，使用所述适应度值对种群中的粒子的群体极值进行更新；

对种群中的粒子进行变异操作，当新粒子的适应度值好于旧粒子时才更新粒子时，对粒子进行更新。

6. 根据权利要求5所述的方法，其特征在于，对种群中的粒子的速度和位置进行更新包括：

使用以下公式对种群中的粒子的速度和位置进行迭代更新：

$$V_{id}^{k+1} = wV_{id}^k + c_1r_1(P_{id}^k - X_{id}^k) + c_2r_2(P_{gd}^k - X_{id}^k);$$

$$X_{id}^{k+1} = X_{id}^k + V_{k+1,id};$$

其中， $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ 表示含有D维的一个种群粒子， $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ 表示含有D维的一个种群粒子的速度， $P_i = (p_{i1}, p_{i2}, \dots, p_{iD})$ 表示含有D维的个体粒子极值， $P_g = (p_{g1}, p_{g2}, \dots, p_{gD})$ 表示含有D维的群体极值，w为惯性权重， $d=1, 2, \dots, D, i=1, 2, \dots, n, k$ 为当前迭代次数， V_{id} 为粒子的速度， c_1, c_2 是非负的常数，为加速度因子， r_1, r_2 是分布在 $[0,1]$ 的随机数。

7. 一种基于神经网络的负荷预测装置，其特征在于，包括：

接收模块，用于接收待预测的时间段；

输入模块，用于将所述时间段输入至用于预测能源负荷的神经网络模型，其中，所述神经网络模型是基于混合粒子群算法训练得到的径向基神经网络RBF；

预测模块，用于使用所述神经网络模型预测在所述时间段的能源负荷值。

8. 根据权利要求7所述的装置，其特征在于，所述装置还包括：

确定模块，用于在所述输入模块将所述时间段输入至用于预测能源负荷的神经网络模型之前，确定初始模型的拓扑结构，其中，所述拓扑结构包括：输入层，隐藏层，输出层；

编码模块，用于对所述初始模型的参数进行编码，得到初始粒子种群，其中，所述参数包括：径向基函数的中心参数，方差参数，隐藏层的权重参数，以及输出层的权重参数，每个参数为一个粒子；

解码模块，用于解码初始粒子种群，得到所述初始模型的初始参数；

赋值模块，用于将所述初始参数赋值给所述初始模型，得到RBF网络模型；

优化模块，用于使用训练样本和测试样本优化所述RBF网络模型。

9. 一种存储介质，其特征在于，所述存储介质中存储有计算机程序，其中，所述计算机程序被设置为运行时执行所述权利要求1至6任一项中所述的方法。

10. 一种电子装置，包括存储器和处理器，其特征在于，所述存储器中存储有计算机程序，所述处理器被设置为运行所述计算机程序以执行所述权利要求1至6任一项中所述的方法。