

基于 ESN 和改进 RBFNN 的城市燃气负荷预测^①



徐 场, 徐晓钟

(上海师范大学 信息与机电工程学院, 上海 201400)

通讯作者: 徐 场, E-mail: yzxybb@163.com

摘 要: 城市燃气负荷预测是城市燃气管网系统运行调度中的重要内容. 针对燃气负荷数据的周期性和非线性特点, 以及单一模型存在的局限性, 本文提出一种 ESN 和改进 RBF 神经网络的组合预测模型. 首先用核 Fisher 线性判别对原始数据进行降维, 其次用 ESN 模型进行初步预测, 然后将 ESN 的预测结果作为 RBF 神经网络的输入来构建组合模型, 并将差分进化算法和梯度下降算法结合, 对 RBF 神经网络的结构和参数同时进行训练和优化, 以增强算法的局部搜索能力, 加快收敛速度. 实验结果表明, 本文模型比原组合模型的预测精度更高.

关键词: 核 Fisher 线性判别; ESN; RBF 神经网络; 差分进化; 梯度下降; 组合模型; 燃气负荷预测

引用格式: 徐场, 徐晓钟. 基于 ESN 和改进 RBFNN 的城市燃气负荷预测. 计算机系统应用, 2019, 28(3): 28-35. <http://www.c-s-a.org.cn/1003-3254/6798.html>

City Gas Load Forecasting Based on ESN and Improved RBFNN

XU Yang, XU Xiao-Zhong

(College of Information and Mechanical Engineering, Shanghai Normal University, Shanghai 201400, China)

Abstract: City gas load forecasting is significant to the operation of city gas networks. In consideration of the periodicity and nonlinearity of gas load data and the shortcomings of a single model, a hybrid model of Echo State Network (ESN) and improved RBF Neural Network (RBFNN) is put forward. First of all, kernel Fisher linear discriminant is utilized for dimension reduction. Secondly, we adopt ESN to do a preliminary prediction. Then, differential evolution integrated with gradient descent by encoding is used to learn and optimize the structure and parameters of RBFNN. Last but not least, the produced result of ESN is the input of RBFNN. It is validated that the proposed model has a higher precision and convergence rate compared with the initial combinational model.

Key words: kernel Fisher linear discriminant; Echo State Network (ESN); RBF Neural Network (RBFNN); differential evolution; gradient descent; hybrid model; gas load forecasting

在倡导低碳生活的背景下, 燃气作为一种清洁能源, 加大其在能源消耗中的比重, 已成为建设生态文明的重点之一. 燃气负荷的变化规律是燃气工业发展和决策的基础, 科学地预测燃气负荷不仅满足经济发展的需要, 还对燃气资源的优化调度、燃气管网的建设 and 投资方案的决定具有重要意义.

神经网络的建模过程是非线性的, 模型本身具有良好的自适应性. 它不仅像传统预测方法那样考虑负荷曲线的变化趋势, 还考虑影响负荷的外在因素, 如天气、温度、日期类型等. 再者, 传统方法只能分析一维的情况, 难以对非线性情况进行分析, 而实际的燃气负荷曲线大多是非线性的, 所以与传统预测方法相比, 基

① 基金项目: 上海市科委项目 (11510502400)

Foundation item: Shanghai Municipal Science and Technology Commission Project (11510502400)

收稿时间: 2018-09-01; 修改时间: 2018-09-26; 采用时间: 2018-10-08; csa 在线出版时间: 2019-02-22

于神经网络的预测方法精度更高,具有更好的发展前景.

回声状态网络 (Echo State Network, ESN) 由 Jaeger 于 2001 年提出^[1], 是一种简化的递归神经网络 (Recurrent Neural Network, RNN). 近年来, ESN 已被广泛用于电力预测^[2,3], 风速预测^[4,5]和风电功率预测^[6]等领域, 而燃气负荷预测领域却用得较少. 文献^[7,8]研究了 ESN 在时间序列预测领域的应用, 而燃气负荷数据属于时间序列的范畴, 因此, 将 ESN 模型用于燃气负荷预测将会是一个可行的方法. 与此同时, ESN 负荷预测模型具有较高的稳定性, 与标准 RNN 相比, 它最大的优点就是只需要训练输出权值, 学习速度快, 不易陷入局部最优解.

但是, 本文所用的燃气历史数据包括日期 (年、月、日)、天气、星期几、最高温度、最低温度、平均温度和历史负荷值, 是高维数据, 而 ESN 算法针对高维矩阵的训练是不可逆的, 所以要先将历史数据进行降维处理^[9]. 众所周知, 主成分分析 (Principal Component Analysis, PCA) 和线性判别分析 (Linear Discriminant Analysis, LDA) 是两种常用的降维方法. 两种方法最大的区别在于, LDA 是有监督的算法, 而 PCA 是无监督的. PCA 算法没有考虑数据的标签, 即数据的类别, 只是把原始数据映射到一些方差比较大的方向上. LDA 算法则考虑了数据的类别属性. 因此, 在有多类数据的情况下, PCA 算法的性能很差, 难以将不同类别的数据区分开.

Fisher LDA 对数据的分布做了一些很强的假设, 例如每个类的数据都是高斯分布, 各个类的协方差相等. 虽然这些假设在实际数据中很可能不满足, 但 Fisher LDA 已被证明是非常有效的降维算法, 原因是线性模型对于噪音的鲁棒性比较好, 不容易产生过拟合. 但 Fisher LDA 也存在局限性, 就是模型简单, 表达能力相对较弱. 为了提高 Fisher LDA 算法的表达能力, 我们可以先将数据非线性地投影到特征空间 F 内, 然后在这个 F 空间内计算 Fisher 线性判别式, 从而达到降维的目的. 但是, 当 F 空间的维数非常高时, 单纯地将原数据投影到 F 空间是庞大的计算量. 文献^[10-12]利用核函数 (kernel function), 在不使用显式方式的情况下对数据进行投影. 这样, 我们就无需将原数据投影到 F 空间, 只需将原 Fisher 线性判别式转化成点乘的形式, 仅仅计算由核函数表示的线性判别式即可. 常用的核函数有线性核函数, Polynomial 核函数, Gaussian

核函数 (也叫 RBF 核函数) 和 Sigmoid 核函数. 本文选用的是高斯核函数, 一方面, 高斯核最常用, 尤其对于非线性数据; 另一方面, RBF 可以有效避免样本范数的影响.

本文先使用高斯核 Fisher 线性判别对燃气数据进行预处理, 再将得到的数据输入 ESN 模型, 得到初步预测结果.

此外, 本文选用了 RBF 神经网络 (径向基函数神经网络, Radial Basis Function Neural Network, RBFNN), 将 ESN 与 RBF 相结合, 提出一个组合模型, 并将 ESN 的预测结果作为 RBFNN 的输入数据, 可以进一步提高预测精度. 相较于常用的 BP 神经网络 (Back Propagation Neural Network, BPNN), RBFNN 弥补了 BPNN 易陷入局部极小值的缺点, 且 RBFNN 的层数更少, 需要确定的权重参数更少, 收敛速度也就更快. 关于 RBF 神经网络的基函数数目和中心, 即隐含层节点数和隐含层中心, 以及连接权值的确定, 一直存在一定的困难. 学者们针对这一问题, 做出了研究, 也提出了一些较可行的方法. 文献^[13]将遗传算法与 RBF 神经网络相结合, 以优化扇形孔, 提高薄膜的冷却性能. 文献^[14]结合和声算法和 RBF 神经网络各自的优点, 建立功能更加完善的和声改进的 RBF 神经网络, 实现对出水水质 COD 指标的检测. 文献^[15]利用改进的粒子群优化算法对 RBF 神经网络不同的隐含层函数和网络参数进行学习. 这类传统算法虽然具有较强的随机优化能力, 但是比较容易过早地收敛, 局部寻优能力有待提高.

差分进化 (Differential Evolution, DE) 算法^[16,17]是一种新兴的进化计算, 和遗传算法 (Genetic Algorithm, GA)^[18]一样, 包括交叉操作和变异操作, 但 DE 用一对一的淘汰机制代替遗传算法的选择操作, 让个体之间相互竞争, 以此更新种群, 这使得 DE 比 GA 更易操作. 除此之外, DE 具有强大的记忆功能, 可以动态跟踪搜索情况, 随时对优化策略做出适当的调整, 因此它的鲁棒性更好, 全局搜索能力也较强. 然而, DE 对局部的搜索能力有限, 当需要优化的参数数目较多时, 网络训练时间较长, 为了解决这一问题, 本文参照文献^[19]的方法, 引入梯度下降算法, 将差分进化算法强大的全局搜索能力和梯度下降算法强大的局部搜索能力结合, 采用混合编码的方法对隐含层节点数和其他参数进行编码, 运用混合进化算法对 RBFNN 的结构和参数同时

进行训练和优化。

实验最后,为了验证该模型的性能,将该模型与 SVM (Support Vector Machine, 支持向量机)、BPNN 和 ESN-RBF 进行对比,比较它们的 MAE(平均绝对误差)、RMSE(均方根误差)、MAPE(平均绝对百分误差)。

1 数据预处理

本文数据来源是上海市吴淞地区 2010 年 4 月 27 日到 2014 年 4 月 30 日每一天的实际燃气负荷值、日期(年、月、日)、天气、最高温度、最低温度、平均温度和日期类型。其中,日期类型指的是星期几,天气指的是阴、晴、雨和多云等等天气状况,需先将它们分别按表 1,表 2 的方式进行量化处理。

表 1 日期类型量化方式

日期类型	星期一	星期二	星期三	星期四	星期五	星期六	星期日
量化值	1	2	3	4	5	6	7

表 2 天气类型量化方式

天气类型	晴	多云	多云到阴	阴到多云	阴	阴有雨	中雨	大雨	雪
量化值	1	2	3	4	5	6	7	8	9

如前文所述,本文使用高斯核 Fisher 线性判别对燃气数据进行预处理,无需将原数据投影到特征 F 空间,只需计算由核函数表示的线性判别式即可,从而增强了简单 Fisher LDA 的表达力。

数据预处理后,选用的输入值有预测日的日期类型,预测日前两天的负荷值和预测日的平均温度,模型的输出值是预测日的负荷值。数据集的前 800 条数据作为训练集用于建立预测模型,第 801-1100 条数据作为测试集,用于检验预测模型的性能。

2 ESN 模型概述及预测

2.1 ESN 模型概述

ESN 由输入层,储备池,输出层组成(如图 1),三层的节点数分别为 K 、 N 和 L 。其中, $U(m)$ 、 $X(m)$ 和 $Y(m)$ 分别表示 m 时刻的输入、储备池状态和输出, W_{in} 、 W 和 W_{out} 分别表示输入层到储备池的连接权值、储备池到下一个时刻储备池状态的连接权值和储备池到输出层的连接权值。

2.1.1 ESN 特点

ESN 的中心思想是:先用输入信号激发储备池的状态响应信号,即“回声信号”;再用“回声信号”的线性组合逼近期望的输出信号^[20]。

ESN 的特点主要有以下三个:

(1) 储备池 (Reservoir) 是 ESN 的核心内容。ESN 的储备池是随机生成的,其中包含大量稀疏连接的神经元,通过调整其内部权值,可以使网络具备短期记忆的能力。

(2) ESN 的输出权值是唯一需要调整的部分。ESN 的 W_{in} 和 W 是随机生成的,且一经生成就保持不变,因此,训练 ESN 就是训练储备池到输出层的连接权值 W_{out} 。

(3) 简单的线性回归就可完成网络的训练。




图 1 ESN 结构

2.1.2 ESN 的状态方程

m 时刻,输入层,中间层(储备池),输出层的状态序列分别是:

$$U(m) = [U_1(m), U_2(m), \dots, U_K(m)]^T \quad (1)$$

$$X(m) = [X_1(m), X_2(m), \dots, X_N(m)]^T \quad (2)$$

$$Y(m) = [Y_1(m), Y_2(m), \dots, Y_L(m)]^T \quad (3)$$

ESN 的储备池内部单元的状态更新方程为:

$$X(m+1) = f_{in}(W_{in} \cdot U(m+1) + W \cdot X(m)) \quad (4)$$

ESN 的输出单元的状态更新方程为:

$$Y(m+1) = f_{out}(W_{out} \cdot (U(m+1), X(m+1), Y(m))) \quad (5)$$

其中, $f_{in} = (f_1, f_2, \dots, f_N)$ 为隐含层内部神经元激活函数,一般取 Sigmoid 函数; $f_{out} = (f_1, f_2, \dots, f_L)$ 为输出层激活函数,一般取线性函数。

2.1.3 储备池的四个参数

储备池的 4 个参数决定了 ESN 的最终性能,这 4 个参数分别是:

(1) 储备池规模 N 。它的值是储备池中的神经个数。储备池规模越大,网络对给定系统的动态描述则越准

确,但同时可能导致过拟合。

(2) 储备池谱半径 SR (Spectral Radius). 它的值是连接权值矩阵 W 的绝对值最大的那个特征值, 记为 λ_{MAX} , 要保证网络稳定, λ_{MAX} 必须小于 1, 此时 ESN 具有回声状态属性。

(3) 储备池伸缩尺度 SE (Scale of Expansion). 它表示的是输入信号与储备池内部神经元连接之前需要乘的一个尺度因子。通常情况下, 输入信号的非线性越强, 伸缩尺度越大。

(4) 储备池稀疏度 S (Sparsity). 它表示的是储备池内部神经元之间的连接程度, 因为并不是所有神经元都是彼此相连的。 S 的值是相互连接的神经元数与神经元总数 N 的比值取百分数, S 的值越大, 非线性逼近能力越强。

2.1.4 ESN 的训练过程

正如前文所述, ESN 的训练过程就是根据给定的样本训练输出权值 W_{out} 。具体流程如下:

Step 1. 确定网络的初始参数。这一步骤不仅包括确定储备池的规模 N 、谱半径 SR 、伸缩尺度 SE 、稀疏度 S 和激活函数, 还包括生成权值矩阵 W_{in} 和 W 。

Step 2. 将训练样本依次加载到输入单元, 并按 SE 进行伸缩。

Step 3. 更新并收集状态方程和矩阵。根据式 (4) 更新。为了避免初始状态的影响, 从 r 时刻开始, 按照式 (6) 收集每个样本的输入 $U(m)$ 和状态 $X(m)$ 构成矩阵 T 。

$$T = \begin{bmatrix} X_1(r) & \cdots & X_N(r) & U(r) \\ X_1(r+1) & \cdots & X_N(r+1) & U(r+1) \\ X_1(r+2) & \cdots & X_N(r+2) & U(r+2) \\ \vdots & \cdots & \vdots & \vdots \\ X_1(m) & \cdots & X_N(m) & U(m) \end{bmatrix} \quad (6)$$

Step 4. 同理, 按照式 (7) 收集 r 时刻开始, 每个样本的期望输出 Y 。

$$Y = [f_{out}(Y(r)), f_{out}(Y(r+1)), \cdots, f_{out}(Y(m))]^T \quad (7)$$

Step 5. 计算输出权值 W_{out} 。根据式 (8) 计算输出权值。

$$W_{out} = (T^{-1} \times Y)^T \quad (8)$$

2.2 ESN 预测

前 800 条历史数据经预处理后, 输入 ESN 模型, 进行训练。本节使用 MATLAB 编写代码实现 ESN 预测, 储备池规模 N 通常可设为几十到上千; 输入层到储

备池的连接权值和储备池到输出层的连接权值在网络初始化时随机产生, 且范围是均匀分布的 $[-1, 1]$; 为确保 ESN 具有回声状态属性, 储备池谱半径 SR 要小于 1。

建模过程完成后, 用第 801–1100 条历史数据测试建成的模型, 结果如图 2 所示。横轴表示 300 个样本, 纵轴表示负荷值, 从图中可以看出, 预测曲线可以大致拟合实际负荷值的走势。




图 2 ESN 网络预测曲线图

3 基于混合进化算法的 RBFNN 模型概述及预测

RBF 神经网络通常只有三层 (如图 3), 每一层发挥着不同的作用。第一层是输入层, 由一些感知单元组成, 作用是将外界环境与网络相连; 第二层是隐含层, 作用是完成从输入空间到隐层空间的非线性变换, 与一般的神经网络不同, RBF 神经网络的隐含层只有一层; 最后一层是输出层, 它通常由简单的线性函数组成, 作用是作用于输入层的激活模式提供响应。

RBF 神经网络的中间层神经元的激活函数是径向基函数, 最常用的是高斯核函数:

$$f_i(x) = \exp\left(-\frac{\|x - a_i\|^2}{\sigma^2}\right), \quad i = 1, 2, \cdots, Z \quad (9)$$

其中, $f_i(x)$ 为隐含层的输出, x 为网络的输入值, a_i 为隐含层中第 i 个节点的基函数的中心值, σ 为高斯函数的方差, 它决定了基函数的宽度, Z 为隐含层节点的个数。

RBF 神经网络预测方法首先将低维形式的输入映射到中间层的高维空间, 其次由隐含层选择径向基函数进行转换, 然后在输出层进行分类处理, 计算出线性组合, 从而实现输入到输出的映射关系, 该模型需调节

的参数就是决定基函数形状的参数和线性组合的权值。




图3 RBF神经网络的结构

设 RBF 预测模型输出层只有一个节点,即为预测结果.输出可表示成:

$$y = \sum_{i=1}^Z \omega_i f_i(x) + b_i \quad (10)$$

其中, ω_i 为隐含层到输出层的权值, b_i 为偏置项。

3.1 基于混合进化算法的 RBFNN 概述

进化算法的本质是模拟大自然生物的进化过程,通过交叉、选择和变异等机制,自适应地随机搜索问题的最优解,它的全局搜索能力较强,适用于 RBF 神经网络参数的优化.差分进化 (DE) 算法是一种简单有效的全局优化启发式算法,主要包括初始化、交叉、选择和变异操作.本文用 DE 算法搜索最优参数,其步骤可以参考文献[13]中遗传算法的基本步骤。

可是,当参数数目较多时,单纯采用差分进化算法进行优化易导致收敛速度过慢,为了解决这一问题,本文引入梯度下降算法,结合两种方法的优点,提出一种混合进化算法对 RBF 网络结构和参数进行训练和优化。

3.1.1 混合编程

该预测模型的关键是要确定基函数的中心 a_i , 宽度 σ 和节点数 Z , 还有隐含层到输出层的权值 ω_i . 为了降低计算复杂度,本文先确定基函数的数目,中心和宽度,再用递推最小二乘法求解隐层到输出层的权值构成的线性方程组,得到 ω_i 的值.为使得网络可以自动

选择参数,本文采用对每个节点同时进行二进制编码和实数编码,其中,对基函数的中心和宽度采用实数编码,对节点采用二进制编码。

进化算法主要依赖适应度函数来决定个体能否进化到下一代.以往的适应度大小常常是训练集的误差,这会导致为了追求误差尽可能地小而产生过拟合的现象,从而使得测试误差很大.本文将训练集 P 和测试集 Q 的加权作为个体的适应度大小,并定义训练误差 E_P 和测试误差 E_Q 分别为:

$$E_P = \frac{1}{N_P} \sum_{j=1}^{N_P} (y_j - \hat{y}_j)^2 \quad (11)$$

$$E_Q = \frac{1}{N_Q} \sum_{j=1}^{N_Q} (y_j - \hat{y}_j)^2 \quad (12)$$

其中, N_P 为训练集 P 的样本数, N_Q 为训练集 Q 的样本数, y_j 为实际负荷值, \hat{y}_j 为模型预测值。

故将此问题转化成计算一组使得式 (13) 的值最小的参数:

$$E = \mu E_P + (1 - \mu) E_Q \quad (13)$$

其中, μ 为权重,且满足 $\mu \in [0, 1]$ 。

要满足式 (13) 的值最小,就是要求 E_P 和 E_Q 中较小的那个所占的权重大.即:要求训练误差较小时, μ 取较大的值;要求测试误差较小时, μ 取较小的值.将式 (13) 作为本文的适应度函数,可以直观地反映出个体的性能,从而决定其是否可以进化到下一代.式 (13) 的根本目的是寻找 RBF 网络的最优参数,该方法可以在保证误差精度的前提下,提高 RBF 网络的泛化能力。

3.1.2 差分进化^[21]

差分进化算法包括初始化,变异,交叉,选择这四个机制:

1) 初始化 (Initialization)

这一步,有几个参数需要随机赋予初值,包括种群规模 NP , 向量 $x_i^j (i=1, 2, \dots, NP, j=1, 2, \dots, D_M)$ 的维度 D_M , 缩放和变异因子 F , 交叉概率常数 CR , 个体值范围 $[G_L, G_U]$. 该种群按式 (14) 进行初始化:

$$x_i^j = G_L + \text{rand}[0, 1] \times (G_U - G_L) \quad (14)$$

其中, G_U 和 G_L 分别表示个体值的上界和下界, $\text{rand}[0, 1]$ 表示区间 $[0, 1]$ 上的随机数。

2) 变异 (Mutation)

随机选取种群中两个不同的基向量,作相减操作,

得到差分向量, 再将差分向量进行缩放, 加到另一个随机基向量上, 产生变异向量, 这一过程被称作变异. 这一过程可以用式 (15) 表示:

$$V_i^{t+1} = X_{r3}^t + F \times (X_{r1}^t - X_{r2}^t) \quad (15)$$

其中, t 表示第 t 代, $r1, r2, r3$ 为 $[1, NP]$ 上的三个随机数, V 为变异向量, X 为个体向量.

3) 交叉 (Crossover)

将变异向量 V 与个体向量 X 进行参数混合, 生成试验向量 U , 这一过程被称作交叉. 这一过程可以用式 (16) 表示:

$$U_{ij}^{t+1} = \begin{cases} V_{ij}^{t+1}, & \text{rand}[0, 1] \leq CR \\ X_{ij}^t, & \text{otherwise} \end{cases} \quad (16)$$

其中, $CR \in [0, 1]$, 其值在初始化步骤中给出. $\text{rand}[0, 1]$ 用来确保试验向量至少有一维变量是由变异向量贡献的, 否则试验向量有可能与个体向量相同, 这样就不能生成新个体.

4) 选择 (Selection)

如果试验向量的适应度优于个体向量的适应度, 则用试验向量取代个体向量, 产生下一代, 这一过程被称作选择. 这一过程可以用式 (17) 表示:

$$X_i^{t+1} = \begin{cases} U_i^{t+1}, & f(U_i^{t+1}) < f(X_i^t) \\ X_i^t, & \text{otherwise} \end{cases} \quad (17)$$

3.1.3 梯度下降

每次进化后都会产生新的种群, 从中选取适应度较好的 R 个个体, 以概率 P_R 进行梯度下降迭代操作, 可以提高算法的局部搜索能力, 加快网络的收敛速度.

3.1.4 混合进化算法流程

采用混合进化算法改进的 RBF 神经网络的算法流程如图 4.

RBF 神经网络模型的关键是确定基函数的中心、宽度和节点数, 本文所采用的实数编码和二进制编码方式可以使得网络自动选择参数, 随机生成初始种群. 本文使用的适应度函数——式 (13) 不同于以往计算适应度的方法, 本文采用的是训练误差和测试误差的加权, 这样不仅可以直观反映出个体能否进化到下一代, 还可以在精度范围内避免过拟合, 提高网络的泛化能力. 此外, 本文引入的梯度下降算法, 其强大的局部搜索能力与进化算法强大的全局搜索能力相结合, 可以进一步加快网络的收敛速度.

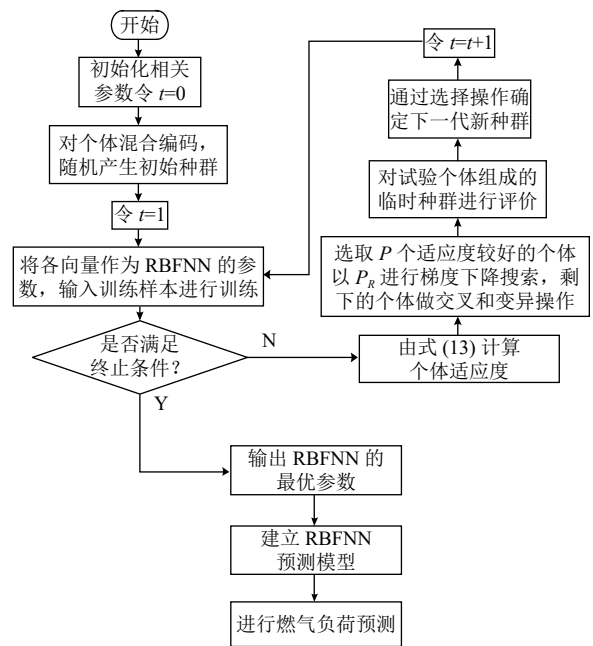


图 4 改进 RBFNN 的算法流程图

3.2 基于混合进化算法的 RBFNN 预测

将 ESN 的预测结果作为 RBF 神经网络的输入来构建组合模型, 其预测结果如图 5 所示. 横轴表示 300 个样本, 纵轴表示负荷值, 从图中可以看出, ESN 和 RBF 神经网络的组合模型的预测精度高于单一的 ESN 模型.




图 5 ESN-RBF 神经网络预测曲线图

本文选取混合进化算法的参数 (参数由实验得出, 由于文章篇幅原因, 不在此赘述过程) 为: 种群规模 $NP=300$, $R=20$, $P_R=0.5$, 预测结果如图 6 所示. 横轴表示 300 个样本, 纵轴表示负荷值, 从图中可以看出, 除了某

几个突变的时刻, 曲线出现尖峰点, 拟合效果稍有欠缺, 对于大多数样本来说, 预测值和实际负荷值的误差相对在一个可接受的范围内, 这验证了优化后的组合模型相较于未优化的组合模型, 预测精度有很大的提升.




图6 改进后的 ESN-RBF 神经网络预测曲线图

为了证明本文的组合模型优于单一的 RBF 神经网络模型, 将原始数据输入传统的 RBF 神经网络, 得到如图 7 所示的预测结果. 从图中可以看出, 单一 RBF 神经网络的拟合效果较差. 而本文不仅使用 ESN 和 RBF 的组合模型, 还对 RBF 网络作出了改进, 大大提高了预测精度.




图7 RBF 神经网络预测曲线图

此外, 本文将提出的组合模型与常见的 SVM、BP 神经网络和未优化的组合模型进行对比, 分别计算它们的平均绝对误差、均方根误差和平均绝对百分误

差, 计算方法如式 (18)、式 (19) 和式 (20), 计算结果如表 3 所示.

表3 各模型评估结果对比

	SVM	BPNN	ESN-RBF	本模型
MAE	34 772.5	33 486.8	28 694.4	21 402.5
RMSE	40 352.3	40 073.5	38 720.8	34 257.3
MAPE	0.2038	0.1839	0.1063	0.0985

平均绝对误差 (Mean Absolute Error, MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (18)$$

均方根误差 (Root Mean Square Error, RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (19)$$

平均绝对百分误差 (Mean Absolute Percentage Error, MAPE):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (20)$$

其中, y_i 为真实值, \hat{y}_i 为预测值, n 为样本个数.

根据表 3 的数据, 可以得到以下两点结论:

- 1) 组合模型相较于单一模型, 预测精度更高;
- 2) 经过本文方法优化过的组合模型, 相比于未优化的组合模型, 预测效果有显著的提升.

4 结论与展望

由于燃气负荷具有非线性和周期性, 单一的传统预测模型难以较好地挖掘数据复杂的非线性特征, 本文提出一种基于 ESN 和 RBF 神经网络的组合预测模型, 将 ESN 的预测结果作为 RBF 神经网络的输入, 可以进一步提高预测精度. 同时对 RBF 神经网络混合编码, 将差分进化算法强大的全局搜索能力与梯度下降算法强大的局部搜索能力相结合, 用于 RBF 神经网络的优化. 仿真实验结果对比表明, 本文的方法具有较好的预测效果.

本文的未来研究方向是寻找更有效地确定 ESN 模型参数的方法, 以及对 RBF 神经网络的进化算法内部参数提出新的改进.

参考文献

- 1 Jaeger H. The echo state approach to analysing and training

- recurrent neural networks. Bonn, Germany: German National Research Center for Information Technology GMD Technical Report, 2001, 148(34): 13.
- 2 Wang L, Hu HL, Ai XY, *et al.* Effective electricity energy consumption forecasting using echo state network improved by differential evolution algorithm. *Energy*, 2018, 153: 801–815. [doi: [10.1016/j.energy.2018.04.078](https://doi.org/10.1016/j.energy.2018.04.078)]
 - 3 Li G, Li BJ, Yu XG, *et al.* Echo state network with Bayesian regularization for forecasting short-term power production of small hydropower plants. *Energies*, 2015, 8(10): 12228–12241. [doi: [10.3390/en81012228](https://doi.org/10.3390/en81012228)]
 - 4 Liu D, Wang JL, Wang H. Short-term wind speed forecasting based on spectral clustering and optimised echo state networks. *Renewable Energy*, 2015, 78: 599–608. [doi: [10.1016/j.renene.2015.01.022](https://doi.org/10.1016/j.renene.2015.01.022)]
 - 5 López E, Valle C, Allende H, *et al.* Long short-term memory networks based in echo state networks for wind speed forecasting. *Iberoamerican Congress on Pattern Recognition. Cham*. 2017. 347–355.
 - 6 Gouveia HTV, De Aquino RRB, Ferreira AA. Enhancing short-term wind power forecasting through multiresolution analysis and echo state networks. *Energies*, 2018, 11(4): 824. [doi: [10.3390/en11040824](https://doi.org/10.3390/en11040824)]
 - 7 黄标兵. 回声状态网络时间序列预测方法及应用研究[博士学位论文]. 长春: 吉林大学, 2017.
 - 8 许美玲. 基于回声状态网络的多元时间序列预测研究[博士学位论文]. 大连: 大连理工大学, 2016.
 - 9 周志华. 机器学习. 北京: 清华大学出版社, 2016: 229
 - 10 Puthenputhussery A, Liu QF, Liu CJ. Multiple anthropological fisher kernel framework and its application to kinship verification. 2018 IEEE Winter Conference on Applications of Computer Vision. Lake Tahoe, NV, USA. 2018. 57–65.
 - 11 Shi YX, Ren XX, Yang SZ, *et al.* A generalized kernel fisher discriminant framework used for feature extraction and face recognition. 2016 12th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery. Changsha, China. 2016. 1487–1491.
 - 12 Yin Y, Hao YF, Bai Y, *et al.* A Gaussian-based kernel Fisher discriminant analysis for electronic nose data and applications in spirit and vinegar classification. *Journal of Food Measurement and Characterization*, 2017, 11(1): 24–32. [doi: [10.1007/s11694-016-9367-3](https://doi.org/10.1007/s11694-016-9367-3)]
 - 13 Wang CH, Zhang JZ, Zhou JH. Optimization of a fan-shaped hole to improve film cooling performance by RBF neural network and genetic algorithm. *Aerospace Science and Technology*, 2016, 58: 18–25. [doi: [10.1016/j.ast.2016.08.004](https://doi.org/10.1016/j.ast.2016.08.004)]
 - 14 李晋贤, 李少甫, 李洪. 和声改进 RBF 神经网络在污水出水 COD 软测量中的应用. *电子技术与软件工程*, 2017, (5): 34, 35.
 - 15 Wang YY, Li X. Improvement of RBF neural network by AdaBoost algorithm combined with PSO. *Telecommunication Computing Electronics and Control*. 2016, 14(3A): 56–64.
 - 16 Price KV. Differential evolution: a fast and simple numerical optimizer. *Proceedings of North American Fuzzy Information Processing*. New York, NY, USA. 1996.
 - 17 Storn R, Price K. Differential evolution-A simple and efficient heuristic for global optimization over continuous spaces. *Journal of Global Optimization*, 1997, 11(4): 341–359. [doi: [10.1023/A:1008202821328](https://doi.org/10.1023/A:1008202821328)]
 - 18 Eremia M, Liu CC, Edris AA. Genetic algorithms. *Advanced Solutions in Power Systems: HVDC, FACTS, and Artificial Intelligence*. New York: John Wiley & Sons, Inc., 2016.
 - 19 韦建波, 张栋柱, 罗浩杰, 等. 基于改进的 RBF 神经网络的配电网故障诊断模型. *吉首大学学报(自然科学版)*, 2018, 39(1): 54–58.
 - 20 周红标, 王乐, 卜峰, 等. 基于 PSO-WPESN 的短期电力负荷预测方法. *电测与仪表*, 2017, 54(6): 113–119. [doi: [10.3969/j.issn.1001-1390.2017.06.019](https://doi.org/10.3969/j.issn.1001-1390.2017.06.019)]
 - 21 Wang L, Zeng Y, Chen T. Back propagation neural network with adaptive differential evolution algorithm for time series forecasting. *Expert Systems with Applications*, 2015, 42(2): 855–863. [doi: [10.1016/j.eswa.2014.08.018](https://doi.org/10.1016/j.eswa.2014.08.018)]