

DOI: 10.7667/PSPC180274

# 基于粗糙集-混沌时间序列 Elman 神经网络的 短期用电量预测

吴佳懋<sup>1</sup>, 李艳<sup>1</sup>, 符一健<sup>2</sup>

(1. 海南大学, 海南 海口 570228; 2. 赫瑞·瓦特大学, 爱丁堡 EH14 4AS)

**摘要:** Elman 神经网络由于其具有无限逼近和适应时变特性的能力被广泛用于动态数据预测。短期的用电量存在多种不确定影响因素, 为了将所有影响因素考虑其中, 引入混沌时间序列的重构相空间技术。由于神经网络在非线形函数中对于峰值预测偏差较大, 粗糙集理论可以对其做出修正。因此, 引入混沌时间序列理论和粗糙集理论改进 Elman 神经网络并进行建模。模型应用嵌入维度和延迟时间重构相空间恢复原来系统的动力学形态, 将处理好的数据代入 Elman 神经网络进行用电量预测。最后引入粗糙集修正误差较大的峰值点, 提高预测精度。收集了 Heriot-Watt 大学某宿舍楼 30 天的用电量数据, 以 5 min 为计数频率共 8 640 个计数点作为数据集进行预测仿真。预测结果与 Elman 神经网络和混沌时间序列 Elman 神经网络进行对比, 验证了该模型在短时间预测的有效性。

**关键词:** 混沌时间序列; Elman 神经网络; 粗糙集; 用电量预测

## Short-term power consumption prediction based on rough set chaotic time series Elman neural network

WU Jiamao<sup>1</sup>, LI Yan<sup>1</sup>, FU Yijian<sup>2</sup>

(1. Hainan University, Haikou 570228, China; 2. Heriot-Watt University, Edinburgh EH14 4AS, UK)

**Abstract:** Elman neural network is widely used for dynamic data prediction because of its ability to approximate and adapting to time-varying characteristics. There are many uncertain factors in the short-term electricity consumption. In order to take all the factors into account, this paper introduces the reconstruction phase space technology of chaotic time series. Due to the large deviation from the neural network of the peak prediction in nonlinear functions, it can be modified by rough set theory. Therefore, the chaotic time series theory and rough set theory are introduced to improve the Elman neural network. The model applies embedded dimension and delay time to reconstruct the phase space to restore the original system's dynamic morphology. The processed data is brought into the Elman neural network to predict the electricity consumption. Finally, the peak point corrected by the rough set is introduced to improve the prediction accuracy. This paper collects the data from a dormitory building in Heriot-Watt university of Edinburgh. It uses thirty days electricity data with 8 640 points as the data set to do predict simulation. The prediction results are compared with the Elman neural network and chaotic time series Elman neural network, and the validity of the model are verified in a short-time prediction.

This work is supported by National Natural Science Foundation of China (No. 71572126).

**Key words:** chaotic time series; Elman neural network; rough set; prediction of electricity consumption

## 0 引言

精准的用电量预测不仅在实时电力精准调度上起到决策作用, 还是保障电网稳定性、解决电量偏

差、节约能源的有效途径<sup>[1]</sup>。目前, 国家推进从需求为切入点来实现电量偏差控制, 售电公司的焦点便放在用电量预测。下一时刻用户用电量预测的实时性和准确性不但是需求侧管理的实现目标之一, 而且对电力系统安全稳定运行和提高经济效益也具有积极意义。用户短期用电量由于其随机性和不确

基金项目: 国家自然科学基金项目资助(71572126)

定性的特点, 预测方法的选择及其克服随机性的能力高低直接影响到电力实时精准调度的实施质量。

短期用电量预测的方法很多, 大体可以分为三大类: 统计学法、工程学法和智能方法<sup>[2]</sup>。统计学法有回归分析法、时间序列法等运用统计工具进行预测的方法; 工程学法则是将工程理论用于预测建模的方法; 智能方法中主要研究热点是神经网络<sup>[3]</sup>。神经网络有自适应、自组织学习样本的能力, 预测精度较高。文献[4]将 Elman 神经网络用于在线实时预测, 展示了 Elman 神经网络在预测上的实用性。文献[5]在神经网络模型中引入了混沌时间序列, 可以将所有影响因素考虑其中。文献[6]采用互信息法辨识对用户用电量相关联因素进行识别, 建立随机森林预测模型, 该方法有效地规避了用户差异性模式对预测造成的影响, 但由于先聚类后预测, 对于远离聚类中心的离散用户预测精度不高。文献[7]采用主成分分析法辨识并提取特征变量, 建立 Elman 神经网络预测模型, 再应用粗糙集理论对预测值进行修补与修正, 粗糙理论克服了原始数据波动大造成预测偏差较大的问题。文献[8-15]都致力于用电量影响因子的识别, 再将影响因子作为变量, 与原有数据进行预测, 此类方法在一定程度上提高了预测精度, 适用于中长期预测, 因为短期用电量预测存在着极强的随机性, 这种随机性体现在影响因子众多、影响程度难以估量和相关数据的提取难度大。

该模型基于短期用电量的混沌特性, 混沌时间序列相空间重构技术可以使原始时间序列数据所隐含的信息进行还原, 并作为 Elman 神经网络的输入。改进 Elman 神经网络进行参数调整以达到运行速度和预测精度的最优结合, 最后采用粗糙集理论对预测值进行修正, 克服了预测值波动过大导致过大的偏差。

## 1 混沌时间序列

在用电量预测中, 原始数据是单一的时间序列。单一时间序列呈现的是时间和用电量的简单关系, 通过观察发现它们并不是简单的线性关系, 所以在对其进行预测的时候, 非线性系统尤其是混沌系统下产生的时间序列倍受关注。混沌时间序列理论认为, 时间序列里单一变量的演化包含了系统所有变量长期演化的全部信息<sup>[16]</sup>。混沌理论在时间序列上的应用, 给预测提供了新思路。

### 1.1 重构相空间的提出

一个系统在某一时刻的状态称为相, 决定其状态的几何空间称为相空间, 非线性系统的相空间可能存在高维数<sup>[17]</sup>。原始数据是单变量的时间序列,

其是许多影响因子相互作用的综合反映, 蕴藏着参与作用的全部变量的影响痕迹<sup>[18]</sup>。短期的电力负荷时间序列只存在用电负荷量单一变量随时间的演化关系, 但该时间序列也暗含了所有相关影响因素相互作用, 例如同时存在温度、降雨、湿度等因子。Packard 提出了重构相空间理论, 通过利用系统长期演化的任一变量时间序列来研究系统的混沌行为<sup>[19]</sup>。时间序列相空间重构的作用是将时间序列嵌入到更高维的相空间, 使时间序列中的信息充分地显露出来。重构相空间是混沌时间序列中最重要的一步, 其质量直接影响着预测结果。

在相空间的重构上, Taken 定理认为系统中任一影响因素的发展变化都由与之相关的其他影响因素的演化过程决定<sup>[20]</sup>。嵌入定理原理如下: 对于一个测量到的时间序列  $\{x_i, i=1, 2, 3, \dots, n\}$ ,  $n$  代表时间序列的长度。其重构的相空间为  $x_i = \{x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}\}, i=1, 2, \dots, M$ 。则相空间的轨迹可由式(1)表示。

$$X = [X_1, X_2, \dots, X_N] = \begin{bmatrix} x(1) & x(2) & \dots & x(n-(m-1)\tau) \\ x(1+\tau) & x(2+\tau) & \dots & x(n-(m-2)\tau) \\ \vdots & \vdots & \ddots & \vdots \\ x(1+(m-1)\tau) & x(2+(m-1)\tau) & \dots & x(n) \end{bmatrix} \quad (1)$$

式中:  $X_i$  为相空间上的一点;  $m$  为嵌入维度;  $\tau$  为延迟时间。

相空间重构的前提条件是嵌入维度和延迟时间两个重要因素的求解, 其可以恢复原来系统的动力学形态, 使重构的相空间在保留原始数据相互影响关系的条件下, 不产生冗余的信息和噪音。时间序列经过相空间重构之后, 便能从中选取出特征向量进行计算和预测, 这将大大提高数据预测的准确度。

### 1.2 延迟时间的选择

考虑到  $x_i = \{x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}\}$  在重建相空间中作为独立变量, 它们应该彼此独立, 因此在延迟时间的选择上需要仔细甄选。延迟时间  $\tau$  的选择应满足 3 个条件<sup>[21]</sup>:

- 1) 它必须是采样时间的倍数。
- 2)  $\tau$  不可太小, 否则  $x(i)$  和  $x(i+\tau)$  将不足以独立, 重构的吸引子会围绕对角线累积, 无法看到动态的展开。
- 3)  $\tau$  不可太大, 否则  $x(i)$  和  $x(i+\tau)$  之间的任何连接在数值上相当于随机。

延迟时间的求解方法有自相关法、改进自相关法、互信息法等。互信息法是较为常用的方法, 互

信息函数是两个随机变量间一般性包括线性和非线性随机关联的度量, 是非线性的分析方法。互信息法利用计算互信息函数的第一极小值来确定最佳延迟时间。

### 1.3 嵌入维度的选择

如果要尽可能恢复其真实的动力系统, 嵌入维度应该足够大。Takens 的嵌入定理为  $m$  提供了一个下限<sup>[22]</sup>。在维度为  $m$  的空间中, 维度  $d_1$  的一个子空间和维度  $d_2$  的另一个子空间一般相交在维度为  $d_1$  的子空间里, 这个子空间的维度  $d_l$  为

$$d_l = d_1 + d_2 - m \quad (2)$$

如果这是负数, 那么两个子空间都不相交。为了满足在实际序列和重建的相空间相点之间获得一对一对应关系, 因此不能发生自相交。因为自相交会有两个方向, 这将破坏一一对应关系。

所以当求相同维度  $d_A$  的两个子空间(即轨道与自身)的交点时, 如果  $2d_A - m < 0$  或  $m > 2d_A$ , 则不会有交点。展开混沌吸引子存在的一个问题是如果将一系列维度  $d_A$  的相点投射到较低维度时, 自相交现象会出现。因此, 给定的展开标准维度是  $m > 2d_A$ 。嵌入维度  $m$  应该是一个整数, 使满足展开条件  $m > 2d_A$  的最小值  $m$  是嵌入维数  $m_E$ 。因此,  $m_E = \text{int}(2d_A + 1)$ , 其中  $\text{int}(\ )$  表示取整数。为了降低计算成本, 可以将自相交忽略, 从而嵌入维度的范围可以缩小在  $d_A < m < 2d_A$ 。

## 2 Elman 神经网络

Elman 神经网络是具有局部记忆单元和局部反馈连接的递归神经网络。Elman 神经网络包括输入层、输出层、隐藏层和承接层。输入和输出层与外界环境相互作用, 输入层单元仅有信号传递作用, 输出层单元有线性加权的作用, 隐含层单元的传递函数可以采用线性或非线性函数, 承接层用于记忆隐含层单元前一时刻的输出值并返回给网络的输入, 可以将其看为是一步的时间延迟<sup>[23]</sup>。

图 1 中输入用  $u(k)$  表示, 输出为  $y(k)$ 。第  $i$  个隐藏层的输入表示为  $v_i(k)$ , 第  $i$  个隐藏层的输出表示为  $x_i(k)$ , 第  $j$  个承接层的输出表示为  $x_j^c(k)$ 。则有以下公式:

$$v_i(k) = \sum_{j=1}^n w_{i,j}^x(k-1)x_j^c(k) + w_i^u(k-1)u(k) \quad (3)$$

$$x_i(k) = f(v_i) \quad (4)$$

$$x_j^c(k) = x_j(k-1) \quad (5)$$

$$y(k) = \sum_{i=1}^n w_i^y(k-1)x_i(k) \quad (6)$$

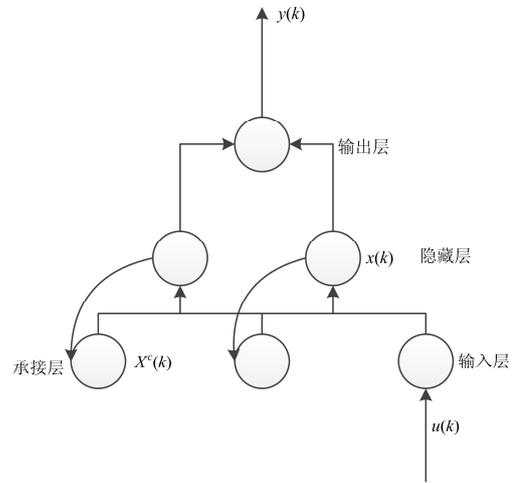


图 1 Elman 神经网络结构图

Fig. 1 Elman neural network structure diagram

如果输入  $u(k)$  在被发送到输入单元之前被延迟一个时间步长, 则  $x_j^c(k)$  将被  $x_j(k-1)$  代替, 并且隐藏层被假设为线性的。上述的方程式则会变为

$$v_i(k) = \sum_{j=1}^n w_{i,j}^x(k-1)x_j^c(k) + w_i^u(k-1)u(k-1) \quad (7)$$

$$x_i(k) = v_i(k) \quad (8)$$

$$y(k) = \sum_{i=1}^n w_i^y(k-1)x_i(k) \quad (9)$$

上述方程式可以用来描述一个  $n$  次线性动力系统的状态空间,  $n$  为输入集  $x(k) = \{x_i(k)\}$  的维度, 也是隐藏层和承接层的数量。模型的维度也决定了隐藏层的数量。该方程可以进一步扩展成以下方程:

$$y(k) = A_1 y(k-1) + A_2 y(k-2) + \dots + A_n y(k-n) + B_1 u(k-1) + B_2 u(k-2) + \dots + B_n u(k-n) \quad (10)$$

因此, Elman 神经网络可以对一个动态系统进行建模并训练。在进行电量预测时, Elman 神经网络可以处理  $n$  阶数据, 普通的前馈式神经网络需要两倍的数据才能完成建模, 而 Elman 神经网络最多只需  $n+1$  个就可以, 如果将承接层也作为输入, Elman 的网络结构也保证了 Elman 在处理大量数据时可以兼具运行效率和预测精度。因此, Elman 在短期预测时具有优势。

## 3 粗糙集理论

### 3.1 误差补偿结构的提出

神经网络具有无限逼近的能力, 在逼近非线性函数时, 两侧斜率过大的峰值点预测误差较大。短

期的用电量随机性大,易产生波动,Elman神经网络进行预测时峰值点会呈现不同程度的预测偏差,本文引入粗糙集对预测出的电量序列进行修正,提高预测精度。

### 3.2 算法的实现

算法以 Elman 神经网络用电量的预测值为基础,根据式(11)进行修正<sup>[24]</sup>。

$$\begin{cases} Y'_{t+1} = Y_{t+1} + S|k_{t+1} - k_t| \\ k_{t+1} = Y_{t+2} - Y_{t+1} \\ k_t = Y_{t+1} - Y_t \end{cases} \quad (11)$$

式中:  $Y'_{t+1}$  为  $t+1$  时刻修正后的预测值;  $V_{t+2}$ 、 $V_{t+1}$ 、 $V_t$  分别表示第  $t+2$ 、 $t+1$ 、 $t$  单位时间 Elman 神经网络模型未修正用电量预测值;  $k_{t+1}$ 、 $k_t$  分别表示预测函数在  $t+1$  时刻两侧的斜率;  $S$  为尺度因子。

$S$  可通过建立基于粗糙集理论的信息系统确定。构建基于粗糙集信息系统  $K = (U, A)$ , 其中  $U$  为 Elman 神经网络模型输出用电量预测值的数据集;  $A = C \cup D$  为属性的非空有限集合, 其中条件属性集  $C$  是原始用电量数据特征组成的集合, 决策属性集  $D = \{d\}$ ,  $d$  为所求的尺度因子  $S$ , 定义  $C = \{a, b, c\}$ , 则有

$$a = \frac{|k_{t+1} - k_t|}{Y_t} \quad (12)$$

$$b = \text{sgn}(k_{t+1} - k_t) \quad (13)$$

$$c = \left| \frac{Y_t}{\max_{t=1}^M Y_t} \right| \quad (14)$$

式中:  $Y_t$  为  $t$  单位时间的用电量预测值;  $Y_t$  为在  $t$  单位时间的实际用电量;  $M$  为数据点的总数。

以 Elman 神经网络模型输出的用电量预测值为基础,根据式(12)~式(14)提取出条件属性集  $C$ , 根据专家经验确定决策属性集  $D$ , 构成了一个完整的信息系统。分别对属性集  $C$  和  $D$  进行等频划分离散化<sup>[25]</sup>处理得到决策表, 采用粗糙集属性约简算法对决策表进行处理即可得到最小决策规则, 从而确定尺度因子  $S$ , 实现对 Elman 神经网络模型的用电量预测值的修正。

## 4 粗糙集-混沌时间序列 Elman 神经网络

文章将混沌理论和神经网络进行结合, 基于电量数据混沌特性, 混沌时间序列利用混沌吸引子在不同层次间的自相似性进行混沌系统的短期预测, 提取了采样时间序列中不同影响因素相互影响、相

互作用的信息, Elman 神经网络具备机器学习以及自带反馈功能, 改进的模型具备混沌时间序列和 Elman 神经网络的优势。

如图 1 所示, 混沌时间序列的 Elman 神经网络预测详细步骤如下:

- 1) 数据初始化处理。
- 2) 嵌入维度计算, 利用假近临法进行数据嵌入维度  $m$  的计算。
- 3) 延迟时间计算, 利用互信息法对数据延迟时间  $\tau$  进行计算。
- 4) 重构相空间, 将已计算的原始数据、嵌入维度和延迟时间作为相空间重构的输入, 将数据还原到初始状态。
- 5) 数据归一化, 将已重构相空间的数据调整到 0~1, 这一步骤可确保 Elman 神经网络顺利进行。
- 6) Elman 神经网络预测, 将归一化的数据作为输入, 设置训练目标最小误差、训练次数、现实频率和学习速率, 在输出结果后可调整神经元个数以达到最优效果。
- 7) 数据反归一化并输出, 将预测的结果反归一化。
- 8) 将输出的预测值来构建条件属性集, 根据专家经验选出的尺度因子构建决策属性集, 通过等频划分的离散方法对集合进行离散化处理形成决策表, 通过最小决策规则确定尺度因子, 最后代入式(11)进行预测值修正。

## 5 案例分析

### 5.1 数据收集

文章选取 Heriot-Watt 大学某栋学生公寓从 2014 年 11 月 1 日到 2014 年 11 月 30 日一共 30 天的用电量数据进行预测, 数据收集前将传感器安装在电表上, 传感器将每 5 min 用电量数据为一个计数点进行传输, 总共有 8 640 个计数点。应用 29 天 8 352 个计数点作为训练数据, 对最后一天 36 个计数点进行预测。

### 5.2 计算过程及参数设置

首先对这组数据进行相空间重构, 相空间重构的前提是计算嵌入维度和延迟时间。如图 2 所示, 用互信息法求时间延迟为 15, 符合上述 3 个条件。再用假近邻法求得嵌入维度为 6, 如图 3 所示, 经过相空间重构, 实际数据还原为 6 维的原始数据。

接着, 对 Elman 神经网络参数进行设置, 参数设置如表 1 所示。

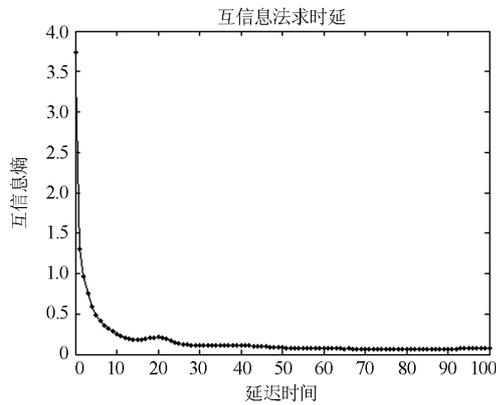


图 2 互信息法求延迟时间图

Fig. 2 Mutual information method for delay time graph

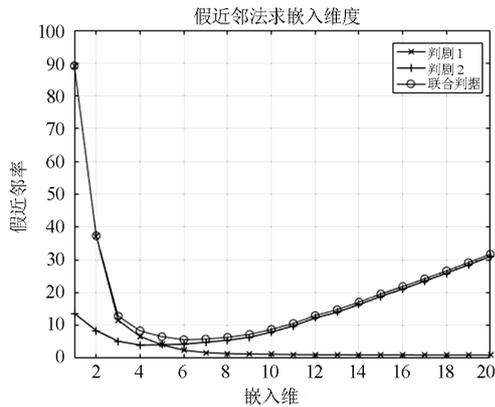


图 3 假近邻法求嵌入维度图

Fig. 3 Embedding dimension graph with false nearest neighbor method

表 1 算法参数设置表

Table 1 Parameter setting table

延迟时间 $t$	嵌入维 度 $d$	训练目标 最小误差 (goal)	训练次数 (epochs)	现实频率 (show)	学习速率(lr)
15	6	0.000 01	5 000	50	0.05

在预测中, 隐含层神经元对结果的影响也很大。根据经验, 神经元个数的选择应遵循经验公式  $t = 2n + 1$  进行选择, 但是经调试后依最好的结果最终选定隐含层的神经元个数为 100。

最后, 根据表 2 所示的条件属性和表 3 决策属性, 采用最小决策规则确定尺度因子, 对预测值进行修正。

### 5.3 仿真结果对比

文章应用 Matlab 实现修正的混沌时间序列 Elman 神经网络预测模型并与 Elman 神经网络模型和混沌时间序列 Elman 神经网络预测结果进行对比分析。

表 2 条件属性表

Table 2 Conditional attribute coding table

$a$ 的值	$a$ 的编码	$b$ 的值	$b$ 的编码	$c$ 的值	$c$ 的编码
$[0, 0.1]$	1	$(0, +\infty)$	1	$(0, 0.05]$	1
$(0.1, 0.5]$	2	$(-\infty, 0)$	2	$(0.05, 0.1]$	2
$(0.5, 9]$	3	0	3	$(0.1, 0.5]$	3
$(9, +\infty)$	4			$(0.5, 1.0]$	4

表 3 决策属性表

Table 3 Decision attribute coding table

$d$ 的值	-0.15	-0.1	-0.05	0	0.05	0.1	0.15
$d$ 的编码	1	2	3	4	5	6	7

图 4—图 6 分别为 Elman 神经网络、混沌时间序列改进 Elman 神经网络和修正后的混沌时间序列 Elman 神经网络预测相同 36 点即 3 个小时的电量预测。图 4 中可看出用 Elman 神经网络模型做出的

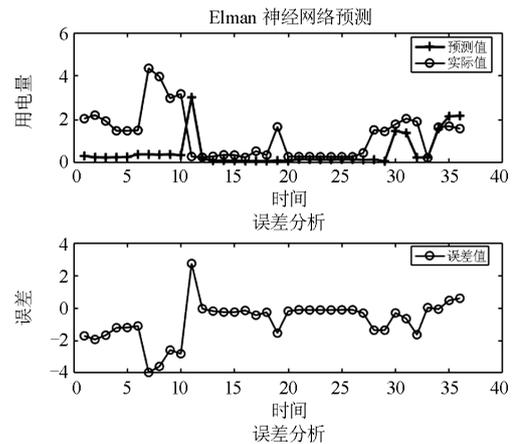


图 4 Elman 神经网络预测图

Fig. 4 Elman neural network prediction

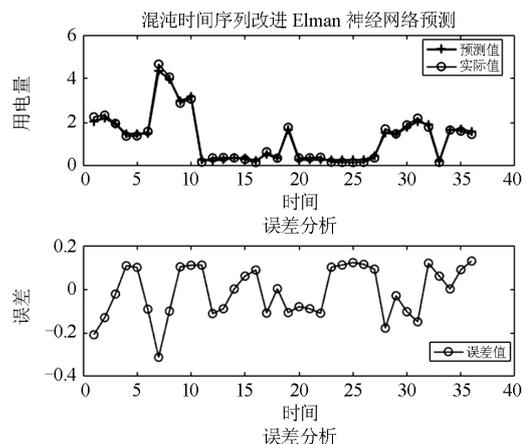


图 5 混沌时间序列 Elman 神经网络预测图

Fig. 5 Improved Elman neural network prediction map with chaotic time series

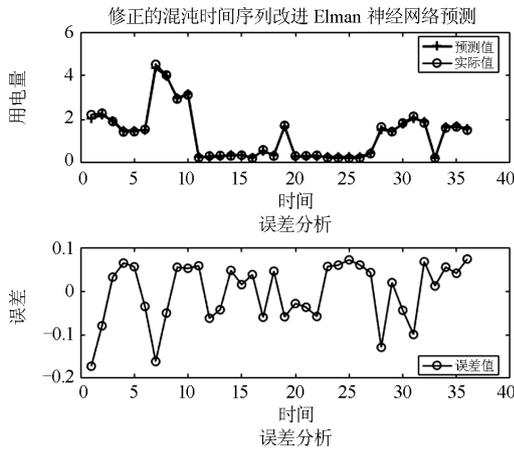


图 6 粗糙集修正的混沌时间序列 Elman 神经网络预测图  
Fig. 6 Modified chaotic time series Elman neural network prediction map

预测趋势大致一致，但实际中随机的突然增大和减少的峰值预测偏差过大；混沌时间序列改进后的 Elman 神经网络预测值和实际值已经趋近相同，但在峰值处稍微有些偏差；而再用粗糙集修正过后各点的偏差不同程度的减少，误差范围再次缩小，由图 5 和图 6 的误差分析图中可看出改进效果明显，误差范围从  $[-0.4, 0.2]$  缩小到  $[-0.2, 0.1]$ 。

而由于修正后的混沌时间序列 Elman 神经网络预测结果误差较小，所以在其预测中的收敛速度也更快，如图 7，表示的是修正后的混沌时间序列 Elman 神经网络预测的训练轨迹。

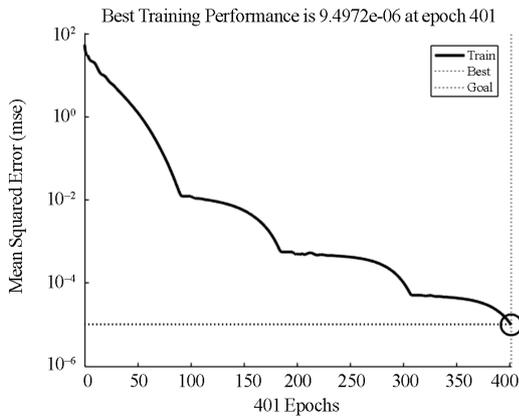


图 7 修正后的混沌 Elman 神经网络训练轨迹  
Fig. 7 Training trajectory of modified chaotic Elman neural network

从图 7 可以看出，在用修正后的混沌 Elman 神经网络学习 401 次后即可达到指定的学习目标从而停止学习，迭代速度更快，预测效率更高。

#### 5.4 误差分析

为了清晰地比较 3 种模型的有效性，引入两个

国际上运用较多的误差指标，分别是均方差(MSE)和平均绝对百分误差(MAPE)。其运算方式为<sup>[26]</sup>

$$e_{MAPE} = \frac{\sum_{t=1}^N |p(t) - y(t)| / y(t)}{N} \times 100\% \quad (15)$$

$$e_{MSE} = \frac{\sum_{t=1}^N [p(t) - y(t)]^2}{N} \quad (16)$$

式中： $y(t)$  为实际值； $p(t)$  为预测值； $N$  为预测数据的个数。运用公式后该结果如表 4。

表 4 算法误差分析表

算法	$e_{MAPE}$	$e_{MSE}$
Elman	48.11%	0.473 0
混沌 Elman	19.67%	0.101 2
修正混沌 Elman	9.73%	0.059 4

表 4 中分别列举了 Elman 神经网络、混沌 Elman 神经网络和混沌粗糙集 Elman 神经网络 3 种模型预测结果在均方差和平均绝对相对误差方面的误差结果。可以看出用单一 Elman 神经网络预测出来的误差较大，平均绝对相对误差达到 48.11%，均方差为 0.473。而经过相空间变化后的混沌 Elman 神经网络预测的误差明显减小，只有 19.67%。如果再加上粗糙集修正后的预测模型则减少更多，只有 9.73%，均方差则缩小到只有 0.059 4。结果显示，用粗糙集修正后的混沌 Elman 神经网络误差最小，效果最优。

## 6 结语

文章将粗糙集理论和混沌理论与 Elman 神经网络结合进行预测。预测结果与单一 Elman 神经网络模型和混沌时间序列 Elman 神经网络预测结果进行对比，验证了该模型在进行短期电量预测的有效性和优越性。

用电量智能化预测依赖于大数据分析，它不仅是用户需求的体现，也是模型普遍使用性的保证。除此之外，考虑用户用电的个性化特性研究有利于在不确定情况下保证电网的安全稳定性。下一步工作应投身于大数据分析和用户个性化特性研究。

## 参考文献

[1] 祖其武, 牛玉刚, 邹媛媛, 等. 基于弹性负荷分时调度和多电源联合供电的微网经济运行[J]. 电力系统保护与控制, 2018, 46(4): 20-27.  
ZU Qiwu, NIU Yugang, ZOU Yuanyuan, et al. Economic operation of microgrid based on elastic load sub-period dispatch and combined power supply of multiple energy[J]. Power System Protection and Control, 2018, 46(4):

- 20-27.
- [2] 廖旋焕, 胡智宏, 马莹莹, 等. 电力系统短期负荷预测方法综述[J]. 电力系统保护与控制, 2011, 39(1): 147-152.  
LIAO Nihuan, HU Zhihong, MA Yingying, et al. A summary of short-term load forecasting methods for power systems[J]. Power System Protection and Control, 2011, 39(1): 147-152.
- [3] 李奎, 李晓倍, 郑淑梅, 等. 基于 BP 神经网络的交流接触器剩余电寿命预测[J]. 电工技术学报, 2017, 32(15): 120-127.  
LI Kui, LI Xiaobei, ZHENG Shumei, et al. Prediction of residual electrical life of AC contactor based on BP neural network[J]. Transactions of China Electrotechnical Society, 2017, 32(15): 120-127.
- [4] 汪清瑶, 刘琼. 基于 Elman 神经网络的烧结矿质量在线预测研究[J]. 仪表技术与传感器, 2017(10): 98-100, 104.  
WANG Qingyao, LIU Qiong. Research on online prediction of sinter quality based on Elman neural network[J]. Meter Technology and Sensors, 2017(10): 98-100, 104.
- [5] 刘振宇, 冯华, 杨仁刚. 基于混沌时间序列及神经网络的大同电网负荷短期预测研究[J]. 中北大学学报(自然科学版), 2014, 35(6): 695-698.  
LIU Zhenyu, FENG Hua, YANG Rengang. Study on short-term load forecasting of datong grid based on chaotic time series and neural network[J]. Journal of North University of China (Natural Science Edition), 2014, 35(6): 695-698.
- [6] 赵腾, 王林童, 张焰, 等. 采用互信息与随机森林算法的用户用电关联因素辨识及用电量预测方法[J]. 中国电机工程学报, 2016, 36(3): 604-614.  
ZHAO Teng, WANG Lintong, ZHANG Yan, et al. User identification and power consumption forecasting method based on mutual information and random forest algorithm[J]. Proceedings of the CSEE, 2016, 36(3): 604-614.
- [7] 廖峥, 熊小伏, 李新, 等. 基于 BP 神经网络的输电线路舞动预警方法[J]. 电力系统保护与控制, 2017, 45(19): 154-161.  
LIAO Zheng, XIONG Xiaofu, LI Xin, et al. Transmission line galloping early warning method based on BP neural network[J]. Power System Protection and Control, 2017, 45(19): 154-161.
- [8] 丁晓, 孙虹, 郑海雁, 等. 基于配用电大数据的短期负荷预测[J]. 电力工程技术, 2018, 37(3): 21-27.  
DING Xiao, SUN Hong, ZHENG Haiyan, et al. Short-term load forecasting based on large distribution data[J]. Electric Power Engineering Technology, 2018, 37(3): 21-27.
- [9] 杨国田, 张涛, 王英男, 等. 基于长短期记忆神经网络的火电厂 NOx 排放预测模型[J]. 热力发电, 2018, 47(10): 12-17.  
YANG Guotian, ZHANG Tao, WANG Yingnan, et al. Prediction model for NOx emissions from thermal power plants based on long-short-term memory neural network[J]. Thermal Power Generation, 2018, 47(10): 12-17.
- [10] 栾开宁, 鲍敏, 易永仙, 等. 基于用电模式数的大用户负荷短期预测技术研究[J]. 电力工程技术, 2018, 37(3): 33-37.  
LUAN Kaining, BAO Min, YI Yongxian, et al. Research on short-term load forecasting technology for large users based on the number of power use modes[J]. Electric Power Engineering Technology, 2018, 37(3): 33-37.
- [11] 田松峰, 吴昭延, 王子光, 等. 基于神经网络的凝汽器污垢热阻预测模型[J/OL]. 热力发电, 2019, 48: 1-5. [2019-01-17]. <https://doi.org/10.19666/j.rlfld.201807145>.  
TIAN Songfeng, WU Zhaoyan, WANG Ziguang, et al. Neural network-based prediction model for thermal resistance of condenser fouling[J/OL]. Thermal Power Generation, 2019, 48: 1-5. [2019-01-17]. <https://doi.org/10.19666/j.rlfld.201807145>.
- [12] 唐静, 李瑞轩, 黄宇航, 等. 基于多维特征分析的月用电量精准预测研究[J]. 电力系统保护与控制, 2017, 45(16): 145-150.  
TANG Jing, LI Ruixuan, HUANG Yuhang, et al. Research on accurate prediction of monthly electricity consumption based on multidimensional feature analysis[J]. Power System Protection and Control, 2017, 45(16): 145-150.
- [13] 穆海振, 孙兰东, 侯依玲. 上海市全社会月用电量预测模型[J]. 中国电力, 2016, 49(6): 146-150.  
MU Haizhen, SUN Landong, HOU Yiling. Shanghai's monthly electricity consumption forecast model for the whole society[J]. Electric Power, 2016, 49(6): 146-150.
- [14] 马瑞, 彭舟, 蒋诗谣, 等. 季节划分下产业用电量关联分析及预测[J]. 中国电力, 2015, 48(7): 82-88.  
MA Rui, PENG Zhou, JIANG Shiyao, et al. Electricity consumption association analysis and forecast under seasonal divisions[J]. Electric Power, 2015, 48(7): 82-88.
- [15] 董朝武, 白江红, 汪鸿, 等. 基于容量利用特征的行业售电量预测方法研究[J]. 电力系统保护与控制, 2018, 46(1): 103-109.  
DONG Chaowu, BAI Jianghong, WANG Hong, et al. Research on forecasting method of electricity consumption based on capacity utilization characteristics[J]. Power System Protection and Control, 2018, 46(1): 103-109.

- [16] HAN M, XI J, XU S, et al. Prediction of chaotic time series based on the recurrent predictor neural network[J]. IEEE Transactions on Signal Processing, 2004, 52(12): 3409-3416.
- [17] GIONA M, LENTINI F, CIMAGALLI V. Functional reconstruction and local prediction of chaotic time series[J]. Physical Review A, 1991, 44(6): 3496.
- [18] KARUNASINGHE D S, LIONG S Y. Chaotic time series prediction with a global model: artificial neural network[J]. Journal of Hydrology, 2006, 323(1): 92-105.
- [19] CASDAGLI M. Nonlinear prediction of chaotic time series[J]. Physica D: Nonlinear Phenomena, 1989, 35(3): 335-356.
- [20] MAGUIRE L P, ROCHE B, MCGINNITY T M, et al. Predicting a chaotic time series using a fuzzy neural network[J]. Information Sciences, 1998, 112(1-4): 125-136.
- [21] LIN D T, DAYHOFF J E, LIGOMENIDES P A. Adaptive time-delay neural network for temporal correlation and prediction[C] // Applications in Optical Science and Engineering, International Society for Optics and Photonics, November, 1992: 170-181.
- [22] KENNEL M B, BROWN R, ABARBANEL H D. Determining embedding dimension for phase-space reconstruction using a geometrical construction[J]. Physical Review A, 1992, 45(6): 3403.
- [23] 叶瑞丽, 郭志忠, 刘瑞叶, 等. 基于小波包分解和改进 Elman 神经网络的风电场风速和风电功率预测[J]. 电工技术学报, 2017, 32(21): 103-111.  
YE Ruili, GUO Zhizhong, LIU Ruiye, et al. Wind speed and power prediction of wind farm based on wavelet packet decomposition and improved Elman neural network[J]. Transactions of China Electrotechnical Society, 2017, 32(21): 103-111.
- [24] 夏非, 范莉, 苏浩益. 基于粗糙集理论和启发式径向基函数神经网络的中长期电力负荷预测模型[J]. 电力系统保护与控制, 2012, 40(16): 21-26.  
XIA Fei, FAN Li, SU Haoyi. A model for medium and long term load forecasting based on rough set theory and heuristic radial basic function neural network[J]. Power System Protection and Control, 2012, 40(16): 21-26.
- [25] 覃泓皓, 牛东晓, 钱望月, 等. 考虑季节特性的改进小波包-RBF 用电量预测方法[J]. 电力科学与技术学报, 2016, 31(2): 37-44.  
TAN Honghao, NIU Dongxiao, QIAN Wangyue, et al. Electricity consumption forecast method with improved wavelet packet-RBF and seasonal characteristics considered power considering the improved wavelet seasonal characteristics[J]. Journal of Electric Power Science and Technology, 2016, 31(2): 37-44.
- [26] LI Zhi, YE Lin, ZHAO Yongning, et al. Short-term wind power prediction based on extreme learning machine with error correction[J]. Protection and Control of Modern Power Systems, 2016, 1(1): 9-16. DOI: 10.1186/s41601-016-0016-y.

收稿日期: 2018-03-04; 修回日期: 2019-01-20

作者简介:

吴佳懋(1991—), 女, 硕士研究生, 研究方向为大数据预测; E-mail: 516753403@qq.com

李艳(1977—), 女, 通信作者, 博士, 教授, 研究方向为公共基础设施管理; E-mail: 34983908@qq.com

符一健(1993—), 男, 硕士研究生, 研究方向为大数据预测。E-mail: yf2@hw.ac.uk

(编辑 周金梅)