

DOI: 10.19783/j.cnki.pspc.200539

# 基于数据序列分辨率压缩尺度优化的月度电量预测方法

王飞<sup>1</sup>, 李正辉<sup>1</sup>, 李渝<sup>2</sup>, 王铁强<sup>3</sup>, 丘刚<sup>2</sup>, 郭怀东<sup>1</sup>, 马辉<sup>4,5</sup>, 王东升<sup>6</sup>

(1. 华北电力大学, 河北 保定 071003; 2. 国网新疆电力有限公司, 新疆 乌鲁木齐 830018; 3. 国网河北省电力有限公司, 河北 石家庄 050021; 4. 北京金风慧能技术有限公司, 北京 100176; 5. 新疆金风科技股份有限公司, 新疆 乌鲁木齐 830026; 6. 国网冀北电力有限公司, 北京 100054)

**摘要:** 准确的月度电量预测是指导电力部门安排运行计划和保障售电公司盈利能力的关键基础。针对基于人工智能算法电量预测模型在训练过程中存在样本分辨率选择不当导致预测精度降低的问题, 提出了一种历史数据序列分辨率压缩尺度优化方法。首先将数据分辨率压缩尺度选择建模成一个优化问题。然后通过数据驱动方式进行求解。最后再利用长短期记忆(Long Short-term Memory, LSTM)神经网络实现月度电量预测, 从而较好地实现了数据分辨率和电量预测步长之间的合理平衡以提升电量预测精度。利用美国 PJM 电力市场的历史电量数据对所提方法进行验证。仿真结果表明, 较不进行分辨率压缩尺度选择所提方法具有更高的预测精度, 同时 LSTM 网络在结合该方法时表现出了最佳的预测性能。

**关键词:** 电量预测; 分辨率; 尺度压缩; 多步预测; 长短期记忆神经网络

## Data series resolution compression scale optimization based monthly electricity consumption forecasting

WANG Fei<sup>1</sup>, LI Zhenghui<sup>1</sup>, LI Yu<sup>2</sup>, WANG Tieqiang<sup>3</sup>, QIU Gang<sup>2</sup>, GUO Huaidong<sup>1</sup>, MA Hui<sup>4,5</sup>, WANG Dongsheng<sup>6</sup>

(1. North China Electric Power University, Baoding 071003, China; 2. State Grid Xinjiang Electric Power Co., Ltd., Urumqi 830018, China; 3. State Grid Hebei Electric Power Co., Ltd., Shijiazhuang 050021, China; 4. Beijing Goldwind Smart Energy Technology Co., Ltd., Beijing 100176, China; 5. Xinjiang Goldwind Science Technology Co., Ltd., Urumqi 830026, China; 6. State Grid Jibei Electric Power Co., Ltd, Beijing 100054, China)

**Abstract:** Accurate monthly electricity forecasting is the crucial basis to guide the operation plans arrangement of power grid corporation and guarantee the profitability of electricity retailers. To address the problem that improper selection of sample resolution during model training process based on artificial intelligence algorithms will seriously reduce the forecasting accuracy, a method for optimizing the compression scale of historical electricity data series resolution is proposed in this paper. First, the selection of data resolution compression scale is modeled as an optimization problem. Then, the data-driven method is used to solve the optimization problem. Finally, Long Short-Term Memory (LSTM) neural network algorithm is utilized to forecast the monthly electricity. As a result, a reasonable balance between data resolution and electricity forecasting step is achieved. The historical electricity data from PJM are utilized to verify the proposed method. The results show that the proposed method performs better than that without resolution compression scale selection, and the LSTM neural network combined with the proposed method shows the best forecasting performance.

This work is supported by National Key Research and Development Program of China (No. 2018YFE0122200), Major Science and Technology Achievements Conversion Project of Hebei Province (No. 19012112Z), and Science and Technology Project of State Grid Corporation of China (No. SGHE0000KXJS1800163).

**Key words:** electricity forecasting; resolution; scale compression; multi-step forecasting; long short-term memory neural network

## 0 引言

国务院 2015 年《关于进一步深化电力体制改革

的若干意见》<sup>[1]</sup>及其相关文件为新一轮电力市场改革拉开了序幕。文件中明确提出了要将稳步推进售电侧改革, 有序向社会资本放开售电业务作为改革的重点任务之一。市场的逐步开放为售电侧引入了竞争机制, 这使得许多的售电公司如雨后春笋般出现<sup>[2-3]</sup>。

根据交易模式的不同, 售电公司可在中长期市

基金项目: 国家重点研发计划项目政府间国际科技创新合作重点专项(2018YFE0122200); 河北省重大科技成果转化专项(19012112Z); 国家电网公司科技项目(SGHE0000KXJS1800163)

场和现货市场分别参与中长期(年度、月度)交易和短期(日前、实时)交易。其中, 中长期交易的合同电量为计划值, 通常用来满足客户大体的用电需求, 其与实际用电量之间的偏差不可避免。此时, 实时的供需平衡需要通过短期现货交易来实现。在成熟的现货市场尚未建立完成之前, 我国大部分省份均通过偏差电量考核机制<sup>[4]</sup>来保障市场的公平性。当合同电量与实际电量的偏差较大时, 售电公司将面临高额的考核费用, 这也成为导致绝大部分售电公司亏损的主要原因。即便是现货市场建立完成后, 激烈的市场竞争力可能会使得电力现货价格产生较大波动。此时, 对于用电客户中长期电力需求的错误估计同样会使得售电公司面临现货市场潜在的价格风险。因此, 从电力市场的角度来说, 建立准确的月度电量预测模型十分重要。此外, 从电力系统运行控制的角度来说, 准确的月度电量预测同样为计划部门合理安排中期运行检修计划, 降低供电成本和提高供电可靠性提供重要依据。

月度电量预测属于中期负荷预测的范畴, 国内外已在该领域开展了多年的研究。根据模型原理的不同, 常用的中期负荷预测方法可分为两类: 传统的预测方法和基于人工智能的预测方法。前者根据数学和统计学原理对负荷的历史变化规律以及外部影响因素进行分析, 主要包括回归分析法<sup>[5-6]</sup>、时间序列法<sup>[7]</sup>以及灰色模型预测法<sup>[7-8]</sup>等。该类方法具有可解释性强、建模简单的特点, 但往往适应性较弱, 预测精度较低; 后者则是利用不同的人工智能模型, 直接建立输入变量与输出之间的复杂非线性映射关系, 主要包括神经网络预测法<sup>[9-11]</sup>、支持向量机(Support Vector Machine, SVM)预测法<sup>[12-14]</sup>、组合模型预测法<sup>[15]</sup>等。该类方法对于时间序列的性质和先验知识的依赖性较小, 具有易于掌握、泛化能力强和预测精度高的特点, 因此广泛应用于负荷预测中。

值得注意的是, 人工智能法, 特别是近年来发展迅猛的深度学习预测算法<sup>[16]</sup>, 普遍对于训练数据具有较高的依赖性, 适应于历史样本数据充足的情况。应用人工智能法解决月度电量预测问题时, 一般利用算法模型拟合历史多个月份的用电量数据与未来一个月的待预测用电量数据之间的非线性关系<sup>[17-19]</sup>, 实现对未来一个月用电量的单步预测。然而, 低分辨率历史月度用电量数据的样本数量有限, 导致模型训练的过程中存在严重的过拟合问题, 因此大多数算法无法提供令人满意的预测精度。由于电量具有累加的特点, 加之智能电表的快速发展使得获取大量的高分辨率历史用电量数据成为可能,

文献[20]提出了如图 1 所示的一种利用高分辨率的小时用电量数据建立多步预测模型, 并将多步预测结果累加得到月度电量预测结果的方法, 最终提升了预测精度。理论上来说, 使用的历史数据分辨率越高, 模型的训练样本就越多, 模型的拟合效果就越好。然而, 采用这种预测方法将导致预测步长的增加。例如, 如果使用小时级数据进行月度电量预测, 需预测得到未来一个月大约 720 个小时的用电量, 再将结果累加得到最终的月度电量预测结果。多步预测的精度往往随预测步长的增大而迅速降低, 最终影响预测精度。针对以上分析, 选择合适的分辨率是改善预测精度的关键。

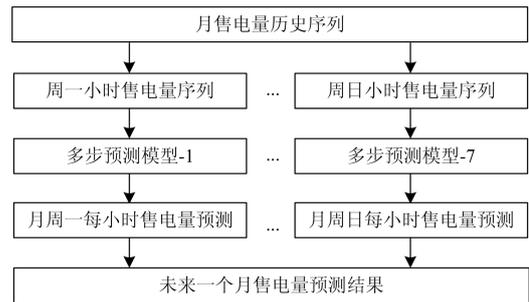


图 1 基于高分辨率历史数据的月度售电量预测方法  
Fig. 1 Monthly electricity consumption forecasting using high-resolution historical data

针对人工智能算法对于训练样本数量的依赖性, 以及多步预测精度与预测步长呈反比的特性, 本文提出了一种基于历史用电量序列分辨率压缩优化的月度电量预测方法。首先, 利用不同分辨率的历史数据结合多步预测模型进行月度电量预测, 此时可以通过改变训练数据的分辨率来获得多个预测结果。然后, 利用基于数据驱动优化建模方法将对应于不同分辨率下的模型预测结果结合起来, 得到最终的结果。通过美国 PJM 电力市场中的数据进行建模仿真, 结果表明本文所提出的方法在结合长短期记忆(Long Short-term Memory, LSTM)神经网络时可以提供最佳的预测精度。

## 1 问题描述

假设采集到其历史  $N_1$  个月的月度用电量数据, 记为

$$\mathbf{D}_{\text{his}}^M = [D_1^M, D_2^M, \dots, D_{N_1-1}^M, D_{N_1}^M] \quad (1)$$

在传统的基于人工智能法的月度电量预测方法中, 普遍将该预测问题建模成一个单步预测模型, 即直接利用历史月度用电量序列  $\mathbf{D}_{\text{his}}^M$  预测未来一个月的用电量  $D_{\text{next}}^M$ 。受样本数量的限制, 大多数人工智能算法常常会出现模型过拟合的问题。因此这类

预测方法通常需要结合 SVM 等适应于小样本学习的算法才能得到令人满意的预测精度。

想要避免过拟合问题的出现, 增加训练样本数是关键。本文分析的时间序列分辨率最高为一小时一个采样点。此时若利用小时级分辨率历史用电量数据进行月度电量预测, 该问题将转化为一个多步预测问题: 假设采集到相同历史时间范围内  $N_2$  个小时的用电量数据, 记为

$$\mathbf{D}_{\text{his}}^H = [D_1^H, D_2^H, \dots, D_{N_2-1}^H, D_{N_2}^H] \quad (2)$$

此时, 一个月的用电量可表示为

$$D^M = \sum_{i=1}^T D_i^H \quad (3)$$

式中,  $T$  表示一个月的总小时点数。

利用历史小时用电量序列向量  $\mathbf{D}_{\text{his}}^H$  预测未来一个月  $T$  个小时的用电量, 再将预测结果累加, 同样可以得到月用电量预测结果。可以看出,  $N_2$  远大于  $N_1$  ( $N_2 \approx 720 \times N_1$ ), 有助于提供更多的训练样本。然而, 预测步长的大幅增加(由 1 增加至  $T$ )会导致预测的不确定性增加, 并最终降低模型的预测精度。

根据以上分析可以得出结论: 序列分辨率过低会导致预测样本数大量减少; 序列分辨率过高会导致预测步长大幅增加。这两种情况最终都会导致预测模型精度降低。因此, 选择合适的历史用电量序列分辨率是提升预测精度的关键。

## 2 历史用电量序列分辨率压缩优化

本文旨在提出一种历史用电量序列分辨率压缩优化方法, 通过优化建模的思路, 将高分辨率的电量历史序列压缩至最优的分辨率, 从而保证压缩后时间序列具有充足的训练样本和适当的预测步长。该方法包括以下四步。

### 1) 样本集合划分

将采集到的历史小时用电量序列向量  $\mathbf{D}_{\text{his}}^H$  的前  $a\%$  被作为预测模型的训练集, 后  $(1-a)\%$  作为验证集, 分别记为  $\mathbf{D}_{\text{tra}}^H$  和  $\mathbf{D}_{\text{val}}^H$ 。

### 2) 待预测步长初步分解

该步骤在训练集  $\mathbf{D}_{\text{tra}}^H$  上进行。为避免过多的预测步长造成多步预测精度的降低, 本文中采用文献[20]的预测框架, 即将小时用电量序列分类以减少每类序列的待预测步长, 然后将预测结果组合以得到总的预测结果。具体来说, 考虑到用电行为的日历效应, 同时为保证时间序列的可预测性, 根据不同星期中的同一工作日或周末休息日中的用电行为之间的相似性, 将历史小时用电量序列按照其周标签分为 7 个时间序列向量。

$$\mathbf{D}_{\text{tra}}^{W_i} = [D_1^{W_i}, D_2^{W_i}, \dots, D_{w_i-1}^{W_i}, D_{w_i}^{W_i}], i=1, \dots, 7 \quad (4)$$

式中:  $W_i$  表示星期 “ $i$ ”;  $\mathbf{D}_{\text{tra}}^{W_i}$  表示训练集历史星期 “ $i$ ” 的小时用电量序列;  $\sum_{i=1}^7 w_i = N_2$ 。

此时, 一个月的用电量可以表示为

$$D^M = \sum_{i=1}^7 \sum_{t=1}^{T_i} D_t^{W_i} \quad (5)$$

$$\sum_{i=1}^7 T_i = T \quad (6)$$

式中,  $T_i$  表示一个月中星期 “ $i$ ” 的总小时数。

针对分解后的七个序列分别建立多步预测模型, 各序列的待预测步长为  $T_i$ , 大约为原始预测步长  $T$  的  $1/7$ 。该方法已被证实可以有效地降低多步预测误差<sup>[20]</sup>。

### 3) 模型训练

该步骤同样在训练集  $\mathbf{D}_{\text{tra}}^H$  上进行。当改变历史用电量数据分辨率时, 可以得到不同的预测结果。在这里, 将高分辨率用电量序列压缩至低分辨率用电量序列的过程定义成一个映射模型  $F$ : 对于一个包含  $N$  天的小时用电量序列  $D^{24 \times N}$ , 有一个包含  $N$  天的压缩后用电量序列  $D^{M \times N}$  与之对应, 即

$$F: D^{24 \times N} \rightarrow D^{C \times N} \quad (7)$$

式中:  $C = 24/k$ ,  $k \in \mathbf{N}^+$ ,  $C \in \mathbf{N}^+$ ,  $k$  表示压缩尺度, 记  $k \in K = \{1, 2, 3, 4, 6, 8, 12, 24\}$ 。

$k$  值不同时, 可以得到不同压缩分辨率下的用电量序列。当  $k=1$  时, 表示不进行分辨率压缩; 当  $k=24$  时, 表示将一天 24 个小时的用电量数据加和为 1 个用电量数据。假设历史星期 “ $i$ ” 小时用电量序列  $\mathbf{D}_{\text{tra}}^{W_i}$  对应的压缩尺度为  $k_i$ , 此时, 压缩后序列的长度将从  $w_i$  变为  $w_i/k_i$ , 即

$$\text{Agg\_D}_{\text{tra}}^{W_i} = [\text{Agg\_D}_1^{W_i}, \dots, \text{Agg\_D}_{w_i/k_i}^{W_i}], i=1, \dots, 7 \quad (8)$$

$$\text{Agg\_D}_j^{W_i} = \sum_{n=k_i \cdot j - k_i + 1}^{k_i \cdot j} D_n^{W_i}, j=1, \dots, w_i/k_i, i=1, \dots, 7 \quad (9)$$

式中,  $\text{Agg\_D}_{\text{tra}}^{W_i}$  表示压缩后历史星期 “ $i$ ” 的历史用电量序列向量。

此时, 一个月的用电量可以表示为

$$D^M = \sum_{i=1}^7 \sum_{t=1}^{T_i/k_i} \text{Agg\_D}_t^{W_i} \quad (10)$$

为了突出本文所提出方法的思想, 仅选择历史用电量数据作为模型的输入特征。值得注意的是, 本文提出的预测方法同样可以考虑其他的相关因素(例如日历因素)。表 1 给出了在任意压缩尺度  $k$  下预测模型的输入与输出,  $h$  表示最高数据分辨率下

一天的采样点数, 此处  $h=24$ 。本文采用单输出模型结合滚动预测方法实现多步预测。图 2 给出了滚动预测的简单示意。

表 1 预测模型的输入与输出

Table 1 Input and output of the forecasting model

压缩尺度	模型输入	模型输出
$k_i$	$\begin{bmatrix} \text{Agg\_}D_{t-\frac{52h}{k_i}}^{W_i}, \text{Agg\_}D_{t-\frac{8h}{k_i}}^{W_i}, \text{Agg\_}D_{t-\frac{4h}{k_i}}^{W_i}, \\ \text{Agg\_}D_{t-8}^{W_i}, \dots, \text{Agg\_}D_{t-1}^{W_i} \end{bmatrix}$	$\text{Agg\_}D_t^{W_i}$

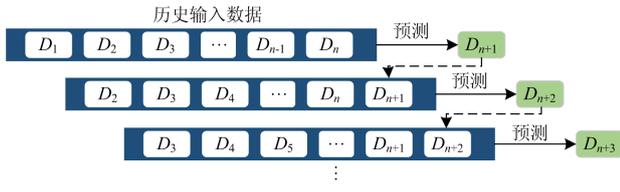


图 2 滚动预测示意图

Fig. 2 Schematic diagram of rolling forecasting

#### 4) 基于数据驱动的压缩优化

作为本文的核心之一, 该步骤在验证集  $D_{val}^H$  上进行。其目的是针对分解后的七个序列分别计算最优压缩尺度  $k_i^{best}$ ,  $i=1, \dots, 7$ , 记最优压缩尺度集合为  $\hat{k}^{best} = \{k_i^{best}\}$ ,  $i=1, \dots, 7$ 。然后将各分解并压缩后的序列的预测结果累加得到最终的预测结果。在这里, 将  $\hat{k}^{best}$  的选择建模成一个优化问题, 目标函数是使得月度用电量预测误差最小, 约束条件包括预测累加方程和压缩尺度集合限制。

$$\hat{k}^{best} = \arg \min_{k_i} (D^M - \hat{D}^M) \quad (11)$$

$$\text{s.t. } \hat{D}^M = \sum_{i=1}^7 \sum_{t=1}^{T_i/k_i} \text{Agg\_}D_t^{W_i}, \quad k_i \in K \quad (12)$$

式中,  $D^M$  和  $\hat{D}^M$  分别表示月度用电量的真实值和预测值。

### 3 长短期记忆神经网络

LSTM 是循环神经网络 (Recurrent Neural Network, RNN) 的一种特殊变体, 最初由 Hochreiter 和 Schmidhuber 于 1997 年提出。它具有 RNN 的所有优点, 同时克服了 RNN 梯度弥散和爆炸的缺点, 门结构的引入使其能够学习时间序列的长期依赖性<sup>[21-22]</sup>, 因此在各类非线性时间序列预测中表现优异。

LSTM 的基本网络结构和单元内部结构如图 3 和图 4 所示。其内部不包含神经元, 而是含有记忆细胞, 该记忆细胞可以被当作一个在  $t$  时刻具有状态  $c_t$  的记忆单元。此外, LSTM 还有三个自适应和乘法单元控制单元内的信息流, 包括输入门  $i_t$ 、输

出门  $o_t$  和遗忘门  $f_t$ 。信息流通过输入和输出门进入网络单元或其余部分, 而遗忘门则会重置记忆单元的状态。在执行学习任务时, LSTM 可以确定应该保留还是遗忘上一时刻单元的状态, 因此能很好地学习时间序列长期和短期的依赖关系, 相较于普通的神经网络更加适用于多步预测问题。

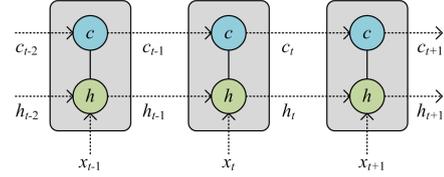


图 3 LSTM 网络结构

Fig. 3 LSTM network structure

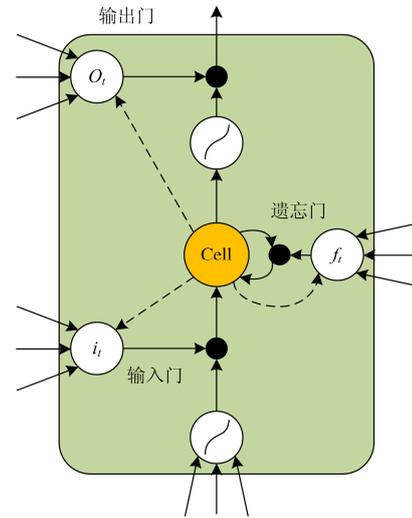


图 4 LSTM 单元

Fig. 4 LSTM unit

LSTM 单元和隐藏状态  $h_t$  可以由以下公式计算。

$$f_t = \sigma_g(W_f x_t + U_f h_{t-1} + b_f) \quad (13)$$

$$i_t = \sigma_g(W_i x_t + U_i h_{t-1} + b_i) \quad (14)$$

$$o_t = \sigma_g(W_o x_t + U_o h_{t-1} + b_o) \quad (15)$$

$$c_t = f_t \circ c_{t-1} + i_t \circ \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (16)$$

$$h_t = o_t \circ \tanh(c_t) \quad (17)$$

式中:  $f_t$ 、 $i_t$  和  $o_t$  分别表示遗忘门、输入门和输出门;  $W_f$ 、 $U_f$ 、 $W_i$ 、 $U_i$ 、 $W_o$ 、 $U_o$ 、 $W_c$  和  $U_c$  表示权重矩阵;  $b_f$ 、 $b_i$ 、 $b_o$  和  $b_c$  表示偏差向量;  $x_t$  表示当前的输入;  $h_{t-1}$  表示  $t-1$  时刻 LSTM 的输出;  $\sigma(\cdot)$  表示 Sigmoid 激活函数;  $\circ$  表示哈达玛积。

### 4 算例分析

本文实验数据来源于美国 PJM 电力市场。收集了其下某售电公司 2012 年 1 月 1 日至 2018 年 12

月 31 日的小时级用电量数据。其中,2012 年至 2016 年的数据被用作所提出方法的训练集,2017 年的数据被用作验证集,用于分辨率压缩优化。2018 年的数据被用作测试集,用于评估预测结果。

#### 4.1 数据预处理

##### 1) 异常值处理

由于数据采集通道以及存储设备的故障,历史数据中往往包含一些异常数据,它们将严重影响预测模型的性能。因此,本文采用文献[23]中提出的改进数据横向比较法对历史数据中包含的离群值(主要包括缺失值和异常值)进行识别和修正。

##### 2) 数据归一化

为提高算法的收敛速度并提升预测精度,本文采用最大最小标准化的方式,将原始数据线性映射至[0,1],其转换函数如式(18)。

$$D' = \frac{D - \min(D)}{\max(D) - \min(D)} \quad (18)$$

#### 4.2 算法及评价指标设置

本文实验工作在 Python3.7 中展开,仿真设备硬件配置为 Intel Core i5-7300HQ 2.50 GHz CPU,12 GB 内存。为验证本文所提出的分辨率压缩优化方法与 LSTM 算法的优越性,选择了 BP 神经网络和 SVM 作为对比算法。所有算法构建的预测模型都采用表 1 中的输入与输出样本对进行训练。

此外,本文采用了三种预测中常用的度量指标来衡量预测精度,包括平均绝对误差 MAE,平均绝对百分比误差 MAPE 和均方根误差 RMSE。

$$MAE = \frac{1}{L} \sum_{i=1}^L |D_i^M - \hat{D}_i^M| \quad (19)$$

$$MAPE = \frac{1}{L} \sum_{i=1}^L \frac{|D_i^M - \hat{D}_i^M|}{D_i^M} \times 100\% \quad (20)$$

$$RMSE = \frac{1}{L} \sqrt{\sum_{i=1}^L (D_i^M - \hat{D}_i^M)^2} \quad (21)$$

式中,  $L$  表示测试集中的样本个数。

#### 4.3 实验结果分析

为了证明本文提出的方法相较于传统的月度用电量预测方法所表现出来的优越性,首先利用 2012 年至 2018 年共 84 个月的月度用电量数据训练单步预测模型,对 2019 年 12 个月的用电量进行预测。此时,模型的输入为待预测月前 12 个月的用电量数据。

$$\text{Input} = [D_{t-12}^M, D_{t-11}^M, \dots, D_{t-2}^M, D_{t-1}^M] \quad (22)$$

为方便起见,将该预测方法记作方案 1。

方案 2: 此方案模拟了不进行分辨率压缩优化时,直接选用各种固定  $k$  值后得到的预测结果。

方案 3: 此方案为本文所提出的基于历史用电量序列分辨率压缩优化的月度电量预测方法。

表 2、表 3 展示了 LSTM 算法在三种预测方案下的预测结果的数值曲线和误差。可以看出,方案一的精度最低,其 MAPE 为 5.27%。从图 5 中也可以看出,方案一并不能很好地学习到用电量变化的趋势,特别是 1 月和 2 月的偏差较大。以上结果表明,传统的基于历史月度用电量数据训练的小样本预测方法并不能提供较高的预测精度。在方案二中,记录了 8 种压缩尺度下的预测结果。可见,当不进行数据压缩时( $k=1$ ),多步预测模型的待预测步长最长,因而预测精度相对其他压缩尺度来说最低,其 MAPE 为 4.72%。即便如此,模型的预测精度依然高于方案一,这表明所提出方法的第二步,即待预测步长初步分解确实有助于减少预测步长并提升预测精度。

表 2 LSTM 在不同方案下的预测结果

Table 2 Forecasting results of different schemes based on LSTM

月份	真实值/GWh	方案一预测值/GWh	方案二预测值/GWh								方案三预测值/GWh
			$k=1$	$k=2$	$k=3$	$k=4$	$k=6$	$k=8$	$k=12$	$k=24$	
1	8 845.9	8 221.5	8 941.7	9 231.3	8 916.5	8 971.0	8 938.7	8 794.3	8 892.4	8 945.7	8 944.5
2	7 627.3	8 230.9	7 325.4	7 841.6	7 515.2	7 412.1	7 423.3	7 346.9	7 290.6	7 477.8	7 458.5
3	7 802.8	7 486.5	7 913.5	8 229.4	8 019.3	7 933.9	7 980.0	7 790.4	7 788.9	7 754.9	7 978.3
4	7 301.3	7 273.5	7 228.3	7 290.4	7 113.6	7 169.2	7 072.8	7 053.6	7 093.0	7 187.2	7 145.8
5	8 083.4	7 807.6	7 565.3	7 472.7	7 437.2	7 476.0	7 402.2	7 366.3	7 528.5	7 661.0	7 342.8
6	8 736.6	8 510.4	8 301.2	8 662.8	8 813.0	8 594.5	8 888.9	8 923.2	8 992.9	8 821.8	8 638.3
7	9 895.6	9 290.4	8 851.7	9 423.7	9 408.6	9 096.5	9 438.0	9 289.6	9 548.7	9 447.1	9 459.2
8	10 029.5	8 997.0	8 680.7	9 062.4	9 123.4	8 912.4	8 941.8	8 819.4	8 902.2	9 246.2	8 965.4
9	8 302.3	7 741.4	7 816.4	8 142.4	8 247.2	7 982.2	8 469.0	8 261.9	8 377.2	7 955.3	8 275.4
10	7 453.2	7 191.7	7 588.0	7 559.5	7 556.5	7 602.8	7 551.1	7 675.5	7 692.2	7 777.1	7 533.1
11	7 652.9	7 141.0	7 450.7	7 460.6	7 384.3	7 431.0	7 485.2	7 393.5	7 603.5	7 568.1	7 398.7
12	8 092.8	7 732.0	8 376.4	8 689.2	8 586.7	8 498.5	8 561.8	8 501.5	8 679.0	8 585.7	8 535.5

表 3 LSTM 在不同方案下的误差比较

Table 3 Error comparison of different schemes based on LSTM

评价指标	方案一	方案二								方案三
		$k=1$	$k=2$	$k=3$	$k=4$	$k=6$	$k=8$	$k=12$	$k=24$	
MAE/GWh	450.6	419.5	351.3	302.0	363.9	331.9	353.6	320.0	283.3	311.8
MAPE/%	5.27	4.72	4.07	3.51	4.15	3.84	4.08	3.71	3.29	3.60
RMSE/GWh	515.6	567.2	441.8	399.1	475.3	437.7	483.8	440.9	356.3	432.2

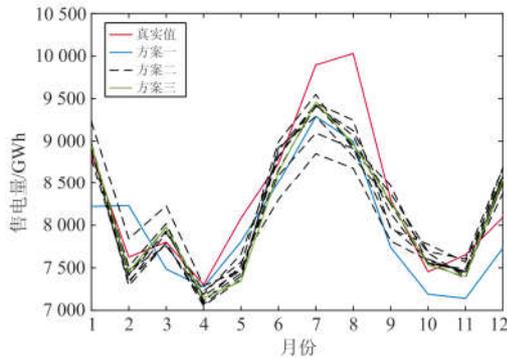


图 5 LSTM 在不同方案下的预测结果曲线  
Fig. 5 Forecasting result curves of different schemes based on LSTM

图 6 记录了不同压缩尺度下模型的预测精度。从中可以看出, 预测误差 MAPE 与压缩尺度之间并没有明显的线性关系, 也就是说很难找到一个保证预测精度的通用压缩尺度  $k$ 。根据表 3 中记录的方案 3 的预测误差与方案 2 的预测误差可以得出看出, 方案 3 的虽无法提供最高的预测精度, 其 MAPE 为 3.60%。但整体上来说其预测精度仅次于  $k=3$  (MAPE=3.51%) 和  $k=24$  (MAPE=3.29%) 的情况, 即在一定程度上可以解决压缩尺度选择问题。

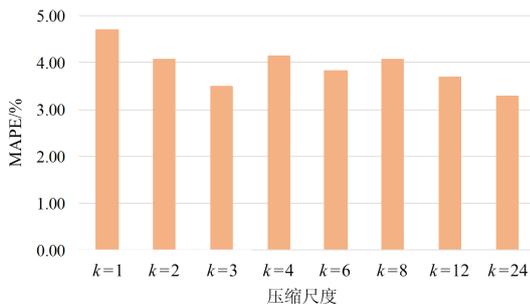


图 6 不同分辨率压缩尺度下的 MAPE 指标  
Fig. 6 MAPE at different resolution compression scales

表 4 记录了不同的预测算法在方案 3 框架下的预测精度。从中可以看出, 由于 LSTM 算法具有长短期记忆的功能, 其处理多步预测问题的能力要显著强于 BP 神经网络和 SVM, 因此在本文提出的预测框架下表现出了更好的预测性能。

表 4 不同预测算法的精度比较

Table 4 Forecasting accuracy comparison between different algorithms

评价指标	BP	SVM	LSTM
MAE/GWh	341.8	387.8	311.8
MAPE/%	3.83	3.95	3.60
RMSE/GWh	475.8	508.3	432.2

## 5 结论

1) 基于历史用电量序列分辨率压缩优化的月度电量预测方法可解决基于智能算法的预测模型在训练过程中存在样本分辨率选择不当导致预测精度降低的问题, 从而有效提升预测精度。

2) 预测步长的增大是导致利用高分辨率历史数据预测时精度降低的重要原因, LSTM 算法在进行多步预测时可以充分发挥其长短期记忆功能, 因此可以实现更为准确的预测。

## 参考文献

- [1] 中华人民共和国国务院. 关于进一步深化电力体制改革的若干意见(中发[2015]9号)文[Z/OL]. [2015-04-27]. <http://www.ne21.com/news/show-64828.html>.
- [2] 白杨, 谢乐, 夏清, 等. 中国推进售电侧市场化的制度设计与建议[J]. 电力系统自动化, 2015, 39(14): 1-7. BAI Yang, XIE Le, XIA Qing, et al. Institutional design of Chinese retail electricity market reform and related suggestions[J]. Automation of Electric Power Systems, 2015, 39(14): 1-7.
- [3] 石帮松, 张靖, 李博文, 等. 多类型售电公司共存下竞价售电的市场均衡研究[J]. 电力系统保护与控制, 2018, 46(5): 62-67. SHI Bangsong, ZHANG Jing, LI Bowen, et al. Market equilibrium study on multiple types of electric power retailers bidding[J]. Power System Protection and Control, 2018, 46(5): 62-67.
- [4] 郭曼兰, 陈皓勇, 张聪, 等. 偏差电量考核机制下售电公司的最优经营策略[J]. 电力系统自动化, 2017, 41(20): 17-25. GUO Manlan, CHEN Haoyong, ZHANG Cong, et al. Optimal marketing strategy of retailers under energy deviation penalty[J]. Automation of Electric Power Systems, 2017, 41(20): 17-25.
- [5] 薛斌, 程超, 欧世其, 等. 考虑舒适温度区间和突变量

- 的月售电量预测线性回归模型[J]. 电力系统保护与控制, 2017, 45(1): 15-20.
- XUE Bin, CHENG Chao, OU Shiqi, et al. A linear regression model for forecasting monthly electricity sales considering comfortable temperature range and sudden variable[J]. Power System Protection and Control, 2017, 45(1): 15-20.
- [6] SONG K B, BAEK Y S, HONG D H, et al. Short-term load forecasting for the holidays using fuzzy linear regression method[J]. IEEE Transactions on Power Systems, 2005, 20(1): 96-101.
- [7] YUAN C, LIU S, FANG Z. Comparison of China's primary energy consumption forecasting by using ARIMA (the autoregressive integrated moving average) model and GM(1,1) model[J]. Energy, 2016, 100: 384-390.
- [8] 张伏生, 刘芳, 赵文彬, 等. 灰色 Verhulst 模型在中长期负荷预测中的应用[J]. 电网技术, 2003, 27(5): 37-39.
- ZHANG Fusheng, LIU Fang, ZHAO Wenbin, et al. Application of grey Verhulst model in middle and long term load forecasting[J]. Power System Technology, 2003, 27(5): 37-39.
- [9] ABDULLAH A G. Hybrid PSO-ANN application for improved accuracy of short term load forecasting[J]. IEEE Transactions on Power Systems, 2014, 9(2): 446-451.
- [10] 李若晨, 朱帆, 朱永利, 等. 结合受限玻尔兹曼机的递归神经网络电力系统短期负荷预测[J]. 电力系统保护与控制, 2018, 46(17): 83-88.
- LI Ruochen, ZHU Fan, ZHU Yongli, et al. Short-term power load forecasting using recurrent neural network with restricted Boltzmann machine[J]. Power System Protection and Control, 2018, 46(17): 83-88.
- [11] CHARYTONIUK W, CHEN M S. Very short-term load forecasting using artificial neural networks[J]. IEEE Transactions on Power Systems, 2002, 17(1): 263-268.
- [12] 陈勇, 李鹏, 张忠军, 等. 基于 PCA-GA-LSSVM 的输电线路覆冰负荷在线预测模型[J]. 电力系统保护与控制, 2019, 47(10): 110-119.
- CHEN Yong, LI Peng, ZHANG Zhongjun, et al. Online prediction model for power transmission line icing load based on PCA-GA-LSSVM[J]. Power System Protection and Control, 2019, 47(10): 110-119.
- [13] EL-SAADAWI M, HATATA A. A novel protection scheme for synchronous generator stator windings based on SVM[J]. Protection and Control of Modern Power Systems, 2017, 2(3): 257-268. DOI: 10.1186/s41601-017-0057-x.
- [14] 王宁, 谢敏, 邓佳梁, 等. 基于支持向量机回归组合模型的中长期降温负荷预测[J]. 电力系统保护与控制, 2016, 44(3): 92-97.
- WANG Ning, XIE Min, DENG Jialiang, et al. Mid-long term temperature-lowering load forecasting based on combination of support vector machine and multiple regression[J]. Power System Protection and Control, 2016, 44(3): 92-97.
- [15] 吴潇雨, 和敬涵, 张沛, 等. 基于灰色投影改进随机森林算法的电力系统短期负荷预测[J]. 电力系统自动化, 2015, 39(12): 50-55.
- WU Xiaoyu, HE Jinghan, ZHANG Pei, et al. Power system short-term load forecasting based on improved random forest with grey relation projection[J]. Automation of Electric Power Systems, 2015, 39(12): 50-55.
- [16] 周念成, 廖建权, 王强钢, 等. 深度学习在智能电网中的应用现状分析与展望[J]. 电力系统自动化, 2019, 43(4): 180-197.
- ZHOU Niancheng, LIAO Jianquan, WANG Qianggang, et al. Analysis and prospect of deep learning application in smart grid[J]. Automation of Electric Power Systems, 2019, 43(4): 180-197.
- [17] HONG Weichang, DONG Yucheng, ZHANG Wenyu, et al. Cyclic electric load forecasting by seasonal SVR with chaotic genetic algorithm[J]. International Journal of Electrical Power and Energy Systems, 2013, 44(1): 604-614.
- [18] YALCINOZ T, EMINOGLU U. Short term and medium term power distribution load forecasting by neural networks[J]. Energy Conversion and Management, 2004, 46(9-10): 1393-1405.
- [19] GONZALEZ-ROMERA E, JARAMILLO-MORAN M A, CARMONA-FERNANDEZ D. Monthly electric energy demand forecasting based on trend extraction[J]. IEEE Transactions on Power Systems, 2006, 21(4): 1946-1953.
- [20] LI Zhenghui, LI Kangping, XUAN Zhiming, et al. Decomposition-accumulation principle based monthly electricity consumption forecasting approach using EMD-XGBoost hybrid model[C] // IEEE Sustainable Power & Energy Conference, November 21-23, 2019, Beijing, China: 2425-2430.
- [21] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [22] GRAVES A, MOHAMED A, HINTON G. Speech recognition with deep recurrent neural networks[C] // IEEE International Conference on Acoustics, Speech and Signal Processing, May 26-31, 2013, Vancouver, Canada.
- [23] 李光珍, 刘文颖, 云会周, 等. 母线负荷预测中样本数据预处理的新方法[J]. 电网技术, 2010, 34(2): 149-154.
- LI Guangzhen, LIU Wenyong, YUN Huizhou, et al. A new data preprocessing method for bus load forecasting[J]. Power System Technology, 2010, 34(2): 149-154.

收稿日期: 2019-05-15

作者简介:

王飞(1973—), 男, 通信作者, 工学博士, 教授/博导, 研究方向为新能源功率预测、综合能源与能源互联网、电力市场与需求响应; E-mail: feiwang@ncepu.edu.cn

李正辉(1996—), 男, 硕士研究生, 研究方向为电量预测与新能源功率预测。E-mail: zhenghuili@ncepu.edu.cn

(编辑 姜新丽)