

文章编号: 1673-8411(2019)03-0072-07

# LSTM 在宜昌短期电力负荷预测中的试验应用

张明<sup>1</sup>, 杜裕<sup>1\*</sup>, 洪国平<sup>2</sup>

(1. 湖北省宜昌市气象局, 宜昌 443000; 2. 武汉区域气候中心, 武汉 430074)

**摘要:** 利用宜昌市历史气象数据、电力负荷数据以及日期类型数据等建立 LSTM 网络模型, 通过逐步调优试验评估, 提出适用于宜昌电力负荷预测的 LSTM 网络模型方案。利用过去 48h 的历史气象资料、电力负荷资料以及节假日类型资料对当前时次的电力负荷预测效果最好, 平均绝对百分比误差可达到 1.79%; 对一天 24h 各时次的负荷进行直接预测时, 宜选用过去 72h 的历史资料及 51 个隐藏层单元, 其预测效果最好, 但效果仍远不如对单一时次的预测; 利用提出的模型分别对选取的三个个例进行单时次滚动预测及 24h 直接预测检验, 结果显示预测效果均较好, 平均 MAPE 均在 2% 以内, 表明提出的预测模型具有一定的可行性。

**关键词:** LSTM; 电力负荷; 神经元; 误差

**中图分类号:** P49

**文献标识码:** A

## Application of LSTM in Yichang Short-term Power Load Forecasting

Zhang Ming<sup>1</sup>, Du Yu<sup>1\*</sup>, Hong GuoPing<sup>2</sup>

(1. Yichang Meteorological Service, Yichang Hubei 443000; 2. Wuhan Regional Climate Center, Wuhan Hubei 430074)

**Abstract:** The LSTM network model is established by using the historical meteorological data, power load data and date type data of Yichang City. The LSTM network model scheme suitable for power load forecasting in Yichang City is put forward through step-by-step optimization test and evaluation. The results show that the historical meteorological data, power load data and holiday type data over the past 48 hours are the best for the current power load forecasting, with an average absolute percentage error of 1.79%. For direct load forecasting of 24 hours a day, the historical data of the past 72 hours and 51 hidden layer units should be selected, the forecasting effect is the best, but still far inferior to that of a single time. Using the proposed model, the single-time rolling prediction and 24-hour direct prediction tests were carried out for three selected cases respectively. The results show that the prediction effect is good, and the average MAPE is less than 2%, which indicates that the proposed prediction model is feasible.

**Keywords:** LSTM; power load forecasting; neuron; stepwise tuning

### 引言

电力负荷预测是电力调度的重要参考依据, 是电力系统稳定、经济运行的重要保障<sup>[1]</sup>。准确的电力负荷预测对实现合理调度, 电网安全、稳定和优质的运行有重要意义。随着科技的进步和业务的发展, 对气象服务有长期需求的宜昌供电公司电力负荷预测精度有了更高的要求, 如何

利用气象资料提高负荷预测精度亦成为亟待解决的问题。

国内外对短期电力负荷预测的研究主要有两大类。一类是时间序列统计学方法, 如张海东等<sup>[2]</sup>、张彦恒等<sup>[3]</sup>利用电力负荷与气温之间的联系建立了线性回归模型, 武辉芹等<sup>[4]</sup>、刘红亚等<sup>[5]</sup>建立了与多个气象因子之间的多元线性回归模型, 李钺等<sup>[6]</sup>、万昆等<sup>[7]</sup>建立了向量自回归模型, 这些

收稿日期: 2019-08-10

基金项目: 湖北省气象局课题“宜昌市电力负荷与气象因子关系及精细化预报方法研究”(2018J06)

作者简介: 张明(1987-), 男, 工程师, 主要研究领域为应用气象。E-mail: 475945482@qq.com

\* 通信作者: 杜裕, E-mail: 1142462598@qq.com

方法模型简单, 运行速度快, 但对影响电力负荷的非线性因素无法体现; 另一类是模型相对复杂的机器学习分析方法, 如潘锋等<sup>[8]</sup>、韩丽娜<sup>[9]</sup>使用支持向量机方法建立模型进行预测, 朱海兵等<sup>[10]</sup>、刘洋等<sup>[11]</sup>使用 BP 神经网络算法建立模型进行预测, 石德琳<sup>[12]</sup>使用 RNN 神经网络算法建立模型进行预测, 这些方法尽管在预测效果上有所提升, 但对时序数据之间存在的关联性考虑仍有所欠缺。同时, 在负荷预测研究中, 文献<sup>[1-5, 12]</sup>等加入气象因子建立模型时由于选用了预测时次或预测日的气象因子, 其在实际应用中亦会受到这些因子预测准确率的影响。

近年来, 深度学习在国内外广泛发展, 给研究者提供了解决负荷预测的新方法。随着电力系统对电力负荷以及气象部门对气象要素的采样频率、数据准确性的不断提升, 也为深度学习在负荷预测上的使用提供了数据基础。因此, 结合负荷数据中存在的时序及非线性特点, 可以有效挖掘序列数据中规律信息的 LSTM 网络模型逐渐被应用于负荷预测中, 并在近年来取得了较好的效果, 如陈卓<sup>[13]</sup>等、陈亮等<sup>[14]</sup>将 LSTM 网络模型应用于负荷预测中取得理想的效果, 周念成等<sup>[15]</sup>对深度学习在电力系统负荷预测的应用现状对比分析指出, 由于 LSTM 特有的门单元, 其对时序数据的预测精度较其他模型更高, 但随着输入因子等的不同, 预测效果不尽相同。为此, 本文利用历史气象因素、电力负荷以及节假日类型资料等建立 LSTM 网络模型, 并采用逐步调优进行预测结果评估, 以期为宜昌电力负荷预测提出更优方案, 从而为宜昌电网的运行调度提供参考依据。

## 1 预测模型

长短期记忆网络模型 (Long Short-Term Memory, LSTM) 是循环神经网络 (Recurrent Neural Networks, RNN) 的一种特殊类型, 适用于处理和预测时间序列中间隔或延迟相对较长的重要事件, 它由 Hochreiter 等<sup>[16]</sup>1997 年提出, 又由 Alex Graves 等<sup>[17-19]</sup>进行了改良和推广。

### 1.1 RNN 网络模型

RNN 网络模型包括输入层、隐藏层、输出层, 每一层又都由若干个神经元组成, 其中, 在隐藏层中有输入到下一时间隐藏层的连接。RNN 模型的输出层依赖于当前的输入以及记忆的隐藏信息, 其网络结构如图 1, 其中  $x_t$ 、 $s_t$ 、 $o_t$  分别代表  $t$  时刻的输入、“记忆”以及输出,  $U$ 、 $V$ 、 $W$  为输入输出共享的一组参数, 即激活参数, 可以由 tanh 或

Sigmoid 等激活函数得到。




图 1 RNN 网络结构图

理论上, 当时序间隔不断增大时, RNN 仍然可以处理长期依赖的问题, 但在实践中, 随着时间的推移, RNN 后面的节点对前面时间节点隐藏信息的感知能力下降, 即存在“梯度消失”的问题<sup>[20]</sup>, 从而导致预测性能下降。

### 1.2 LSTM 网络模型

鉴于 RNN 梯度消失的问题, Hochreiter 等提出了 LSTM 网络模型, 区别于 RNN 的地方主要为在隐藏层增加了遗忘门, 即在隐藏层算法中加入了一个判断信息是否有用的“处理器”<sup>[16]</sup>。后经 Alex Graves 等改良后进一步解决了网络训练过程中“梯度消失”或“梯度爆炸”的问题, 有效的避免了长期依赖问题。




图 2 LSTM 网络结构图

LSTM 网络结构如图 2 所示, 其主要是通过图中的输入门、遗忘门、输出门来实现数据序列信息的保护和控制, 其中  $x_t$ 、 $h_t$  分别为当前时刻的输入和输出。在遗忘门中, 由  $x_t$  和  $h_{t-1}$  经过 Sigmoid 函数共同输出一组 0 到 1 之间的数值向量  $f_t$  来决定当前的保留信息和遗忘信息; 在输入门中包含一个经 Sigmoid 函数决定的需要更新信息  $i_t$  以及一个经 tanh 函数生成的备选更新向量, 并与遗忘门生成的  $f_t$  以及前一时刻产生的状态单元  $C_{t-1}$  共同生成新的细胞状态; 在输出门部分由当前时刻的输入及前一时刻的输出经 Sigmoid 函数决定当前需要输出的部分, 并与经 tanh 函数处理后的细胞状态共同决定当前时刻的输出  $h_t$ 。各门部分的计算公式如式 (1) - 式 (3) 所示, 其中  $W$ 、 $b$  分别为相应门与输入  $x_t$ 、输出  $h_{t-1}$  相乘的矩阵权重及相应门的偏置项。

$$f_t = \sigma(W_f \cdot [h_{t-1} \times_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1} \times_t] + b_i)$$

$$C_t = \tanh(W_c \cdot [h_{t-1} \times_t] + b_c) \quad (2)$$

$$C_t = f_t * C_{t-1} + i_t * C_t$$

$$O_t = \sigma(W_o \cdot [h_{t-1} \times_t]) \quad (3)$$

$$h_t = O_t * \tanh(C_t)$$

### 1.3 模型评价指标

为了评估模型预测的性能,合理的选择影响因子的序列时数即输入层神经元个数及隐藏层神经元的个数,参考负荷预测的相关指标,本文对模型性能评判的标准主要选择平均绝对百分比误差(MAPE)以及均方根误差(RMSE)。

## 2 预测影响因子

国内外对电力负荷的研究表明,电力负荷受多个因素的影响。一般意义来讲,电力负荷可以为四个分量作用叠加而来<sup>[12]</sup>,即趋势负荷分量、天气敏感负荷分量、特殊事件如节假日负荷分量以及随机负荷分量,其中随机负荷分量表示随机产生的负荷分量,通常表示不可解释部分,其值较小,故通常将其忽略。

### 2.1 因子选择

对电力负荷的大量研究表明气象因子对负荷

预测有着重要影响,常见的影响因子包括温度、湿度、风等,因此,利用逐小时电力负荷与同期气象要素进行相关分析,最后,选取相关系数相对较高的因子作为相关因子(具体结果略),挑选出气压、最高气压、气温、最高气温、最低气温、相对湿度、2分钟风速、10分钟风速共8个要素。即LSTM网络模型中的输入层包括 $8*n$ (前 $n$ 个小时,下同)个气象因素神经元。

对于趋势负荷,表现为时间趋势,主要与时间相关。对于短期负荷预测,主要体现在一天24h中上下班以及节假日等的周期变化,同时,对于电力负荷本身,考虑其在短时期的总负荷变动较小,因此,本文选取前 $n$ 个小时的历史负荷来决定趋势负荷分量,即输入层包括 $n$ 个历史负荷神经元。

对于特殊事件带来的负荷影响,日期类型是一个极为重要的影响因素,非工作日的负荷量会比工作日显著减少。为区别工作日与非工作日,本文将工作日、周六日以及节假日分别以0、1、2(注:周六日因为节假日影响需要正常上班的按工作日处理)表示后,亦加入至输入层神经元。

本文选择在进行 $t$ 时刻预测时均已准确获取的因子特征,即前 $n$ 个时次的气象数据、负荷数据以及日期信息等作为预测的输入,具体如表1所示。

表1 输入因素汇总

| 因素   | 特征  | 描述                            |
|------|---|-------------------------------|
| 气象要素 | 气压、最高气压、气温、最高气温、最低气温、相对湿度、2分钟风速、10分钟风速等( $t-1$ , $t-2$ , ..., $t-n$ ) | 前 $n$ 个时次的逐小时气象因素值            |
| 日期因素 | 工作日 / 非工作日 / 节假日  | 前 $n$ 个时次以及预测时次的日期、特征值(0/1/2) |
| 历史数据 | 历史负荷( $t-1$ , $t-2$ , ..., $t-n$ )                                    | 前 $n$ 个时次的逐小时负荷值              |

### 2.2 资料来源及处理

#### 2.2.1 资料来源

文中使用宜昌市电力部门提供的2014~2017年的逐15min电力负荷资料,提取逐时负荷数据与日期类型资料以及宜昌市各国家气象站提供的同期气象资料作为LSTM网络模型数据集进行试验分析。

#### 2.2.2 资料处理

由于不同要素存在量级、单位等的不同,为避免这种不同对网络训练结果带来的不良影响,本文采用min-max标准化方法将数据进行线性变

换,使数据值映射到[0 - 1]之间。

## 3 试验分析

为测试、分析LSTM模型的预测效果,本文通过不断增加LSTM网络输入层的历史资料时次数进行逐步调优试验。

对隐藏层节点个数的选择通过简单的经验公式<sup>[12]</sup>确定,即:

$$L = \sqrt{x+y} + a \quad (4)$$

其中,  $L$  为隐藏层节点个数,  $x$  为输入层节点个数,  $y$  为输出层节点个数,  $\alpha$  为  $1 \sim 10$  之间的常数。

本文分别对单时次滚动预测和 24h 直接预测建立模型。其中, 单时次滚动预测, 即利用  $t-1$ 、 $t-2$ 、 $\cdots$ 、 $t-n$  等  $n$  个时次的资料预测  $t$  时刻的电力负荷, 利用  $t$ 、 $t-1$ 、 $\cdots$ 、 $t-n+1$  等  $n$  个时次的资料预测  $t+1$  时刻的电力负荷, 以此类推; 24h 直接预测, 即利用  $t-1$ 、 $t-2$ 、 $\cdots$ 、 $t-n$  等  $n$  个时次的资料直接预测  $t$ 、 $t+1$ 、 $\cdots$ 、 $t+23$  等连续 24h 各时刻的电力负荷。

### 3.1 输入层调优

为测试输入层不断变化时对预测结果的影响, 选取  $\alpha=5$  来评估不同  $n$  情况对电力负荷的单时次滚动预测效果。试验结果如表 2 所示, 可以看到: 一是通过适当增加历史资料时次数可以提高 LSTM 模型的预测能力, 但增加到一定时次后, 其误差又会上升, 表明存在过度拟合; 二是利用 LSTM 模型进行宜昌短期电力负荷预测时, 宜选用过去 48h 的历史资料。

表 2 输入层调优试验结果

| $n$         | 1h    | 2h    | 3h    | 6h    | 12h   | 24h   | 36h   | 48h   | 72h   |
|-------------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| MAPE 平均 (%) | 2.51  | 2.44  | 2.40  | 2.29  | 2.24  | 1.98  | 1.97  | 1.91  | 1.94  |
| RMSE (MW)   | 62.05 | 58.14 | 61.56 | 58.14 | 54.43 | 48.26 | 48.45 | 47.82 | 53.95 |

### 3.2 隐藏层调优

根据输入层调优试验确定的历史资料时次数, 选择不同  $\alpha$  对应的隐藏层节点数进行预测试验。

试验结果如表 3, 可以看到一是随着  $\alpha$  的变化, LSTM 的预测能力呈现出波动状态, 同时在取值 5 以上后对预测的结果影响较小; 二是  $\alpha$  取 8 时, 预测结果最好, 其 MAPE 可达到 1.79%。

表 3 隐藏层调优试验结果

| $\alpha$ 取值 | 1     | 2     | 3     | 4     | 5     | 6     | 7     | 8     | 9     | 10    |
|-------------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| MAPE 平均 (%) | 2.00  | 1.86  | 1.83  | 2.16  | 1.92  | 1.92  | 1.89  | 1.79  | 1.89  | 1.89  |
| RMSE (MW)   | 49.84 | 45.71 | 44.80 | 50.99 | 47.81 | 47.43 | 46.39 | 44.52 | 46.66 | 46.12 |

### 3.3 24h 直接预测试验

根据前期试验结果, 选择预测效果最好的  $n$  及  $\alpha$  进行 24h 直接预测试验, 结果如表 4。可以看到, 预测结果相比单时次滚动预测的误差明显要大, 而且随着时次越往后, 其误差也相对更大, 表明选择同样的  $n$  及  $\alpha$  对多时次的预测能力下降。

为优化 24h 直接预测模型, 同样采取输入层、隐藏层逐步调优的方式进行试验。根据逐步试验结果, 依据模型评价指标, 在使用过去 72h 历史

资料及 51 个隐藏层单元时, 预测效果最好, 结果如表 5。可以看到, 预测效果有明显改善, 但效果仍不如单时次滚动预测, 且随着预测时次越往后, 其预测能力依然随之有所下降, 这可能是由多个方面造成: 一是尽管 LSTM 解决了 RNN 的梯度消失问题, 但并没有解决全部问题, 即它从输入到输出能够记忆大量长期的信息, 但随着输出层的增加其记忆能力有所下降; 二是随着输出层的增加, 预测模型的复杂度随之成倍增长, 从而导致预测能力下降。

表 4 24h 预测误差

| 时间 /h       | 1    | 2    | 3    | 4    | 5    | 6    | 7    | 8    | 9    | 10   | 11   | 12   |
|-------------|------|------|------|------|------|------|------|------|------|------|------|------|
| MAPE 平均 (%) | 2.73 | 2.83 | 2.98 | 2.89 | 2.90 | 2.91 | 2.96 | 3.02 | 3.04 | 3.13 | 3.14 | 3.14 |
| 时间 /h       | 13   | 14   | 15   | 16   | 17   | 18   | 19   | 20   | 21   | 22   | 23   | 24   |
| MAPE 平均 (%) | 3.19 | 3.13 | 3.14 | 3.17 | 3.19 | 3.12 | 3.08 | 3.07 | 3.09 | 3.11 | 3.12 | 3.17 |



表 5 24h 预测最优试验结果

| 时间 /h       | 1    | 2    | 3    | 4    | 5    | 6    | 7    | 8    | 9    | 10   | 11   | 12   |
|-------------|------|------|------|------|------|------|------|------|------|------|------|------|
| MAPE 平均 (%) | 2.27 | 2.33 | 2.66 | 2.75 | 2.80 | 2.82 | 2.92 | 2.98 | 2.95 | 2.99 | 2.97 | 2.96 |
| 时间 /h       | 13   | 14   | 15   | 16   | 17   | 18   | 19   | 20   | 21   | 22   | 23   | 24   |
| MAPE 平均 (%) | 3.00 | 2.97 | 3.03 | 2.91 | 2.90 | 2.78 | 2.81 | 2.80 | 2.85 | 2.82 | 2.81 | 2.83 |

3.4 模型应用验证

根据前期的试验评估结果，对 2018 年 4 月 12 日（工作日）、4 月 14 日（非工作日）、4 月 29 日（法定节假日）三天分别进行单时次滚动预测及 24h 直接预测验证，其结果如表 6、表 7。对比两表可知，一是对于工作日和非工作日两者的预

测 MAPE 基本一样，而对于节假日，24h 直接预测的效果更好；二是对于工作日与非工作日的预测，两者对各时次的预测除个别时次外，MAPE 基本都在 2% 以内。总体而言，预测模型在这三天中的预测效果均较好，平均 MAPE 均在 2% 以内，表明提出的预测模型具有一定的可行性。

表 6 单时次滚动预测验证

| 日期   | 4 月 12 日      |               |             | 4 月 14 日      |               |             | 4 月 29 日      |               |             |
|------|---------------|---------------|-------------|---------------|---------------|-------------|---------------|---------------|-------------|
| 预测时次 | 实际值<br>(MW·h) | 预测值<br>(MW·h) | MAPE<br>(%) | 实际值<br>(MW·h) | 预测值<br>(MW·h) | MAPE<br>(%) | 实际值<br>(MW·h) | 预测值<br>(MW·h) | MAPE<br>(%) |
| 0    | 1758.6        | 1787.3        | 1.6         | 1704.9        | 1711.0        | 0.4         | 1785.1        | 1776.3        | 0.5         |
| 1    | 1773.4        | 1742.2        | 1.8         | 1705.5        | 1672.8        | 1.9         | 1789.2        | 1743.6        | 2.5         |
| 2    | 1766.8        | 1734.0        | 1.9         | 1723.3        | 1664.1        | 3.4         | 1724.3        | 1732.9        | 0.5         |
| 3    | 1700.7        | 1728.8        | 1.6         | 1678.3        | 1682.4        | 0.2         | 1718.0        | 1700.3        | 1.0         |
| 4    | 1722.0        | 1695.5        | 1.5         | 1681.5        | 1687.9        | 0.4         | 1692.7        | 1698.7        | 0.3         |
| 5    | 1704.2        | 1716.9        | 0.7         | 1708.9        | 1724.9        | 0.9         | 1767.4        | 1722.8        | 2.5         |
| 6    | 1728.1        | 1753.3        | 1.5         | 1779.8        | 1781.0        | 0.1         | 1824.4        | 1827.3        | 0.2         |
| 7    | 1826.8        | 1821.1        | 0.3         | 1844.9        | 1846.8        | 0.1         | 1869.0        | 1935.0        | 3.5         |
| 8    | 1905.8        | 1935.6        | 1.6         | 1936.1        | 1877.5        | 3.0         | 1919.5        | 1930.3        | 0.6         |
| 9    | 1959.3        | 1983.6        | 1.2         | 1937.1        | 1914.2        | 1.2         | 1898.4        | 1897.7        | 0.0         |
| 10   | 1923.7        | 1962.4        | 2.0         | 1929.6        | 1926.0        | 0.2         | 1908.5        | 1930.1        | 1.1         |
| 11   | 1934.3        | 1953.7        | 1.0         | 1901.7        | 1919.6        | 0.9         | 1846.8        | 1964.7        | 6.4         |
| 12   | 1850.1        | 1975.8        | 6.8         | 1846.3        | 1932.5        | 4.7         | 1830.8        | 1945.6        | 6.3         |
| 13   | 1878.8        | 1930.9        | 2.8         | 1889.1        | 1898.2        | 0.5         | 1897.1        | 1938.9        | 2.2         |
| 14   | 1926.4        | 1940.1        | 0.7         | 1873.5        | 1920.8        | 2.5         | 1923.7        | 1984.5        | 3.2         |
| 15   | 1955.9        | 1981.8        | 1.3         | 1890.8        | 1915.6        | 1.3         | 1952.3        | 2009.6        | 2.9         |
| 16   | 1859.7        | 2009.2        | 2.5         | 1904.7        | 1918.9        | 0.7         | 1947.1        | 2011.1        | 3.3         |
| 17   | 2016.1        | 1985.3        | 1.5         | 1856.7        | 1916.7        | 3.2         | 1890.6        | 1947.2        | 3.0         |
| 18   | 1968.7        | 1953.0        | 0.8         | 1875.7        | 1881.1        | 0.3         | 1865.3        | 1870.9        | 0.3         |
| 19   | 1901.1        | 1910.0        | 0.5         | 1875.2        | 1879.2        | 0.2         | 1913.0        | 1887.8        | 1.3         |
| 20   | 1893.2        | 1895.7        | 0.1         | 1877.3        | 1866.4        | 0.6         | 1912.0        | 1923.0        | 0.6         |
| 21   | 1882.0        | 1888.0        | 0.3         | 1857.5        | 1843.6        | 0.7         | 1894.6        | 1905.7        | 0.6         |
| 22   | 1859.3        | 1867.2        | 0.4         | 1786.6        | 1813.5        | 1.5         | 1819.6        | 1862.8        | 2.4         |
| 23   | 1786.3        | 1836.7        | 2.8         | 1777.5        | 1756.4        | 1.2         | 1810.7        | 1801.0        | 0.5         |
| 平均   |               |               | 1.6         |               |               | 1.3         |               |               | 1.9         |

表 7 24h 直接预测验证

| 日期   | 4 月 12 日      |               |             | 4 月 14 日      |               |             | 4 月 29 日      |               |             |
|------|---------------|---------------|-------------|---------------|---------------|-------------|---------------|---------------|-------------|
| 预测时次 | 实际值<br>(MW·h) | 预测值<br>(MW·h) | MAPE<br>(%) | 实际值<br>(MW·h) | 预测值<br>(MW·h) | MAPE<br>(%) | 实际值<br>(MW·h) | 预测值<br>(MW·h) | MAPE<br>(%) |
| 0    | 1758.6        | 1812.0        | 3.0         | 1704.9        | 1723.9        | 1.1         | 1785.1        | 1785.2        | 0.0         |
| 1    | 1773.4        | 1775.9        | 0.1         | 1705.5        | 1696.8        | 0.5         | 1789.2        | 1747.3        | 2.3         |
| 2    | 1766.8        | 1747.6        | 1.1         | 1723.3        | 1678.5        | 2.6         | 1724.3        | 1726.8        | 0.1         |
| 3    | 1700.7        | 1732.1        | 1.8         | 1678.3        | 1686.2        | 0.5         | 1718.0        | 1729.7        | 0.7         |
| 4    | 1722.0        | 1726.9        | 0.3         | 1681.5        | 1720.1        | 2.3         | 1692.7        | 1742.2        | 2.9         |
| 5    | 1704.2        | 1734.8        | 1.8         | 1708.9        | 1766.4        | 3.4         | 1767.4        | 1783.1        | 0.9         |
| 6    | 1728.1        | 1772.2        | 2.6         | 1779.8        | 1819.3        | 2.2         | 1824.4        | 1824.7        | 0.0         |
| 7    | 1826.8        | 1826.3        | 0.0         | 1844.9        | 1856.6        | 0.6         | 1869.0        | 1855.8        | 0.7         |
| 8    | 1905.8        | 1888.9        | 0.9         | 1936.1        | 1880.2        | 2.9         | 1919.5        | 1898.7        | 1.1         |
| 9    | 1959.3        | 1929.2        | 1.5         | 1937.1        | 1879.6        | 3.0         | 1898.4        | 1904.2        | 0.3         |
| 10   | 1923.7        | 1958.5        | 1.8         | 1929.6        | 1868.8        | 3.2         | 1908.5        | 1911.0        | 0.1         |
| 11   | 1934.3        | 1952.0        | 0.9         | 1901.7        | 1858.9        | 2.2         | 1846.8        | 1914.6        | 3.7         |
| 12   | 1850.1        | 1942.4        | 5.0         | 1846.3        | 1879.1        | 1.8         | 1830.8        | 1937.1        | 2.8         |
| 13   | 1878.8        | 1933.8        | 2.9         | 1889.1        | 1900.2        | 0.6         | 1897.1        | 1940.4        | 2.3         |
| 14   | 1926.4        | 1941.1        | 0.8         | 1873.5        | 1916.2        | 2.3         | 1923.7        | 1946.4        | 1.2         |
| 15   | 1955.9        | 1943.5        | 0.6         | 1890.8        | 1906.5        | 0.8         | 1952.3        | 1943.7        | 0.4         |
| 16   | 1859.7        | 1954.0        | 0.3         | 1904.7        | 1900.2        | 0.2         | 1947.1        | 1941.3        | 3.3         |
| 17   | 2016.1        | 1943.8        | 3.6         | 1856.7        | 1884.6        | 1.5         | 1890.6        | 1915.7        | 1.3         |
| 18   | 1968.7        | 1932.5        | 1.8         | 1875.7        | 1869.9        | 0.3         | 1865.3        | 1916.0        | 2.7         |
| 19   | 1901.1        | 1927.3        | 1.4         | 1875.2        | 1863.4        | 0.6         | 1913.0        | 1913.5        | 0.0         |
| 20   | 1893.2        | 1901.7        | 0.5         | 1877.3        | 1865.8        | 0.6         | 1912.0        | 1904.3        | 0.4         |
| 21   | 1882.0        | 1891.0        | 0.5         | 1857.5        | 1833.2        | 1.3         | 1894.6        | 1890.7        | 0.2         |
| 22   | 1859.3        | 1870.6        | 0.6         | 1786.6        | 1809.5        | 1.3         | 1819.6        | 1861.8        | 2.3         |
| 23   | 1786.3        | 1844.7        | 3.3         | 1777.5        | 1757.7        | 1.1         | 1810.7        | 1810.5        | 0.0         |
| 平均   |               |               | 1.5         |               |               | 1.5         |               |               | 1.2         |

## 4 小结

利用 LSTM 模型在宜昌市短期电力负荷预测中的试验情况得到主要结论如下:

(1) 利用过去 48h 的历史气象资料、电力负荷资料及节假日类型资料对电力负荷的单时次滚动预测效果最好, 平均绝对百分比误差可达到 1.79%。

(2) 对连续 24h 的电力负荷直接预测时, 宜选用过去 72h 的历史资料及 51 个隐藏层单元数。

LSTM 尽管可以有效的兼顾时间序列数据的时序性及非线性关系, 但通过本文的试验, 其仍然存在一些局限性, 即在进行多时次的预测时, 其效果有所下降, 且随着时序的延长, 其效果会更差。

在后续的研究中将进一步对网络模型进行优

化。一是在输入层加入更多的影响因子, 如加入前  $n$  天同一时刻的电力负荷、周一至周日 7 种日期类型、电价因素等; 二是在考虑优化输入因子的情况下优化网络层数, 提高预测能力。

### 参考文献:

- [1] 王增平, 赵兵, 纪维佳, 等. 基于 GRU-NN 模型的短期负荷预测方法 [J]. 电力系统自动化, 2019, 43(5): 53-58.
- [2] 张海东, 孙照渤, 郑艳, 等. 温度变化对南京城市电力负荷的影响 [J]. 大气科学学报, 2009, 32(4): 536-542.
- [3] 张彦恒, 杨琳晗, 武辉芹, 等. 冀北电网电力负荷特征与气温的关系 [J]. 干旱气象, 2016, 34(5): 881-885.

(下转第97页)

软件后, 有时候地图没有载入。针对以上问题, 采取以下方法来解决: (1) 将加密后的数据库挂到外网服务器上, 只要电脑能上外网, 就可以使用; (2) 增加在地图上自定义区域的保存功能; (3) 对可射击区域最小面块方位划分为 15 度; (4) 打开软件后, 重新选择一次所需要的地图, 便可实现地图的载入。

## 5 结语

广西人影安全射界绘制系统实现了专人负责对人工影响天气作业点安全射界的绘制、审核工作, 针对作业站点周围环境变化可以及时更新安全射界图, 提高了人影安全射界图的规范化和自动化程度, 达到了提高人影安全射界管理安全性的目的。本系统还预留了未来接入其它物联网管理系统和业务软件平台的接口, 以便软件后期的扩展。

### 参考文献:

- [1] 龚佃利, 孙建东, 杨凡, 等. 《37mm 高炮人工影响天气作业点安全射界图绘制规范》[S]. 北京: 中国气象局, QX/T 256-2015.
- [2] 杨凡, 孙琪, 孟繁辉, 等. 安全射界图技术在人工影响天气指挥系统中的应用[J]. 气象科技, 2014, 42: 511-515.
- [3] 杨云, 陈英, 彭晓霞, 等. 基于卫星地图的人工影响天气安全射界图研究[J]. 电子技术与软件工程, 2016(17): 168.
- [4] 孙建东, 卢培玉, 周茂山. 人影安全射界图的设计原理及制作应用[J]. 山东气象, 2010, 30(3): 37-41.
- [5] 毕力格, 佟小林, 李汉超. 人影地面作业安全射界分析系统的设计与实现[J]. 电子测量技术, 2017, 40(6): 1-4+14.
- [6] 王跃宁. 基于 GIS 平台与 C/S 架构人影作业安全射界图设计制作[A]. 第 35 届中国气象学会年会 S16 人工影响天气理论与应用技术研讨[C]. 中国气象学会, 2018: 6.
- [7] 航天科技集团公司四院四十一所. R 增雨防雹火箭作业系统[S]. 西安: 航天科技集团公司四院四十一所, 2002: 15-16.
- [8] 段成国, 杨煜珍. 人影安全射界图的设计原理与制作[J]. 科技传播, 2012, 4(15): 162-163.
- [9] 刘德安, 王新光. 人工影响天气作业点安全管理方法探讨[J]. 山东气象, 2010, 30(4): 57-58.
- [10] 郝克俊, 王维佳, 徐精忠. 关于地面人工影响天气安全管理的思考[J]. 黑龙江气象, 2010, 27(3): 33-34.
- [11] 廖雪萍. 《气象研究与应用》应对数字化变革之实践——纪念《气象研究与应用》创刊 60 周年[J]. 气象研究与应用, 2017, 38(1): 5-6.
- [12] 李耀先, 覃峥嵘. 撰写气象论文的几点注意事项[J]. 广西气象, 2004, (4): 53-55+50.
- [4] 武辉芹, 张金满, 曲晓黎. 河北省南部电网夏季电力负荷特征及与气象因子的关系[J]. 气象科技, 2013, 41(5): 945-948.
- [5] 刘红亚, 曹亮. 上海市电力负荷与气象因子关系及精细化预报[J]. 应用气象学报, 2013, 24(4): 455-463.
- [6] 李钜, 李敏, 等. 基于改进回归法的电力负荷预测[J]. 电网技术, 2006, 30(1): 99-104.
- [7] 万昆, 柳瑞禹. 区间时间序列向量自回归模型在短期电力负荷预测中的应用[J]. 电网技术, 2012, 36(11): 77-81.
- [8] 潘锋, 储琳琳, 张宇俊. 考虑气象因素的 SVM 方法在短期电力负荷预测中的应用[J]. 华东电力, 2007, 35(11): 86-89.
- [9] 韩丽娜. 杭州地区电力负荷特性的分析及预测[D]. 浙江大学, 硕士学位论文, 2008.
- [10] 朱海兵, 崔玉, 熊浩. 基于改进型 BP 神经网络的电网负荷预测[J]. 现代电子技术, 2016, 39(20): 64-66.
- [11] 刘洋, 许立雄. 适用于海量负荷数据分类的高性能反向传播神经网络算法[J]. 电力系统自动化, 2018, 42(21): 96-103.
- [12] 石德琳. 基于神经网络的电力负荷预测研究与实现[D]. 山东大学硕士学位论文, 2016.
- [13] 陈卓, 孙龙祥. 基于深度学习 LSTM 网络的短期电力负荷预测方法[J]. 电子技术设计与应用, 2018, 47(1): 39-41.
- [14] 陈亮, 王震, 王刚. 深度学习框架下 LSTM 网络在短期电力负荷预测中的应用[J]. 电力信息与通信技术, 2017, 15(5): 8-11.
- [15] 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): 180-191.
- [16] Hochreiter S. and Schmidhuber J. Long Short-Term Memory[J]. Neural computation, 1997, (9): 1735-1780.
- [17] Alex Graves, Jurgen Schmidhuber. Framewise phoneme classification with bidirectional LSTM and other neural network architectures[J]. Neural Networks, 2005, 18(5): 602-610.
- [18] Alex Graves. Supervised sequence labelling with recurrent neural networks[M]. Berlin: Springer, 2012: 37-45.
- [19] Alex Graves, Navdeep Jaitly, Abdel-rahman Mohamed. Hybrid speech recognition with Deep Bidirectional LSTM[J]. Automatic Speech Recognition and Understanding (ASRU), IEEE Workshop, 2013.
- [20] Y. Bengio, P. Simard, and P. Frasconi. Learning long-term dependencies with gradient descent is difficult[J]. Neural Networks, 1994, (5): 157-166.

(上接第77页)