

# 基于 ARIMA-LSTM 模型的综合能源系统负荷与风光资源预测

王 鑫<sup>1</sup>, 李安桂<sup>1</sup>, 李 扬<sup>1</sup>, 卜令晨<sup>1</sup>, 彭怀午<sup>2</sup>, 牛东圣<sup>2</sup>, 许晨琛<sup>2</sup>, 韩 欧<sup>1</sup>

(1. 西安建筑科技大学 建筑设备科学与工程学院, 陕西 西安, 710055;

2. 太阳能利用工程技术研究所, 中国电建集团西北勘测设计研究院有限公司, 陕西 西安, 710065)

**摘要:** 在能源互联网快速发展的背景下, 研究分析了综合能源系统的多元负荷预测模型及理论方法。针对传统 ARIMA (Autoregressive Moving Average Model, ARMA) 模型仅能处理线性关系的问题, 将 ARIMA 模型与 LSTM (Long-Short Term Memory, LSTM) 网络模型结合, 提出并建立了 ARIMA-LSTM 模型。该模型不仅兼容冷、热、气、电等多元负荷的预测, 并且可以用于风速、辐射照度等数据的预测, 有较好的适应性和预测精度。

**关键词:** 综合能源系统; 负荷预测; 构建模型; 误差分析

中图分类号: TU111.19<sup>+</sup> 5.4; TK 01

文献标志码: A

文章编号: 1006-7930(2022)05-0762-08

## Multivariate load prediction and wind-solar resource characteristic quantity prediction of integrated energy system based on ARIMA-LSTM model

WANG Xin<sup>1</sup>, LI Angui<sup>1</sup>, LI Yang<sup>1</sup>, BU Lingchen<sup>1</sup>, PENG Huaiwu<sup>2</sup>,  
NIU Dongsheng<sup>2</sup>, XU Chenchen<sup>2</sup>, HAN Ou<sup>1</sup>

(1. School of Building Services Science and Engineering, Xi'an Univ. of Arch. & Tech., Xi'an 710055, China

2. Institute of Solar Engineering Technology, Northwest Engineering Corporation Limited,  
Power China, Xi'an 710065, China)

**Abstract:** Under the background of the rapid development of energy Internet, this paper studies and analyzes the multivariate load prediction and theoretical method of integrated energy system. Aiming at the problem that the traditional ARIMA model can only deal with the linear relationship, the ARIMA-LSTM model is proposed and established by combining ARIMA model with LSTM ( Long-Short Term Memory, LSTM ) network model. The model is not only compatible with the prediction of multiple loads such as cold, heat, gas and electricity, but also can be used for the prediction of wind speed, radiation illumination and other data, and has good adaptability and prediction accuracy.

**Key words:** integrated energy system; load forecasting; construction model; error analysis

在人类提高环保意识和改变能源结构的呼声中, 能源互联网应运而生, 为应对能源危机提供了新思路, 成为学者研究重点<sup>[1]</sup>。能源互联网主要通过互联网技术, 将新能源利用技术、计算机信息技术与新型电力网络相结合, 从而实现能量的双向流动<sup>[2]</sup>。该技术改变了电力系统传统的发配输用四个环节, 是当前应对能源问题和推动能源系统发生变革的重要方式, 而综合能源系统能发挥

载体作用, 承载能源互联网进行能源整合和高效利用等工作<sup>[3]</sup>。因此, 研究综合能源系统对我国改变能源消费结构, 提高能源利用效率以及可再生能源消费占比有重要意义。

国内外研究机构和高校在综合能源系统的计算模型与求解方法等研究上已取得大量的成果<sup>[4]</sup>, 但是对综合能源系统负荷预测的研究较少, 多用负荷模拟软件模拟, 这种方法得到的负荷偏差较

收稿日期: 2021-07-30 修改稿日期: 2022-10-08

基金项目: 十二五国家科技支撑课题合作单位基金资助项目(2011BAJ03B03-5)

第一作者: 王 鑫(1996—), 男, 硕士, 主要研究方向为综合能源系统。E-mail: xjd\_wangxin@163.com

通信作者: 李安桂(1963—), 男, 博士生导师, 主要研究建筑通风空调气流组织、地下空气环境、太阳能建筑一体化等。E-mail: liangui@xauat.edu.cn

大且不能用于动态预测, 同时, 在综合能源系统规划设计计算中, 存在风电等清洁能源出力不确定性难题<sup>[5]</sup>. 预测风光资源特征量(风速和辐射照度)可以有效预测风光发电设备出力, 因此研究预测技术对综合能源系统的规划设计计算以及削减风光发电设备出力不确定性有着重要意义.

负荷预测是综合能源系统设计、运行、控制的基础<sup>[6]</sup>. 关于预测方法, 以往学者做了很多研究. 文献[7]基于模糊理论与时间序列, 提出了模糊时间序列方法负荷预测模型, 在短期负荷预测上有较好的准确度. 文献[8]根据我国 20 年间逐年的能源生产总量数据, 运用 ARMA(Autoregressive Moving Average Model, ARMA)模型对我国能源生产进行了预测, 预测结果与我国能源生产情况趋势相同, 证明了时间序列预测法适用性广泛的特点. 文献[9]改进了 Elman 网络( global feed forward local recurrent, Elman), 采用相关系数预处理和样本异常值平均化处理, 将 Elman 网络的输入层变量大幅精简, 减少了预测的时间并提高了预测精度.

近年来, 大量的研究表明, 建立优势互补的混合模型或改进模型能够提高预测的精度. 文献[10]提出了由时间序列法和神经网络结合的混合模型, 得到了很好的预测结果, 并指出, 混合模型相对于两个原模型, 均方根误差降低了 40%, 文献[11]基于神经网络和模糊推理提出了新的混合预测模型, 综合模型在预测短期负荷时, 预测结果更贴合实际. 文献[12]基于混沌理论和神经网络构建了混合模型, 用混沌理论去优化神经网络, 得到预测结果更好的混合模型. 文献[13]结合遗传算法和神经网络构建了混合模型, 用遗传算法优化人工神经网络相关参数, 得到更好的参数设置, 再用优化后的神经网络预测负荷, 将平均百分比误差降低了 2%~4%. 文献[14]提出了一种改进的 PSO-BP 神经网络算法预测大型公共建筑的冷负荷. 通过对输入变量与输出结果进行灰色关联度分析, 确定影响冷负荷的关键性因素, 将其作为输入变量, 提高了预测结果的精确度, 在算例中使用改进模型, 将均方根误差从 20% 降低至 7%. 文献[15]提出一种基于相似日 LM(Levenberg-Marquardt, LM)神经网络的高校图书馆能耗预测模型, 改进后的预测模型与传统预测模型的各项指标进行对比分析. 依据对比结果可知,

改进后模型的平均绝对百分比误差降低了 1.28% 达到 11% 左右, 改进模型预测精度有明显提升.

上述研究表明混合模型和改进模型相对于传统模型, 通常可以降低一定的预测误差, 在负荷预测研究中使用广泛. 但是, 负荷预测研究中, 电负荷预测研究出现较早, 热负荷、风光资源数据预测研究起步相对较晚<sup>[13]</sup>. 近年来, 大量的综合能源系统已经部署完成或者正在部署中, 综合能源系统所需要的负荷数据, 包括园区热、冷、电、气负荷, 且不乏有对风电出力有预测需求的系统, 负荷的多样化使得实现综合园区综合能源系统动态管理的关键难题之一就是更通用的负荷预测技术, 尤其是综合能源系统在管理时所需的短期负荷预测技术, 且需有较好的适用性, 能在没有历史运行数据或者运行数据较少时完成预测任务, 并需要兼容多元负荷及风光资源特征量(风速和辐射照度)的预测. 本文提出了一种新综合预测模型 AMIRA-LSTM 模型, 融合了两种模型各自的优势; 并用算例验证模型在不同负荷类型、不同的训练集下的负荷预测以及风光资源数据预测上的准确性和兼容性.

## 1 ARIMA-LSTM 预测模型

ARIMA 模型全称为移动差分自回归移动平均模型 (Autoregressive Integrated Moving Average Model, ARIMA), 是用于预测平稳时间序列的最受欢迎的线性回归模型之一<sup>[16]</sup>, 且有预测所需数据量较小的特点. LSTM 网络全称为长短期记忆网络 (Long-Short Term Memory, LSTM), 是拥有强大处理非线性数据的模型<sup>[17]</sup>, 它成功的解决了原始循环神经网络梯度消失的问题, 能够很好地处理时间序列数据<sup>[18]</sup>. 受到这两种模型自身特点的启发, 提出了 ARIMA-LSTM 综合预测模型.

### 1.1 ARIMA 预测模型<sup>[16]</sup>

ARIMA 模型表示为 ARIMA( $p, d, q$ ), 其中参数  $p, d$  和  $q$  表示预测模型的结构, 该模型可拆分为自回归 AR( $p$ ), 移动平均值 MA( $q$ ) 和差分度  $d$ .

AR(AutoRegressive, 自回归模型)模型确定当前时间序列观测值, 是先前时间序列观测值加上一些噪声项的线性组合. 参数  $p$  为自回归模型的阶数.

MA(Moving Average, 移动平均值)模型中,

当前时间序列值是过去误差的函数。移动平均预测模型使用预测误差的误差值来改进当前的预测，参数  $q$  为移动平均的阶数。

$I$  代表差分操作，它主要是对等周期间隔的数据进行线性求减，从而使数据变得平稳，ARIMA 一般进行一次差分即可稳定，因此  $d$  一般取值为 0、1、2。

ARIMA( $p, d, q$ )的数学公式可以描述如下。

$$\begin{aligned} x_i = & \alpha_0 + \alpha_1 x_{i-1} + \alpha_2 x_{i-2} + \dots + \alpha_p x_{i-p} + \\ & \varepsilon_0 + \beta_1 \varepsilon_{i-1} + \beta_2 \varepsilon_{i-2} + \dots + \beta_q \varepsilon_{i-q} \end{aligned} \quad (1)$$

式中： $\alpha_p, \beta_q$  为时间序列的自相关系数。

模型的建立过程：构建 ARIMA 模型的一般过程涉及三个迭代步骤。

第一步为模型识别和选择模型类型。为了判断最佳拟合模型，固定时间序列必不可少，在该序列中，基本统计属性（例如均值，方差，协方差或自相关）随时间是恒定的。为了构建平稳时间序列，使用了适当的微分度( $d$ )。然后，检查自相关函数(ACF)和部分自相关函数(PACF)以选择模型类型；

第二步为参数估计。选择  $q$  和  $p$  的阶数，在 ARIMA 模型中，许多学者已经基于 Akaike 信息标准(AIC)、最小描述长度(MDL)、贝叶斯信息标准(BIC)或模糊系统等开发了许多方法<sup>[19]</sup>。在本文的研究中使用 AIC 指标来估计参数；

最后一步为对残值( $\varepsilon_t$ )分析的诊断检查。通过一些诊断统计数据和残差图检查偏差，包括残差白噪声检验，及判断  $E(\varepsilon_t)$  是否为零，为零则代表模型通过检验，不同时刻的变量之间不相关，反正则相反，需要修正模型。

## 1.2 LSTM 预测模型<sup>[17]</sup>

LSTM 网络是递归神经网络(Recurrent Neural Network, RNN)的扩展。由于 LSTM 模型在处理大尺寸参数方面具有多功能性，并且在每一层中都使用了非线性激活函数，因此，LSTM 模型可以捕获数据中的非线性趋势并长时间记住以前的信息。LSTM 已成功应用于许多时间序列问题。LSTM 结构的优点是它包含三种类型的门，包括输入，忘记和输出。如图 1 所示，LSTM 解决了 RNN 消失的梯度问题，并允许长期存储信息。

LSTM 单元(图 1)的主要信息流可以用数学方式描述。符号  $+$  和  $\times$  表示模型中的加法和乘法，

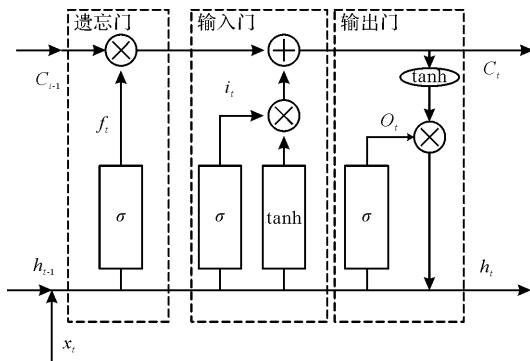


图 1 长短时记忆单元结构

Fig. 1 Structure of short - and long-term memory units

箭头表示信息的流向。存储器门的第一层确定将不必要的信息删除到单元状态，可以表示如下。

$$f_t = \sigma(W_f \times x_t + U_f \times h_{t-1} + b_f) \quad (2)$$

式中： $f_t$  表示在时间忘记门， $\sigma$  表示 sigmoid 函数， $W_f$  和  $U_f$  表示权重  $x_t$  表示输入值， $h_{t-1}$  表示在时间  $t-1$  的输出值，并且  $b_f$  表示偏差项。

第二个输入门根据当前输入向量决定应在单元状态下存储哪些信息。同时由 tanh 层生成新的状态值  $C_t$ 。具体表达式如下。

$$i_t = \sigma(W_i \times x_t + U_i \times h_{t-1} + b_i) \quad (3)$$

$$\bar{C}_t = \sigma(W_c \times x_t + U_c \times h_{t-1} + b_c) \quad (4)$$

式中： $i_t$  表示在时间  $t$  的输入阈值， $W_i, U_i, W_c$ ，和  $U_c$  是重量  $b_c$  和  $b_i$  是偏见。为了在时间  $t$  更新单元格的状态，表达式如下。

$$C_t = f_t \times C_{t-1} + i_t \times \bar{C}_t \quad (5)$$

第三个输出门作为输出信息生成，可以表示如下。

$$O_t = \sigma(W_o \times x_t + U_o \times h_{t-1} + b_o) \quad (6)$$

式中： $O_t$  表示在此时的输出值， $W_o$  和  $U_o$  是权重，并且  $b_o$  是偏差项。然后，该单元的输出值可以表示如下。

$$h_t = O_t \times \tanh(C_t) \quad (7)$$

式中：表示时间  $t$  单元的输出值， $\tanh$  表示激活函数，并且  $C_t$  表示在时间  $t$  的单元状态。数据通过三个门之后，将输出有效信息，并会忘记无效信息。

## 1.3 ARIMA-LSTM 预测模型

综合能源系统中的多元负荷数据及资源数据(风速和太阳日辐射量)为时间序列数据的形式，多元负荷数据均可假定由线性部分和非线性部分组成，ARIMA 方法可以成功地建模时间序列数据中的线性关系，而 LSTM 可以成功地建模非线性

分量。为了达到最佳的预测结果, 本文构建了混合模型, 如图 2 所示, 它们结合了 ARIMA 和 LSTM 方法的优势。即 ARIMA-LSTM 预测模型, 用公式可以表示为

$$L_{p,t} = L_{ap,t} + L_{lp,t} \quad (8)$$

式中:  $L_{p,t}$  为综合预测序列;  $L_{ap,t}$  为 ARIMA 模型预测序列;  $L_{lp,t}$  为 LSTM 模型预测序列。

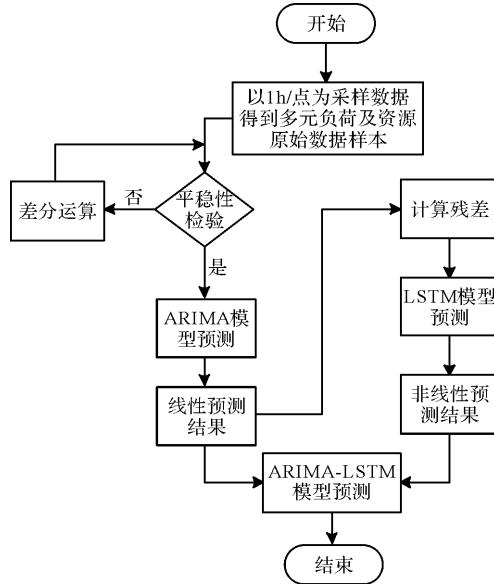


图 2 ARIMA-LSTM 模型预测步骤

Fig. 2 ARIMA-LSTM model prediction steps

基于图 2 中提出的方法的工作流程。

综合模型建模流程可以分为以下几个步骤:

(1) 通过数据采集等方法获取历史数据。

(2) 平稳性检验, 平稳的数据指其基本统计属性(例如均值, 方差, 协方差或自相关)随时间是恒定的。若数据不平稳, 则需要进行差分运算。差分运算是将非平稳的时间序列进行平稳化的运算方法。如果 1 阶差分不能使序列达到平稳的话, 本文还可以继续进行差分运算, 直到将序列转换为平稳序列为止。差分公式如下。

1 阶差分

$$\nabla X_t = X_t - X_{t-1} = (1-B)X_t \quad (9)$$

2 阶差分

$$\nabla^2 X_t = X_t - 2X_{t-1} + X_{t-2} = (1-B)^2 X_t \quad (10)$$

以此类推, 可  $d$  阶差分为

$$\nabla^d X_t = (1-B)^d X_t \quad (11)$$

式中:  $\nabla^d$  为  $d$  阶差分算子。

(3) 模型定阶:

通过差分运算得到了 ARIMA( $p, d, q$ ) 模型中的其中一个参数  $d$ , 接下来就要确定对参数  $p$  和

$q$  进行定阶, 这里用到的定阶方法就是 AIC 准则, 方法如下。

假设  $X_t$  为 ARMA( $p, q$ ) 模型, 其中未知参数的个数为  $p+q+1$  个, 其中包括自回归系数  $\varphi_1, \varphi_2, \dots, \varphi_p$ 、移动平均系数  $\theta_1, \theta_2, \dots, \theta_q$  和  $\sigma_e^2$ , 那么 ARMA( $p, q$ ) 的定阶准则为

选取适当的  $p$  和  $q$ , 使得 AIC 值达到最小, AIC 计算公式为<sup>[19]</sup>

$$AIC = n \ln \hat{\sigma}_e^2 + 2(p+q+1) \quad (12)$$

式中:  $n$  为样本容量,  $\hat{\sigma}_e^2$  与  $p, q$  有关。

若当  $p=p'$ ,  $q=q'$  时, 值最小, 则认为模型的阶数为  $p'$  和  $q'$ , 即为 ARMA( $p', q'$ ) 模型。

(4) ARIMA 模型的线性预测。应用 ARIMA 统计模型提取生产时间序列的线性部分  $L_{ap,t}$ , 并计算拟合误差, 这是下一步的输入项。设原始负荷数据集为  $H = [h_1, h_2, h_3, \dots, h_n]$ , 利用 ARIMA 模型得到  $H$  的历史数据拟合序列  $F$  和预测序列  $L_{ap,t}$ ,

$$F = [F_1, F_2, F_3, \dots, F_n]$$

$$L_{ap,t} = [L_{ap,1}, L_{ap,2}, L_{ap,3}, \dots, L_{ap,n}]$$

(5) 将拟合序列  $F$  与相应负荷实际序列  $H_f$  相比较, 得到拟合误差序列

$$\Delta F = [\Delta F_1, \Delta F_2, \Delta F_3, \dots, \Delta F_n]$$

(6) LSTM 建模的非线性预测。ARIMA 模型的残差是 LSTM 机器学习模型的输入。因此, 本文预测非线性数据计算公式为

$$L_{lp,t} = f(\Delta F_1, \Delta F_2, \Delta F_3, \dots, \Delta F_n) \quad (13)$$

式中:  $f(\cdot)$  为 LSTM 的非线性建模。

(7) 耦合和评估 ARIMA-LSTM 模型的最终结果。通过将 ARIMA 模型的预测结果与到 LSTM 网络的预测结果结合, 可以获得拟合得出时间序列的最终结果。随后进行预测评价。

#### 1.4 预测性能评价

为了评估不同实验场景下的预测性能, 选择科学的评估指标进行时间序列预测。作为评估指标常用的包括: 均方根误差(RMSE), 平均绝对误差(MAE), 平均绝对百分比误差(MAPE)和相似度(Sim), 这些指标用于评估不同模型在预测结果中的性能, 并且可以表示如下。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i(t) - y_i(t))^2} \quad (14)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i(t) - y_i(t)| \quad (15)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i(t) - y_i(t)}{x_i(t)} \right| \quad (16)$$

$$Sim(x, y) = \frac{1}{n} \sum_{i=1}^n \frac{1}{1 + \frac{|x_i(t) - y_i(t)|}{\max(x) - \min(x)}} \quad (17)$$

式中:  $x_i(t)$  表示多元负荷数据值;  $y_i(i)$  表示通过不同模型预测的产量值;  $n$  表示时间序列数。通常, RMSE, MAE 和 MAPE 的值越低, 预测任务的性能越好。此外, Sim 值在  $[0, 1]$  区间内, 较高的 Sim 值表示较好的拟合结果。

## 2 模型算例

### 2.1 案例概况及数据训练集的确定

本文使用某机场能源岛 2019 年全年 8 760 h 多元负荷数据以及资源数据集, 包括热、冷、电、气负荷、风速、辐射照度等, 如图 3、图 4 所示。

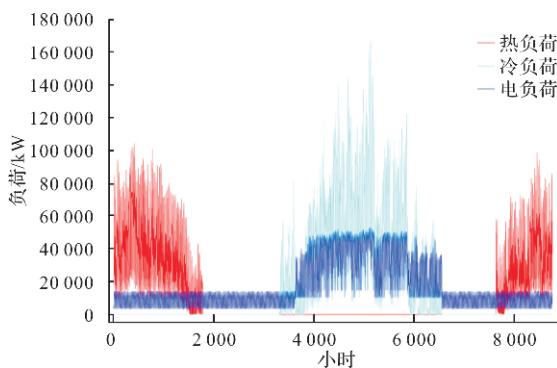


图 3 能源站负荷图

Fig. 3 Load diagram of energy station

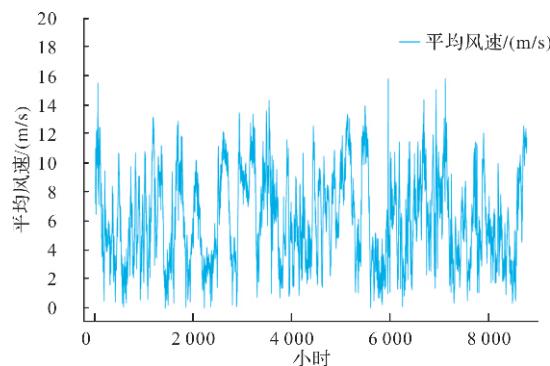


图 4 能源站风速数据图

Fig. 4 Wind speed data of energy station

其中, 1 月份数据作为样本数据, 样本数据共有 720 小时的数据, 用混合模型预测 2 月份负荷预测数据, 与对比数据对比验证模型可靠性。本文在 ARIMA 模型中以样本数据(1 月份数据)的前 50% 作为训练集, 后 50% 作为测试集以确定最近模型。在 LSTM 网络模型中, 以确定的 ARIMA 模型对样本数据的拟合产生的拟合误差(1 月份拟

合误差)的前 50% 作为训练集, 后 50% 作为测试集训练最佳模型。

### 2.2 预测过程

这里以热负荷预测为例, 余同。

(1) 平稳性检验, 检验数据平稳性。热、冷、电样本均值及方差随时间变化均近似趋近于某定值, 认为数据平稳, 可以建模。而风速数据不平稳, 作一阶差分后平稳;

(2) 模型定阶, 计算使用公式(12)计算最小 AIC 值, 为了节约计算时间, 使用编程计算方便节约时间, 本文使用 Python 编程计算。经计算, 当  $p=3$ ,  $d=0$ ,  $q=24$  时, AIC 值最小, 故时间序列模型确定为 ARIMA(3, 0, 24);

### (3) ARIMA 模型计算

用确定好的 ARIMA 模型直接预测能源岛 2 月份 1 日到 7 日的负荷数据, 得到能源岛 2 月份的线性预测负荷  $L_{ap,t}$ , 并与实际热负荷做对比, 如图 5 所示;

(4) 确定 ARIMA 模型后即可得到拟合误差序列, 以拟合误差序列的前 50% 作为训练集, 后 50% 作为测试集训练最佳 LSTM 模型。

在多次试验中, 训练 LSTM 神经网络时, 本文设置的初始学习率为 0.005 并且训练 125 次后学习率下降, 衰落因子为 0.2 时, 网格效果最好。图 6 显示了 LSTM 网络的训练过程。可以看出, 在最后一次迭代完成后, RSME 和 Loss 基本不再变动并且与 0 非常接近, 认为模型已经训练完成。其中, 不同的数据集要设置不同的学习率。

用训练好的模型预测 2 月份负荷, 得到 2 月份的非线性预测负荷  $L_{lp,t}$ 。

(5) 用公式(8)得到 ARIMA-LSTM 模型综合预测序列  $L_{p,t}$ , 至此, 热负荷综合预测完成。用同样的方法得到电负荷、风速预测序列(冷负荷为零)。

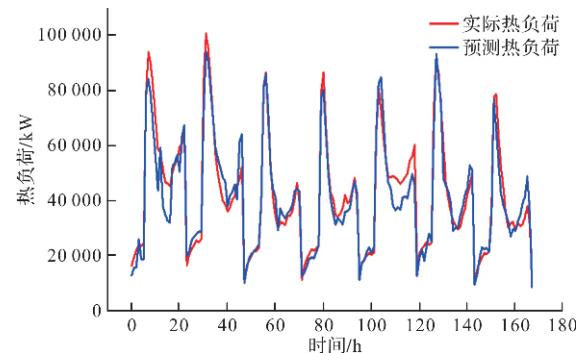


图 5 ARIMA 模型预测热负荷与实际热负荷对比

Fig. 5 Comparison of predicted heat load and actual heat load by ARIMA model

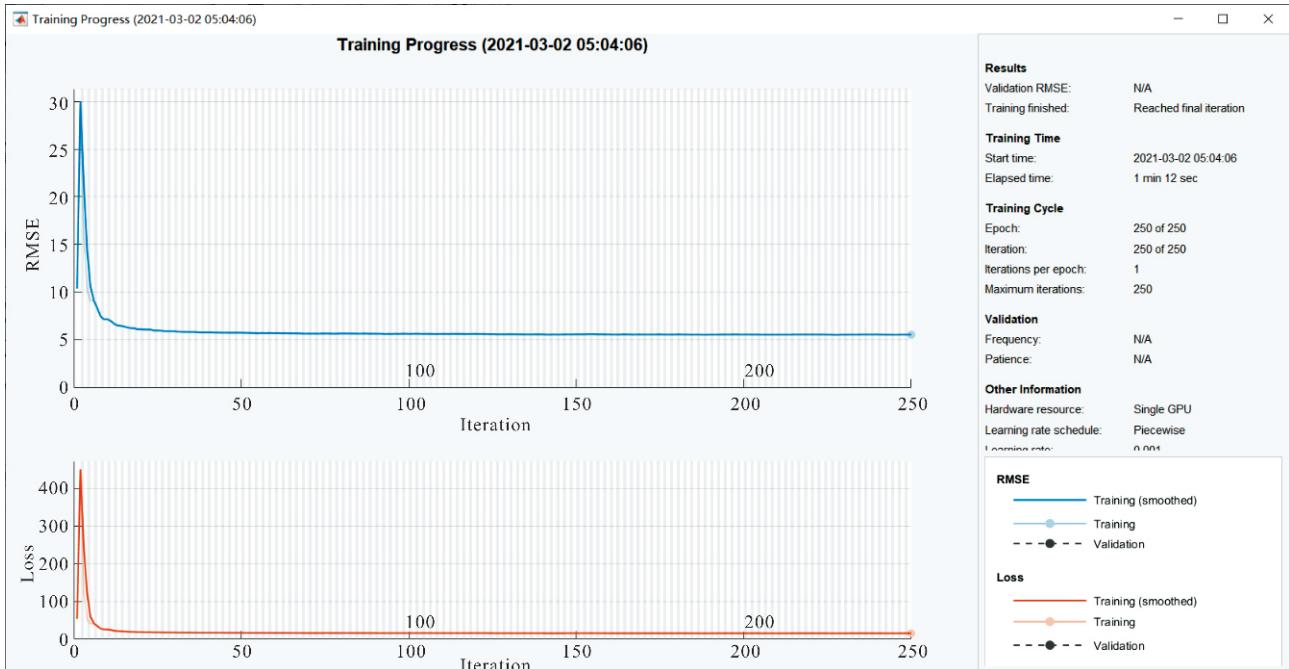


图 6 LSTM 训练过程

Fig. 6 LSTM training process

### 2.3 预测结果分析

将模型综合预测结果与对比数据进行对比, 如图 7 所示, 其中, 热负荷、电负荷和风速数据均为 2 月 1 日到 7 日的逐小时数据。

为比较不同模型的预测效果, 本文采用 ARI-

MA 模型、LSTM 模型、Elman 模型<sup>[9]</sup>与 ARIMA-LSTM 组合模型, 分别对该能源岛 2 月 1 日至 7 日为期一周的热电负荷及风速进行逐时预测, 并计算日相对平均误差 MAPE。各模型的预测结果误差曲线如图 8 所示。

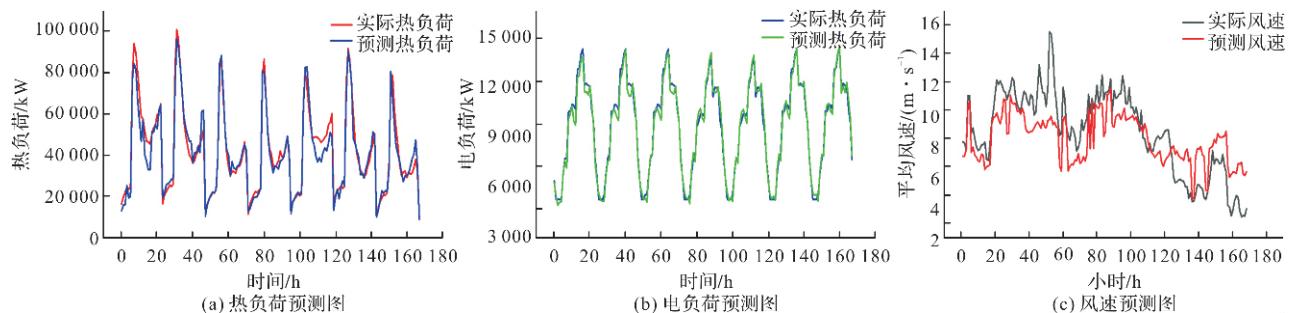


图 7 综合预测结果与实际对比

Fig. 7 Comparison between comprehensive prediction

results and actual results

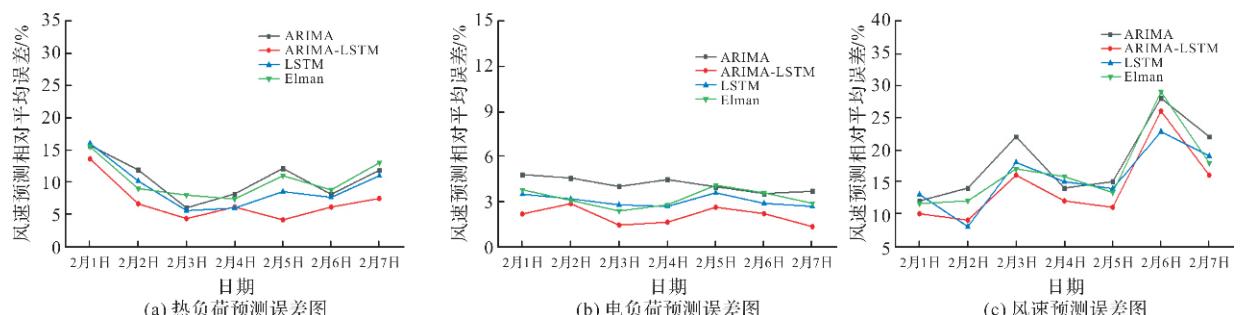


图 8 预测误差对比图

Fig. 8 Comparison chart of prediction error

由图 8 可知, 电负荷的预测效果相对较为理想, 热负荷和风速由于其本身的特点误差相对更大, 但基本控制在一定范围内。同时, 相对于其他模型, 本文的混合模型在大多数情况下相对平均误差 MAPE 更小, 预测效果最理想, 而 ARIMA 模型的预测效果在这几种方法中效果最不理想。组合模型相比于其他三种模型在负荷预测方面表现得更出色。

为了比较训练集对预测结果的影响, 以一种负荷为例, 测试了训练集为一周、一月、一年所得预测结果的误差, 如下表所示。

表 1 不同模型在不同训练集长度下对应的热负荷预测误差

Tab. 1 Thermal load prediction errors corresponding to different models under different training set lengths

模型	训练集 长度/h	计算所用 时长/min	相对平均误差 百分数/%
AMIRA	168	1	15.8
AMIRA	720	3	16.7
AMIRA	8760	10	15.6
LSTM	168	5	19.3
LSTM	720	16	16.2
LSTM	8760	110	14.3
组合模型	168	6	17.6
组合模型	720	18	15.8
组合模型	8760	121	14.3

根据表 1 分析可知, LSTM 模型作为当下比较流行的模型<sup>[17]</sup>, 其预测精度高、仅需历史数据即可进行预测的特点受到极大的关注。而本文建立的 ARIMA-LSTM 组合模型, 不仅有相比 LSTM 模型更好地预测精度, 同时保证了运算时长相差不大; 而且该模型在训练集更少时将更可靠。

### 3 结语

本文基于 ARIMA 以及 LSTM 网络构建了用于综合能源系统多元负荷预测及风光资源数据预测的 ARIMA-LSTM 混合模型, 介绍了模型的建模过程以及运算流程。

该模型结合了线性预测和非线性预测, 能更充分的提取历史数据的规律, 能有效的减少预测误差, 削减风光等设备由于出力不确定性造成的负面影响。

该模型在训练集较少时预测表现更加可靠, 同时计算时间能控制在合理的范围内, 对综合能源系统在运行初期的调控计算分析有更好的适用性。

### 参考文献 References

- [1] 刘超. 考虑混合储能的综合能源系统调度方法研究 [D]. 哈尔滨: 哈尔滨工业大学, 2020.  
LIU Chao. Research on scheduling method of integrated energy system considering hybrid energy storage [D]. Harbin: Harbin Institute of Technology, 2020.
- [2] 王奖, 邓丰强, 张勇军, 等. 园区能源互联网的规划与运行研究综述[J]. 电力自动化设备, 2021, 41(2): 24-32, 55.  
WANG Jian, DENG Fengqiang, ZHANG Yongjun, et al. Review on the planning and operation of energy Internet in park[J]. Electric Power Automation Equipment, 2021, 41(2): 24-32, 55.
- [3] 余晓丹, 徐宪东, 陈硕翼, 等. 综合能源系统与能源互联网简述[J]. 电工技术学报, 2016, 31(1): 1-13.  
YU Xiaodan, XU Xiandong, CHEN Shuoyi, et al. Integrated energy system and energy Internet brief[J]. Transactions of China Electrotechnical Society, 2016, 31(1): 1-13.
- [4] 付学谦, 孙宏斌, 郭庆来, 等. 能源互联网供能质量综合评估[J]. 电力自动化设备, 2016, 36(10): 1-7.  
FU Xueqian, SUN Hongbin, GUO Qinglai, et al. Comprehensive evaluation of energy Internet energy supply quality[J]. Electric Power Automation Equipment, 2016, 36(10): 1-7.
- [5] 贾云辉, 张峰. 考虑分布式风电接入下的区域综合能源系统多元储能双层优化配置研究[J]. 可再生能源, 2019, 37(10): 1524-1532.  
JIA Yunhui, ZHANG Feng. Optimal allocation of multi-layer energy storage in regional integrated energy system considering distributed wind power access[J]. Renewable Energy, 2019, 37(10): 1524-1532.
- [6] 熊焰, 吴杰康, 王强, 等. 风光气储互补发电的冷热电联供优化协调模型及求解方法. 中国电机工程学报[J], 2015, 35: 3616-3625.  
XIONG Yan, WU Jiekang, WANG Qiang, et al. Optimal coordination model and solution method of combined cooling, heating and power generation for wind-wind gas storage complementary power generation. Proceedings of the CSEE, 2015, 35: 3616-3625.
- [7] SADAEI Hossein Javedani, GUIMARAES Frederico Gadelha. Short-term load forecasting method based on fuzzy time series, seasonality and long memory process [J]. International journal of approximate reasoning, 2017, 83(1): 196-217.
- [8] 陈淑绵. 1997-2010 年我国能源生产的预测[J]. 统计与预测, 1998(2): 40-41, 15.  
CHEN Shumian. The forecast of energy production in

- China from 1997 to 2010 [J]. Statistics and Forecast, 1998(2):40-41,15.
- [9] 王琦, 杨超杰, 李丽锋. 改进 Elman 神经网络在短期热负荷预测中的应用 [J]. 工业仪表与自动化装置, 2020(1): 50-53.  
WANG Qi, YANG Chaojie, LI Lifeng. Application of Improved Elman Neural Network in Short-term Thermal Load Prediction [J]. Industrial Instrumentation & Automation, 2020(1): 50-53.
- [10] 卢建昌, 王柳. 基于时序分析的神经网络短期负荷预测模型研究 [J]. 中国电力, 2005, 38(7): 11-14.  
LU Jianchang, WANG Liu. Research on short-term load forecasting model of neural network based on time series analysis [J]. China Electric Power, 2005, 38(7): 11-14.
- [11] 姜勇. 电力系统短期负荷预测的模糊神经网络方法 [J]. 继电器, 2002, 30(7): 11-13.  
JIANG Yong. Fuzzy Neural Network Method for Short-term Load Prediction of Power System [J]. Relay, 2002, 30(7): 11-13.
- [12] 李广, 邹德忠, 谈顺涛. 基于混沌神经网络理论的小电网短期电力负荷预测 [J]. 电力自动化设备, 2006, 26(2): 50-52.  
LI Guang, ZOU Dezhong, TAN Shuntao. Short-term Power Load Prediction of Small Power Grid Based on Chaotic Neural Network Theory [J]. Electric Power Automation Equipment, 2006, 26(2): 50-52.
- [13] 梁海峰, 涂光瑜, 唐红卫. 遗传神经网络在电力系统短期负荷预测中的应用 [J]. 电网技术, 2001, 25(1): 49-53.  
LIANG Haifeng, TU Guangyu, TANG Hongwei. Application of Genetic Neural Network in Short-term Load Prediction of Power System [J]. Power Network Technology, 2001, 25(1): 49-53.
- [14] 杨熊, 于军琪, 郭晨露, 等. 基于改进 PSO-BP 神经网络的冰蓄冷空调冷负荷动态预测模型 [J]. 土木与环境工程学报, 2019, 41(1): 168-174.  
YANG Xiong, YU Junqi, GUO Chenlu, et al. Dynamic prediction model of cold load for ice storage air conditioning based on improved PSO-BP neural network [J]. Chinese Journal of Civil and Environmental Engineering, 2019, 41(1): 168-174.
- [15] 王茜, 于军琪. 基于相似日 LM 神经网络的高校图书馆能耗预测 [J]. 西安建筑科技大学学报(自然科学版), 2022, 54(3): 459-465.  
WANG Qian, YU Junqi. Energy consumption prediction model of a university library based on Similar day selection and Levenberg-marquardt neural network [J]. J. of Xi'an Univ. of Arch. & Tech. (Natural Science Edition), 2022, 54(3): 459-465.
- [16] 卫小英, 霍丽骊. 博克思-詹金斯预测方法简介 [J]. 预测, 1984(S1): 35-39.  
WEI Xiaoying, HUO Lili. Box-jenkins forecasting method introduction [J]. Forecasting, 1984 (S1): 35-39.
- [17] 王鑫, 吴际, 刘超, 等. 基于 LSTM 循环神经网络的故障时间序列预测 [J]. 北京航空航天大学学报, 2018, 44(4): 772-784.  
WANG Xin, WU Ji, LIU Chao, et al. Fault time series prediction based on LSTM cyclic neural network [J]. Journal of Beijing University of Aeronautics and Astronautics, 2018, 44(4): 772-784.
- [18] MUZAFFAR S, AFSHARI A. Short-term load forecasts using LSTM networks [J]. Energy Procedia, 2019, 158: 2922-2927.
- [19] FAN Dongyan, SUN Hai, YAO Jun, et al. Well production forecasting based on ARIMA-LSTM model considering manual operations [J]. Energy, 2021, 220: 119708.

(编辑 桂智刚)