

doi: 10.11835/j.issn.1000-582X.2022.252

# 面向功能分区的大型商场建筑冷负荷预测方法

赵安军<sup>1a</sup>, 杨航杰<sup>1b</sup>, 荆 竞<sup>2</sup>, 张萌芝<sup>1b</sup>, 焦 阳<sup>1a</sup>

(1. 西安建筑科技大学 a. 建筑设备与工程学院; b. 信息与控制工程学院, 西安 710055;

2. 中国建筑西北设计研究院有限公司, 西安 710018)

**摘要:**针对大型商场面向建筑整体冷负荷预测不能为商场各区域按需供冷提供合理控制策略的问题,通过研究商场不同区域冷负荷特点,采用灰色关联度分析法筛选影响商场不同区域冷负荷的关键影响因素,针对实际情况中各输入特征对冷负荷影响程度的不稳定性,提出了基于双重注意力机制和 LSTM 的短期分区冷负荷预测模型。LSTM 网络充分考虑空调冷负荷与相关特征变量之间的非线性关系,特征注意力自主分析历史信息 and 输入变量之间的关系,提取重要特征,时序注意力选取 LSTM 网络关键时刻的历史信息,提升较长时间段预测效果的稳定性。以西安某大型商场建筑的冷负荷数据集为实验数据,实验结果表明所提模型相比于 LSTM 模型、CNN-LSTM 模型和 Attention-LSTM 模型,误差指标 MAPE 和 RMSE 均有显著降低, $R^2$ 明显增加且稳定 0.99 以上,具有较好的泛化能力和较强的稳定性。

**关键词:**功能分区;灰色关联度;冷负荷预测;注意力机制;长短记忆神经网络

中图分类号:TP391.9

文献标志码:A

文章编号:1000-582X(2023)06-061-15

## A cold load prediction method of shopping malls oriented to functional zoning

ZHAO Anjun<sup>1a</sup>, YANG Hangjie<sup>1b</sup>, JING Jing<sup>2</sup>, ZHANG Mengzhi<sup>1b</sup>, JIAO Yang<sup>1a</sup>

(1a. School of Building Services Science and Engineering; 1b. School of Information and Control

Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, P. R. China;

2. China Northwest Architecture Design and Research Institute, Xi'an 710018, P. R. China)

**Abstract:** Current cooling load prediction method of overall buildings for large-scale shopping malls cannot provide a reasonable control strategy for demands of various areas of the shopping mall. By studying the characteristics of cooling load in different areas of shopping malls, the key influencing factors of cooling load in different areas of shopping malls were screened by using grey relational degree analysis method. To solve the instability of the influence degree of each input variable on cooling load in actual situation, a short-term zoned cooling load prediction model based on double attention mechanism and LSTM was proposed. LSTM network fully considers the nonlinear relationship between air-conditioning cooling load and related characteristic variables. Feature attention analyzes the relationship between historical information and input variables

收稿日期:2021-10-30 网络出版日期:2022-03-08

基金项目:国家重点研发计划资助项目(2017YFC0704100)。

Supported by National Key Research and Development Program(2017YFC0704100).

作者简介:赵安军(1975—),男,西安建筑科技大学副教授,硕士生导师,主要研究方向为建筑物联网、建筑节能与能效分析、建筑设备控制与优化。

通信作者:荆竞(1982—),男,高级工程师,(E-mail)xby5s@163.com。

autonomously to extract important features. Sequential attention selects historical information at critical moments of LSTM network to improve the stability of long-term prediction effects. The experimental results show that compared with LSTM model, CNN-LSTM model and attention-LSTM model, the error indexes MAPE and RMSE of the proposed model decrease significantly, and its  $R^2$  increases significantly and remains stable above 0.99, indicating good generalization ability and strong stability.

**Keywords:** functional partition; grey relational degree; cooling load prediction; attention mechanism; long short term memory neural network (LSTM)

随着中国社会经济的快速发展, 能源和环境问题日益突出, 目前建筑运行能耗约占全社会总能耗的30%, 单位建筑能耗面积是发达国家的2~3倍, 已经成为限制中国可持续发展的主要问题<sup>[1]</sup>。大型商场因其人流量大, 舒适性要求高, 空调系统运行时间长等特点, 其空调系统单位建筑面积能耗为城镇建筑的5倍<sup>[2]</sup>。现阶段大型商场建筑冷负荷预测通常是面向建筑整体<sup>[3]</sup>, 这种整体性冷负荷预测往往忽略了实际冷负荷需求在空间上的不确定性和不均匀性, 造成了输送过程中能源的浪费。因此, 面向区域的冷负荷预测是实现大型商场空调系统优化运行, 按需分配的必要手段。

从预测原理上, 冷负荷预测方法主要分为基于物理模型的方法和基于数据驱动的方法<sup>[4]</sup>。基于物理模型的方法依赖于物理原理和建筑及其系统的详细信息来表征建筑热行为<sup>[1]</sup>。如 Campana 等<sup>[5]</sup>利用 BESTEST 软件针对巴西商业建筑研究了一种简化负荷模拟的过程, 研究中评估了4座建筑, 得出的结论是, 4座建筑的结果存在显著差异, 简化方法不能充分表明建筑的负荷性能。Abasnezhad 等<sup>[6]</sup>为了确定负荷计算的最佳设计, 考虑了10个不同设计精度的模型, 使用 Energy Plus 软件对建筑进行了分析, 得出模型高度依赖于建筑围护结构和热工设计相关参数的识别。虽然基于物理模型的方法可以捕捉实际建筑对各种影响因素的热响应, 但是需要大量建筑本体及相关设备详细信息, 如果不满足物理原理的假设, 模型性能将会出现严重偏差。

数据驱动法主要依靠建筑运行数据来发现建筑冷负荷与相关变量(如室外温度、相对湿度、室内占用率等)之间的关系<sup>[1]</sup>。Zhou 等<sup>[7]</sup>根据商场空调冷负荷混沌和非线性的特点, 基于机器学习的混沌支持向量回归、小波支持向量机回归、支持向量回归和BP神经网络4种预测算法, 以历史时间的冷负荷作为输入, 预测下一时刻的负荷。Fan 等<sup>[8]</sup>通过蒙特卡洛模拟和随机处理对输入变量进行离线校准, 优化模型结构来提高预测输出精度, 以精准的冷负荷预测提升 HVAC 系统的节能潜力。Fan 等<sup>[9]</sup>通过对变量进行敏感性分析, 将温度、湿度、太阳辐射、人员密度和照明密度作为主导变量, 利用多元非线性回归(MNR)模型来准确预测短期冷负荷, 预测结果为实际系统中冷水机组提供一种简单的控制策略。杨雄等<sup>[10]</sup>提出了一种改进的 PSO-BP 神经网络算法, 采用灰色关联度分析, 确定  $T-1$  时刻的温度、 $T$  时刻的温度、 $T-1$  时刻的太阳辐射、 $T$  时刻的太阳辐射、 $T$  时刻的室外温度和  $T-1$  时刻的冷负荷为影响冷负荷的关键因素, 并以此作为预测模型的输入变量预测商场  $T$  时刻的冷负荷。周璇等<sup>[11]</sup>提出基于多元非线性回归的空调冷负荷预测, 采用实际用能系数描述不用时刻商场空调的负荷特性, 建立空调负荷预测模型。邵必林等<sup>[12]</sup>提出了注意力机制的 LSTM 网络模型, 在 LSTM 模型的基础上加入 Attention 机制, 突出关键时间节点包含的建筑能耗特征对预测结果的影响。这些预测的研究是针对商场建筑整体层面, 但是忽视了实际商场中不同区域不同时间段的冷负荷的变化规律, 存在一定的片面性, 导致不能满足实际工程输配系统的优化研究。

为了实现商场空调输配系统的节能潜力, 准确控制冷负荷按需分配至商场各个区域。通过从建筑空间结构、业态分布和人员等因素分析商场的特点, 提出面向功能分区的冷负荷预测方法, 分区冷负荷预测的目的在于使空调系统能有效地跟踪负荷变化, 改善室内热环境和降低空调能耗。相较于以往的研究, 有着如下的贡献:

1) 针对商场各区域在不同时间段冷负荷非均匀分布问题, 提出商场功能分区理念, 根据商场业态功能特点和空间分布情况, 将商场划分为不同供冷区域, 分析不同供冷分区冷负荷变化的特点, 基于灰色关

联度筛选不同分区空调冷负荷关键影响因素。

2) 针对于商场冷负荷受多因素影响与时序变化的特点。在 Attention-LSTM 网络的基础上引入特征注意力机制, 利用特征变量的关联性自主增强实际运行中各输入特征与冷负荷的关联关系, 同时结合 Attention-LSTM 网络可以分析关键历史时刻对待预测时刻负荷的重要程度, 优化模型的输出, 提高模型准确性。

## 1 商场建筑分区冷负荷特性

通过调研结果发现, 各商场既有各自的特点又有一定的共性。以西安某大型商场为研究对象, 该建筑物高 20.3 m, 地下 2 层, 地上 4 层, 总建筑面积 12.5 万  $\text{m}^2$ , 商业面积 10 万  $\text{m}^2$ , 建筑空调面积 9.38 万  $\text{m}^2$ 。

### 1.1 功能分区及冷负荷特性

商场内部空间结构以及功能分区的复杂性, 导致商场建筑室内环境状况复杂。通过对该商场空间布局、业态分布和室内环境等因素进行调研, 结合各区域人员密度变化规律, 将该商场划分为 5 类功能区: 地下超市区、珠宝区、服装区、餐饮区和娱乐区。各功能区照明密度及设备功率密度, 如表 1 所示。

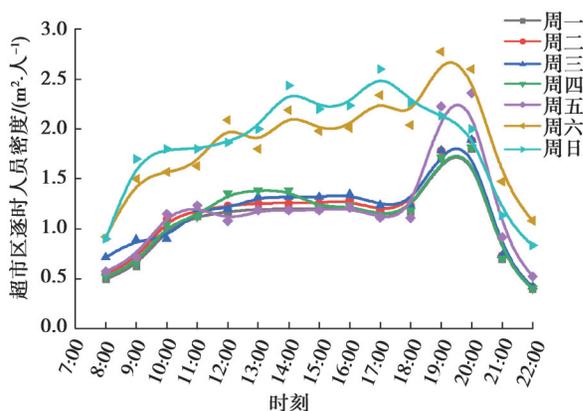
表 1 各功能区照明密度及设备功率密度

Table 1 Lighting density and equipment power density of each functional area

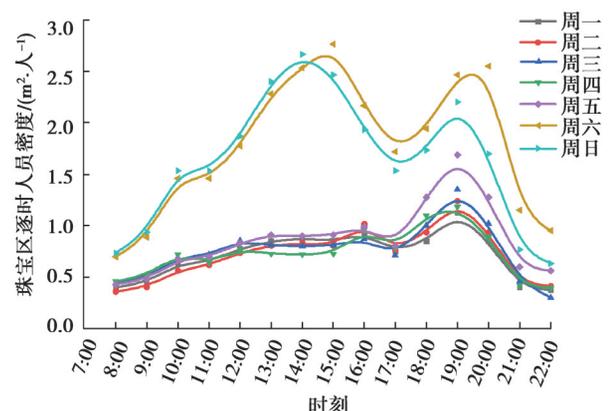
| 功能区 | 照明功率密度/( $\text{W}\cdot\text{m}^{-2}$ ) | 设备功率密度/( $\text{W}\cdot\text{m}^{-2}$ ) |
|-----|---|---|
| 超市区 | 50                                      | 25                                      |
| 珠宝区 | 40                                      | 10                                      |
| 服装区 | 40                                      | 10                                      |
| 餐饮区 | 30                                      | 20                                      |
| 娱乐区 | 25                                      | 30                                      |

由于人员的活动不确定性, 人员统计不针对某个时刻, 而是统计某一段时间该区域平均滞留人员的数量, 所以在统计过程中, 9:00—10:00 时间段的平均人员数量作为 9:00 时刻的人员数量。通过多元线性回归进行拟合, 获取不同区域逐时在室人员密度, 各区域人员密度变化规律, 如图 1 所示。各区域周一到周四人员密度较为一致, 周五晚上有较大起伏, 而周六周日则出现明显上升趋势; 不同区域的人员密度变化随时间变化有所差异, 这与人员生活作息规律密切相关。

各功能分区逐时冷负荷变化规律各具特点。根据调查发现, 一周之中工作日冷负荷变化具有相似性, 和周六周日相比具有差异性。该商场某一工作日和某一周日各功能分区的冷负荷变化, 如图 2 所示。



(a) 超市区



(b) 珠宝区

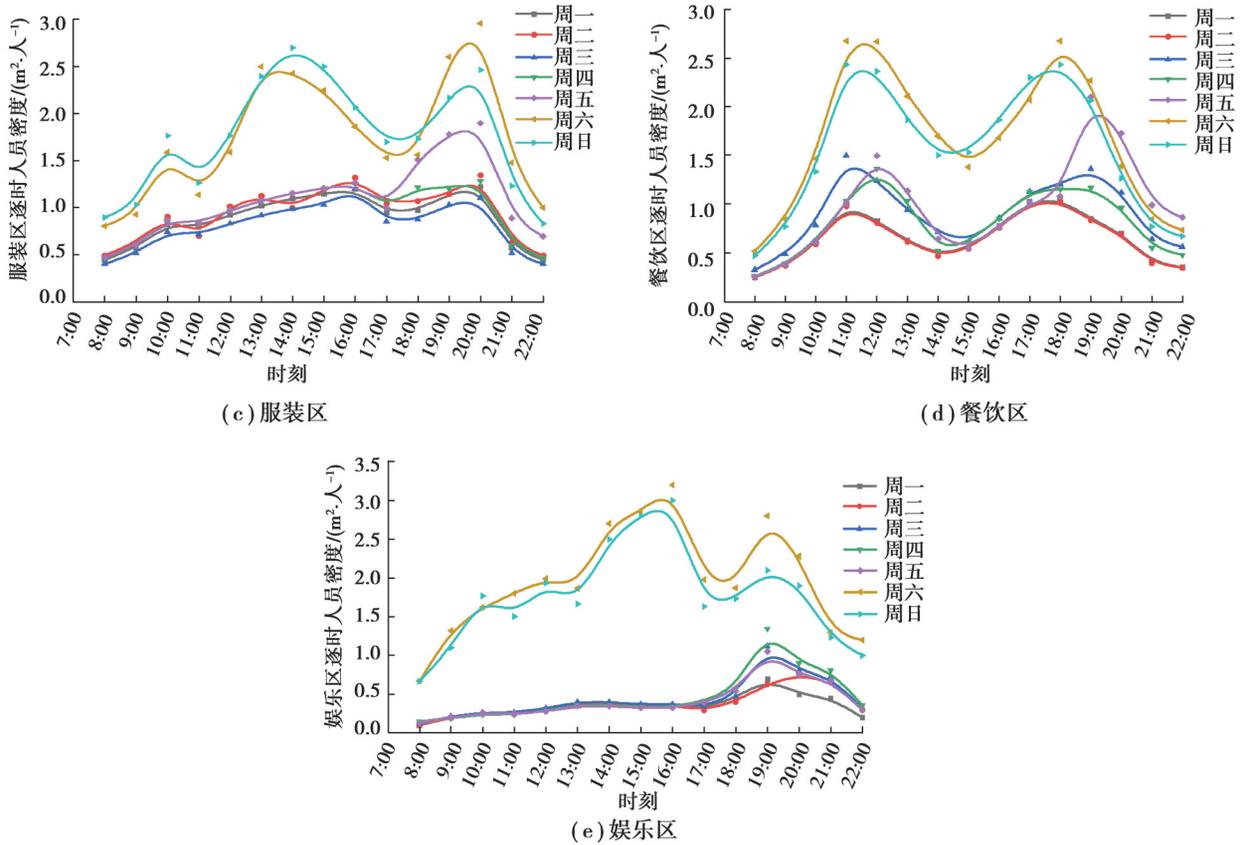


图1 各功能分区人员密度变化

Fig. 1 Personnel density changes in each functional zone

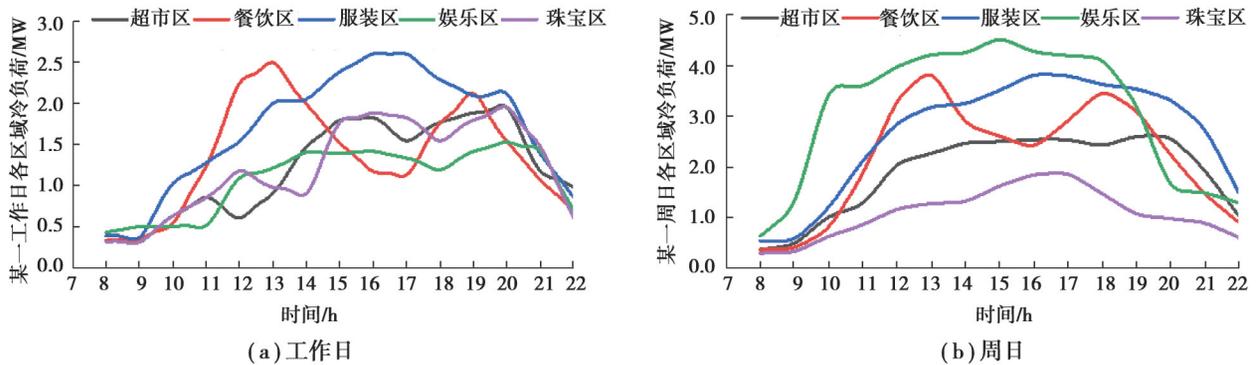


图2 工作日和周末各功能分区冷负荷变化

Fig. 2 Changes in cooling load of each functional zone on weekdays and weekends

由图2冷负荷变化可知，各功能区冷负荷在不同时间段需求差异性较大。餐饮区冷负荷时段性明显且波动较大，上午冷负荷较小，就餐期间冷负荷明显增大，总体负荷变化呈现双峰形。冷负荷峰值出现在在12:00左右和19:00左右；娱乐区工作日和周末冷负荷需求相差数倍之多，工作日和周末冷负荷峰值需求的时段并不相同，工作日冷负荷峰值出现在18:00—20:00之间，周末冷负荷峰值出现在16:00左右，相比于工作日，周末冷负荷波动性更大；珠宝区和服装区冷负荷变化规律与餐饮区存在一定互补现象，冷负荷峰值均出现在下午16:00—18:00时段。超市区工作日冷负荷波动较大，冷负荷峰值出现在晚上20:00左右，周末冷负荷变化较为平稳，冷负荷峰值出现在下午16:00左右。

## 1.2 面向功能分区冷负荷影响因素分析

大型商场冷负荷主要由围护结构负荷、人员负荷、照明负荷、新风负荷和电器设备负荷等构成<sup>[13]</sup>。

该商场超市位于地下一层,围护结构形成冷负荷可以忽略不计,相比于地上空间,该区域面临无天然采光或天然光不足,需要大量照明设备保证亮度,因此超市区照明功率密度最高,同时为了保证地下空气质量需要除去过量的湿气;珠宝区和服装区内扰较为相近,电器设备功率密度较低,为了显示商品的特性与美观,增加局部照明导致照明功率密度偏高;餐饮区照明功率密度偏低,电器设备功率密度较高但使用有明显的时段性;娱乐区位于建筑顶层,照明功率密度最低同时该区域具有大量且保持常开状态的电器设备,因此电器设备功率最高。由于空间位置的原因,服装区、餐饮区和娱乐区通过围护结构与室外温度和太阳辐射直接发生传热,受外界气象参数影响较大。

空调冷负荷与多变量因素之间存在非线性关系,灰色关联度分析法(grey relation analysis, GRA)是一种多因素统计分析方法,用来描述输入因素对输出结果影响的强弱、大小和次序<sup>[14]</sup>。GRA法根据关联度大小判断各功能分区空调冷负荷与多变量因素相关性强弱。

采用灰色关联度分析,需要计算输入变量与输出结果间灰色关联度,具体步骤如下。

Step 1: 确定参考序列和比较序列。

空调冷负荷( $Y_c$ )为参考序列,干球温度( $X_t$ )、相对湿度( $X_h$ )、太阳辐射量( $X_r$ )、风速( $X_w$ )、人员密度( $X_p$ )、照明功率密度( $X_l$ )、电器功率密度( $X_e$ )设为比较序列。设置参考数列 $Y_c$ ,参考数列为 $Y_c = \{Y_c(1), Y_c(2), \dots, Y_c(n)\}$ ,比较数列为 $X_i = \{X_i(1), X_i(2), X_i(3), \dots, X_i(n)\}$ ,其中 $X_i$ 为比较序列 $X_t, X_h, X_r, X_p, X_l, X_e, X_w$ 。

Step 2: 求参考数列与比较数列的灰色关联度系数 $\xi_i(k)$ ,如式(1)所示。

$$\xi_i = \frac{\min_i \min_k |y(k) - x_i(k)| + \rho \min_i \min_k |y(k) - x_i(k)|}{|y(k) - x_i(k)| + \rho \min_i \min_k |y(k) - x_i(k)|}, \quad (1)$$

式中: $y(k)$ 为归一化负荷序列; $x_i(k)$ 为归一化的影响因素序列;分辨系数 $\rho = 0.5$ 。

Step 3: 求灰色关联度 $r_i$ ,如式(2)所示。

$$r_i = \frac{1}{n} \sum_{k=1}^n \xi_i(k). \quad (2)$$

各功能区空调冷负荷动态预测模型中不同输入变量与空调冷负荷灰色关联度,见表2。

表2 各功能区影响变量与当前时刻冷负荷灰色关联度

Table 2 Grey correlation degree between influencing variables of each functional area and cooling load at the current moment

| 变量       | 灰色关联度 |       |       |       |       |
|----------|-------|-------|-------|-------|-------|
|          | 超市区   | 珠宝区   | 服装区   | 餐饮区   | 娱乐区   |
| 干球温度     | 0.260 | 0.304 | 0.735 | 0.767 | 0.746 |
| 相对湿度     | 0.741 | 0.539 | 0.538 | 0.532 | 0.514 |
| 太阳辐射     | 0.146 | 0.085 | 0.602 | 0.602 | 0.735 |
| 风速       | 0.032 | 0.063 | 0.072 | 0.079 | 0.075 |
| 人员密度     | 0.834 | 0.859 | 0.833 | 0.822 | 0.855 |
| 照明功率密度   | 0.856 | 0.891 | 0.835 | 0.761 | 0.735 |
| 电器功率密度   | 0.855 | 0.356 | 0.337 | 0.872 | 0.921 |
| T-1时刻冷负荷 | 0.875 | 0.886 | 0.827 | 0.864 | 0.816 |
| T-2时刻冷负荷 | 0.443 | 0.472 | 0.523 | 0.472 | 0.384 |

由上述分析可知,各功能分区空调冷负荷与风速关联度极小,这是由于大型商场建筑采用封闭式的外围护结构,没有与外界形成自然通风,空调冷负荷受风速影响较小。照明和电器功率较大的区域,散热量较大,直接影响冷负荷的变化,因此与空调冷负荷的关联性较大。各功能分区由于空间布局和使用功能的差异性,不同功能区空调冷负荷的影响因素有较大的差异性。通过表2灰色关联度的定量分析,确定各功能区的的关键变量因素为表3所示。 $T-2$ 时刻冷负荷相比于 $T-1$ 时刻的冷负荷关联度较低,为了降低历史冷负荷对于当前时刻冷负荷预测的耦合作用,仅将各功能区的的关键影响因素与 $T-1$ 时刻的区域历史冷负荷数据共同构成预测模型的输入数据集。

表3 各功能区关键影响变量

Table 3 Key influence variables of each functional area

| 功能区 | 关键影响因素                            |
|-----|-----------------------------------|
| 超市区 | 相对湿度;人员密度;照明功率密度;电器功率密度           |
| 珠宝区 | 相对湿度;人员密度;照明密度                    |
| 服装区 | 干球温度;太阳辐射;相对湿度;人员密度;照明功率密度        |
| 餐饮区 | 干球温度;太阳辐射;相对湿度;人员密度;照明功率密度;电器功率密度 |
| 娱乐区 | 干球温度;太阳辐射;相对湿度;人员密度;照明功率密度;电器功率密度 |

## 2 基于注意力机制的LSTM冷负荷预测模型

### 2.1 LSTM神经网络

通过商场区域冷负荷数据分析,冷负荷变化有明显的周期性规律,因此需要充分考虑其时序性问题。相较于传统的神经网络,LSTM网络模型<sup>[15]</sup>可以利用时间序列有效分析时序性数据中的隐含信息,在进行商场区域冷负荷预测过程中,LSTM网络能够充分利用前一时刻历史冷负荷信息处理序列数据,并利用该状态影响下一时刻冷负荷的输出。

LSTM网络的体系结构图,如图3所示。LSTM神经网络包含记忆单元、输入门、输出门和遗忘门。通过控制3个门的输入状态,可以减少由于存储长度的增加而引起的梯度爆炸和梯度消失的影响。输入变量 $X$ 用式(3)表示。

$$X = \begin{pmatrix} X_{c_{T-1}} \\ X_t \\ X_h \\ X_r \\ X_p \\ X_l \\ X_c \end{pmatrix} = \begin{pmatrix} X_{c_{T-1}}(1) & X_{c_{T-1}}(2) & X_{c_{T-1}}(n) \\ X_t(1) & X_t(2) & X_t(n) \\ X_h(1) & X_h(2) & X_h(n) \\ X_r(1) & X_r(2) & \dots & X_r(n) \\ X_p(1) & X_p(2) & X_p(n) \\ X_l(1) & X_l(2) & X_l(n) \\ X_c(1) & X_c(2) & X_c(n) \end{pmatrix}, \quad (3)$$

式中: $X_{c_{T-1}}$ 为上一时刻冷负荷; $X_t$ 为干球温度; $X_h$ 为相对湿度; $X_r$ 为太阳辐射量; $X_p$ 为人员密度; $X_l$ 为照明功率密度。

遗忘门用来决定从神经单元状态中丢弃的那些信息,此时细胞状态输出为:

$$f_T = \sigma(W_f[h_{T-1}, X_T] + b_f). \quad (4)$$

输入门是对细胞状态中的信息进行更新并储存,输入门的公式如下:

$$i_T = \sigma(W_i[h_{T-1}, X_T] + b_i), \quad (5)$$

$$C_T' = \tanh(W_c[h_{T-1}, X_T] + b_c), \quad (6)$$

$$C_T = f_T C_{T-1} + i_T C_T'. \quad (7)$$

输出门决定细胞输出的信息,其公式如下:

$$O_T = \sigma(W_o[h_{T-1}, X_T] + b_o), \quad (8)$$

$$h_T = O_T \tanh(C_T), \quad (9)$$

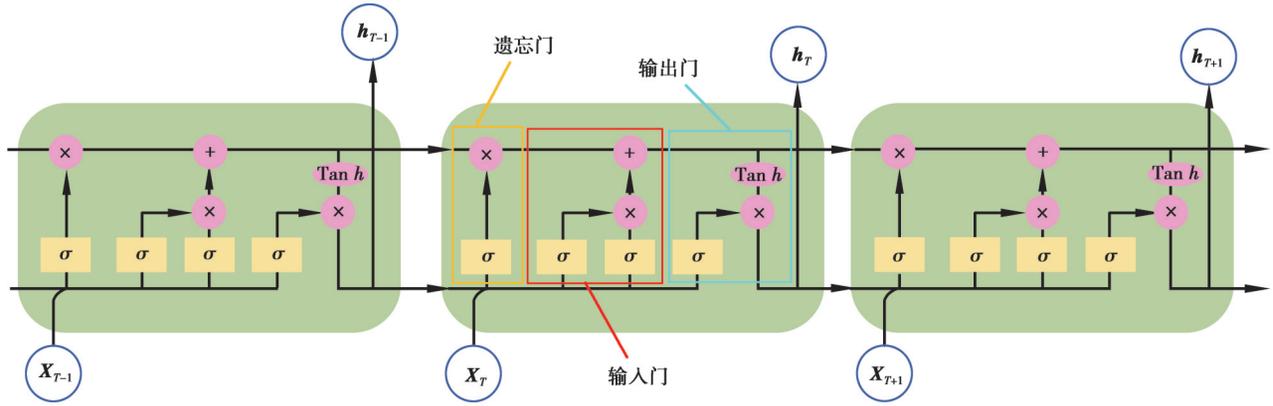


图 3 LSTM 体系结构图

Fig. 3 LSTM architecture diagram

式中： $f_t$ 为 LSTM 网络舍弃的信息， $i_t$ 为 LSTM 网络更新的信息， $C_t$ 为中间变量，存储当前 cell 信息， $C_t$ 表示新的细胞状态， $O_t$ 表示  $T$ 时刻输出门的信息， $h_{t+1}$ 表示隐藏层节点输出值， $W$ 为各个门的权重度量， $b$ 为偏差。

### 2.2 注意力机制

深度学习中的注意力机制通过模拟人脑注意力的资源分配机制，在某个特定时刻会将注意力集中在需要重点关注的区域，以获取更多所需要关注的细节信息，抑制其他无用的信息<sup>[16]</sup>。基于注意力机制的原理，针对商场冷负荷变化受实时变化的气象因素与人员主观行为的影响，设计出特征注意力机制和时序注意力机制，特征注意力机制用于分析不同输入变量对冷负荷的重要程度，挖掘变量与冷负荷之间的关联关系；时序注意力机制分析不同历史时刻的负荷对于预测时刻的重要程度，来选择关键时间点数据，从而提高预测模型的准确度。

#### 2.2.1 特征注意力机制

空调冷负荷变化受多因素影响。根据上文灰色关联度分析，不同区域影响空调冷负荷的关键变量有所差异，且关键变量的影响程度也不尽相同。为了探索相关因素对于空调冷负荷的关联程度，更好的学习输入特征的信息，引入特征注意力机制，如图 4 所示，采用多重感知机的方法对各特征影响力进行权重量化。

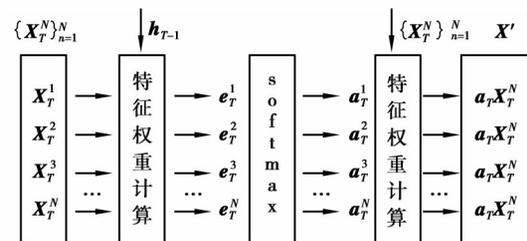


图 4 特征注意力机制

Fig. 4 Characteristic attention mechanism

根据特征注意力机制算法，前一时刻 LSTM 网络的隐藏状态  $h_{t-1}$  和当前时刻输入特征  $X_t^N$  作为特征注意力机制的输入，通过式(10)对当前时刻各变量进行注意权重计算，然后使用式(11)进行归一化处理。最后将当前时刻的权重与对应特征变量相乘得到特征注意力输出  $X'$ ，自适应优化相关特征的影响力。

$$e_t^N = V_c^T \tanh(W_c h_{t-1} + U_c X_t^N + b_c), \tag{10}$$

$$a_t^N = \text{soft max}(e_t^N) = \frac{\exp(e_t^N)}{\sum_{i=1}^M e_t^N}, \tag{11}$$

$$\mathbf{X}' = (\alpha_1^1 \mathbf{X}_1^1, \alpha_1^2 \mathbf{X}_1^2, \dots, \alpha_1^N \mathbf{X}_1^N)^T, \quad (12)$$

式中： $V_c \in \mathbb{R}^{N \times 1}$ 、 $W_c \in \mathbb{R}^{N \times q}$ 、 $U_c \in \mathbb{R}^{N \times N}$ 为多层感知机需要学习的神经元权重， $b_c \in \mathbb{R}^{N \times 1}$ 偏置参数； $q$ 为LSTM网络最后一层隐含层神经元数量。

### 2.2.2 时序注意力机制

当前时刻冷负荷受历史冷负荷影响较大且不同时刻的冷负荷影响力是不同的，为了研究每一历史时刻信息对当前预测结果的影响程度，对LSTM网络输出结果引入时序注意力机制。通过概率分配的方式对LSTM网络历史时刻进行重要性分析，分析各历史时刻的负荷对于预测时刻负荷的重要程度，从而提高预测精度。

时序注意力机制结构，如图5所示。其中， $\mathbf{X}_T (T \in [1, n])$ 表示LSTM网络的输入， $\mathbf{h}_T (T \in [1, n])$ 对应LSTM模型隐含层输出， $\alpha'_T (T \in [1, n])$ 为attention机制对LSTM隐含层输出的注意力概率分布值， $y$ 为引入时序注意力机制LSTM网络的输出值。

时序注意力机制中注意力权重矩阵 $\alpha'$ 和特征向量表示 $v$ 计算公式如下。

$$e'_T = u_s \tanh(w_s h_T + b_s), \quad (13)$$

$$\alpha'_T = \frac{\exp(e'_T)}{\sum_{n=1}^T e'_n}, \quad (14)$$

$$v = \sum_{T=1}^n \alpha'_T h_T, \quad (15)$$

式中： $e'_T$ 指为归一化权重矩阵； $w_s$ 、 $b_s$ 和 $u_s$ 分别为随机初始化的注意力机制权重矩阵、偏置量和时间序列矩阵。

### 2.3 基于双重注意力机制LSTM冷负荷预测模型

双重注意力机制LSTM预测模型，如图6所示。模型主要由输入向量、特征注意力层、LSTM网络层、时序注意力机制层和全连接输出层组成。输入向量结合前一时刻LSTM网络的隐藏状态 $h_{T-1}$ ，通过特征注意力机制层计算得到各特征变量当前时刻的权重并与对应特征变量相乘得到特征注意力输入 $\mathbf{X}'$ ，特征变量输入 $\mathbf{X}'$ 经过LSTM网络学习特征，然后通过时序注意力机制层计算各历史时刻输出冷负荷信息的影响权重并得到改进后的当前时刻隐含层状态输出，最后输入到全连接层得到最终预测结果。

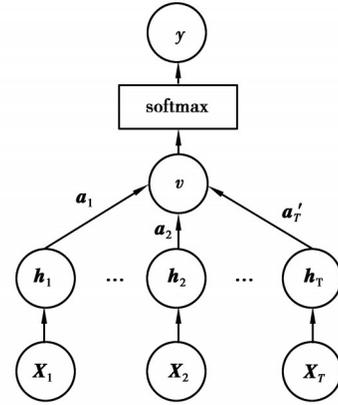


图5 时序注意力机制结构

Fig. 5 Temporal attention mechanism structure

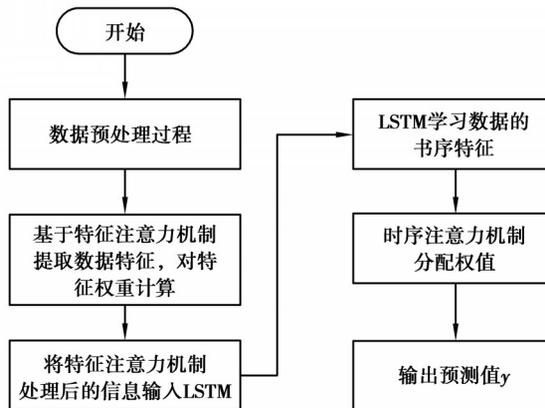


图6 基于双重注意力机制LSTM模型结构

Fig. 6 LSTM model structure based on dual attention mechanism

### 2.4 评价指标

预测模型采用3个评价指标（决定系数 $R^2$ 、平均绝对百分比误差MAPE、均方根误差RMSE）评价模

型的准确性。通过估算  $R^2$  值来量化某一时间段内冷负荷预测模型的拟合精度,  $R^2$  值越大, 表明模型与数据的对应时刻准确。MAPE 可以用来量化数据中的方差。RMSE 反映预测值和真实值的误差大小。这些评价公式见式 (16) ~ (18)。

$$R^2 = 1 - \frac{\sum_{j=1}^n (C_{pj} - C_{aj})^2}{\sum_{j=1}^n (C_{pj} - C_{aj})^2 + \sum_{j=1}^n (C_{pj} - C_{a,\text{mean}})^2}, \quad (16)$$

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{C_{pj} - C_{aj}}{C_{aj}} \right|, \quad (17)$$

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (C_{pj} - C_{aj})^2}{n}}, \quad (18)$$

式中:  $n$  为负荷数据总数,  $J$  为数据在时间上的指数,  $C_{aj}$  为实际冷负荷,  $C_{pj}$  为预测冷负荷,  $C_{a,\text{mean}}$  为实际冷负荷数据的平均值。

### 3 案例分析

#### 3.1 数据集

为了更好的验证本文所用方法, 采用西安某大型商场 2020-6-1 至 2020-8-31 的实际数据进行预测模型的学习和测试。由于此商场制冷系统采用间歇运行方式, 每天 8:00—22:00 空调保持运行。为保证实验过程中数据不重复使用, 特将 2020-6-1—2020-7-31 的数据作为训练集, 2020-8-1—2020-8-15 的数据作为验证集, 2020-8-15—2020-8-31 的数据作为测试集。原始数据集包括: 8:00—22:00 冷负荷数据 (kW), 干球温度 ( $^{\circ}\text{C}$ ), 相对湿度 (%), 太阳辐射量 ( $\text{kW}/\text{m}^2$ ), 人员密度 ( $\text{kw}/\text{m}^2$ ), 照明功率密度 ( $\text{W}/\text{m}^2$ ), 设备功率密度 ( $\text{W}/\text{m}^2$ )。

#### 3.2 实验设置

本实验考虑到商场周内和周末变化差异性, 拟合出不同星期类型人员逐时在室密度作为负荷预测的输入, 用于表示时间和星期的影响。利用 keras 进行数据处理, 输入时间步长 6, 通过滑动时间窗方法使用前 6 h 的数据预测下一时刻的冷负荷。通过使用网格搜索与交叉验证的方法对 LSTM 网络进行参数调整。通过对模型相关参数进行多次调整最终确定 LSTM 预测模型的具体参数, 见表 4。

表 4 LSTM 结构参数设置

Table 4 LSTM structure parameter settings

| 参数           | 数值        |
|--------------|-----------|
| LSTM 网络层数    | 2         |
| 第一层 LSTM 神经元 | 128       |
| 第二层 LSTM 神经元 | 32        |
| 时间步长         | 6         |
| 初始学习率        | 0.001     |
| Dropout      | 0.2       |
| 输出层          | 激活函数 Relu |
| 梯度下降法        | Adam      |
| 训练周期         | 200       |

#### 3.3 实验结果及分析

##### 3.3.1 变量选择对实验结果的影响

不同功能分区冷负荷关键影响因素的不同, 为了探究输入变量对预测模型的影响效果, 将原始数据集分为 2 类, 即使用经过灰色关联度选择的特征变量和不进行灰色关联度选择的原始特征变量, 使用 Attention-LSTM 预测模型分别进行预测, 如图 7 所示, 预测精度评价见表 5。

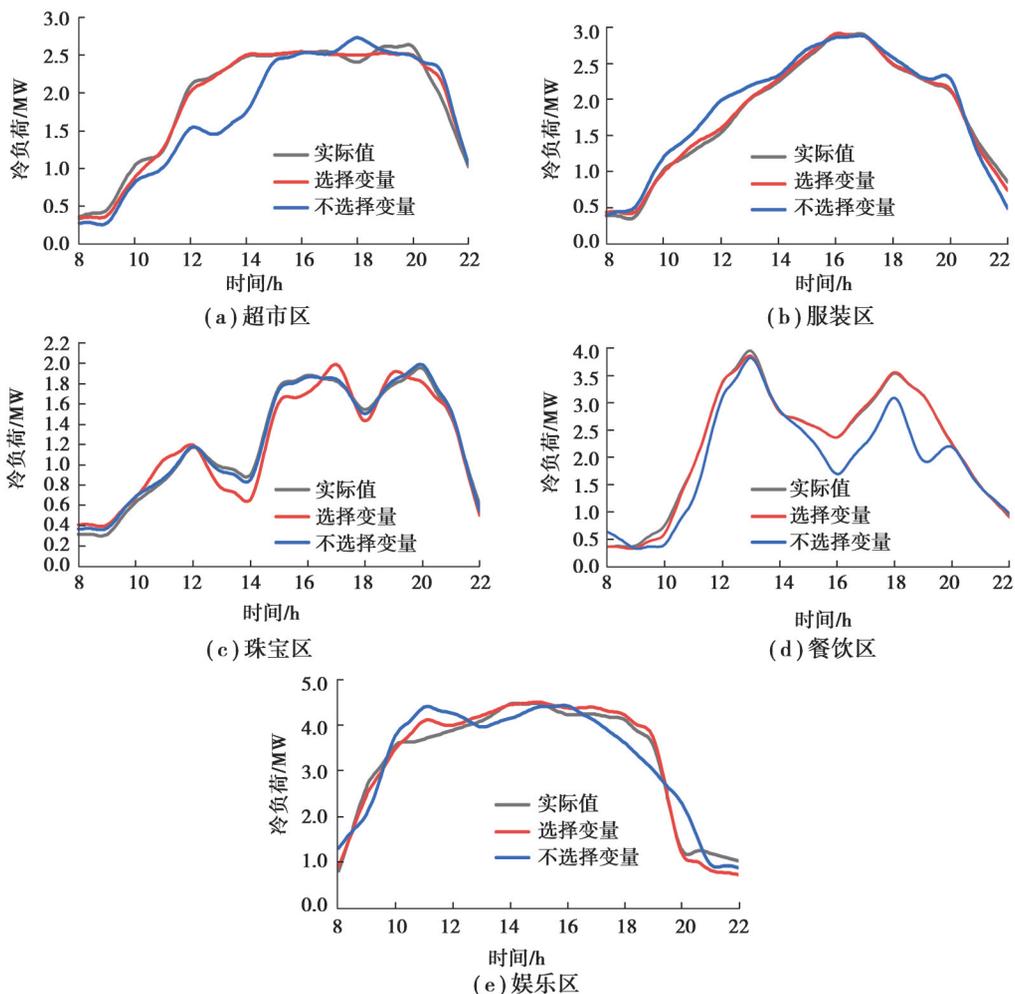


图7 不同输入变量下冷负荷预测结果

Fig. 7 Prediction results of cooling load under different input variables

由图7预测曲线可知,在对各功能分区输入的特征变量进行选择后,其预测曲线与真实曲线贴合度最好,由表5具体评价指标可知,在对输入变量进行选择后,MAPE减小到4%以下, $R^2$ 均稳定在0.99之上, RMSE也有显著减小。实验结果表明,当同一数据集,对原始变量进行选择后,其误差要比没有进行变量选择的低,这说明对输入的特征变量进行选择,可以剔除冗余变量和无效变量,增强模型的泛化能力,有效提高模型的预测速度,展现更好的预测效果。

表5 不同输入变量下预测精度比较

Table 5 Comparison of prediction accuracy under different input variables

| 功能区 |       | 评价指标   |       |         |
|-----|-------|--------|-------|---------|
|     |       | MAPE/% | $R^2$ | RMSE/kW |
| 餐饮区 | 选择变量  | 3.31   | 0.998 | 35.87   |
|     | 不选择变量 | 4.20   | 0.946 | 200.34  |
| 超市区 | 选择变量  | 3.44   | 0.991 | 52.07   |
|     | 不选择变量 | 4.61   | 0.964 | 170.30  |
| 服装区 | 选择变量  | 3.98   | 0.992 | 62.89   |
|     | 不选择变量 | 5.63   | 0.950 | 219.27  |
| 娱乐区 | 选择变量  | 2.57   | 0.998 | 22.17   |
|     | 不选择变量 | 4.37   | 0.879 | 93.48   |
| 珠宝区 | 选择变量  | 2.52   | 0.998 | 43.55   |
|     | 不选择变量 | 6.01   | 0.973 | 191.47  |

3.3.2 不同预测模型对实验结果的影响

为了验证双重注意力机制 LSTM 模型的有效性,在考虑到工作日和周末冷负荷需求的差别。选取商场 8 月 27 日周四作为夏季工作典型日,8 月 30 日周日作为夏季周末典型日进行预测分析。测试日室外气象情况,如图 8 所示。为了探究双重注意力机制 LSTM 模型的预测效果,将传统 LSTM 预测模型和 CNN-LSTM 预测模型以及文献[13]中提出的 Attention-LSTM 预测模型的预测结果与本文所提出的双重注意力机制 LSTM 模型进行对比,各功能分区使用 3 个不同预测模型预测值与实际值的对比,如图 9~13 所示。

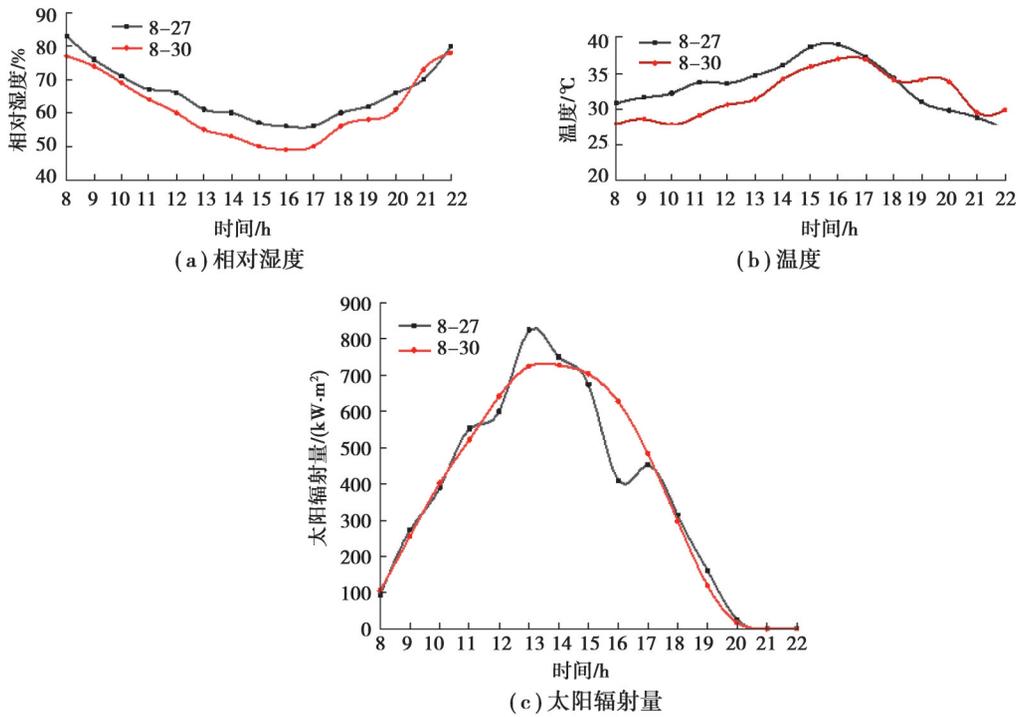


图 8 不同测试日室外气象参数

Fig. 8 Outdoor meteorological parameters of different test days

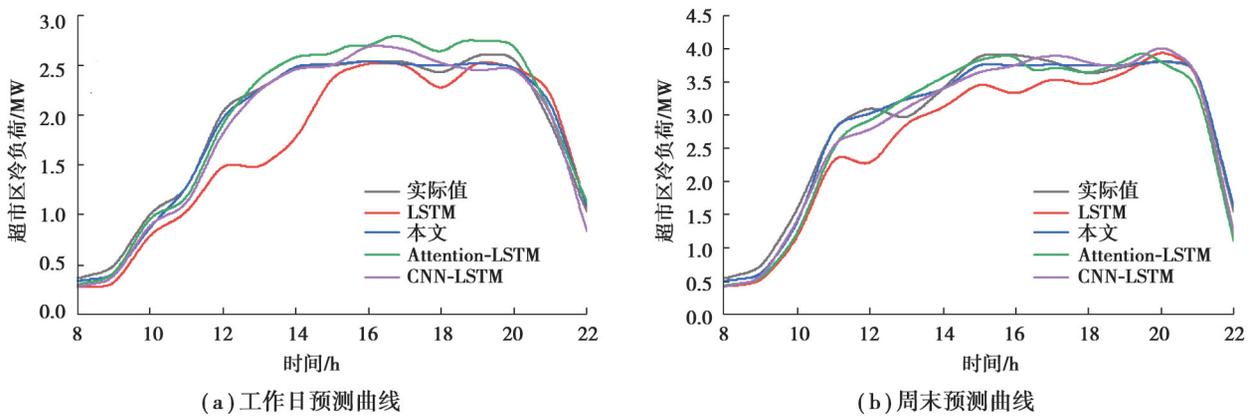


图 9 超市区冷负荷预测曲线

Fig. 9 Prediction curve of cooling load in supermarket area

在对工作日各功能区冷负荷的预测中,由图 9~13 预测曲线可知,双重注意力机制 LSTM 模型预测曲线与真实值贴合最好。具体评价指标,见表 6。对工作日预测时,各功能区平均绝对百分误差 MAPE 分别为 3.23%、3.41%、3.41%、3.39% 和 3.52%,低于其他 2 种模型;决定系数  $R^2$  均大于 0.99,高于其他模型;RMSE 小于其他模型,这说明双重注意力机制 LSTM 模型的预测更准确,展现了更好的预测效果。

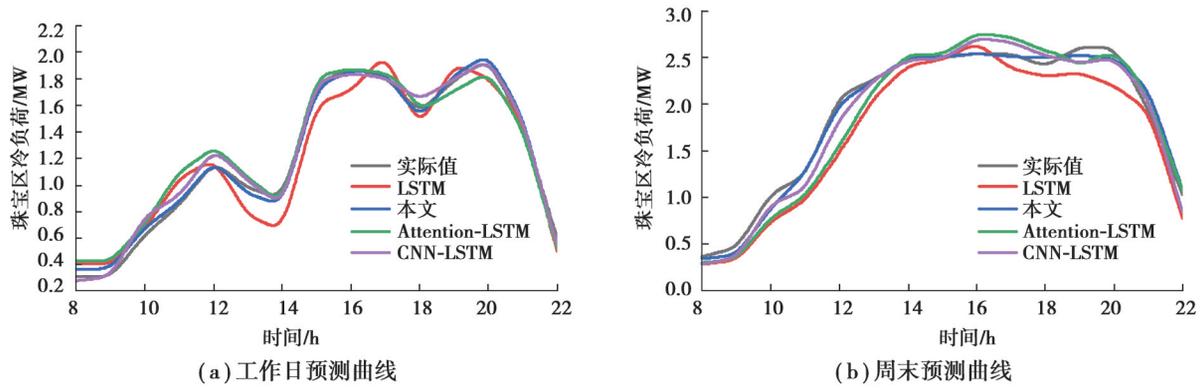


图10 珠宝区冷负荷预测曲线

Fig. 10 Prediction curve of cooling load in jewelry area

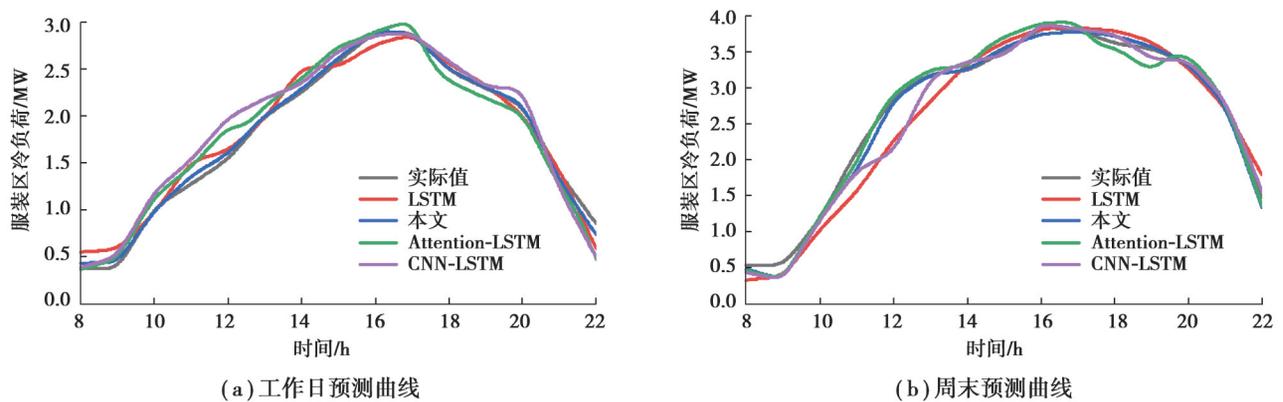


图11 服装区冷负荷预测曲线

Fig. 11 Prediction curve of cooling load in garment area

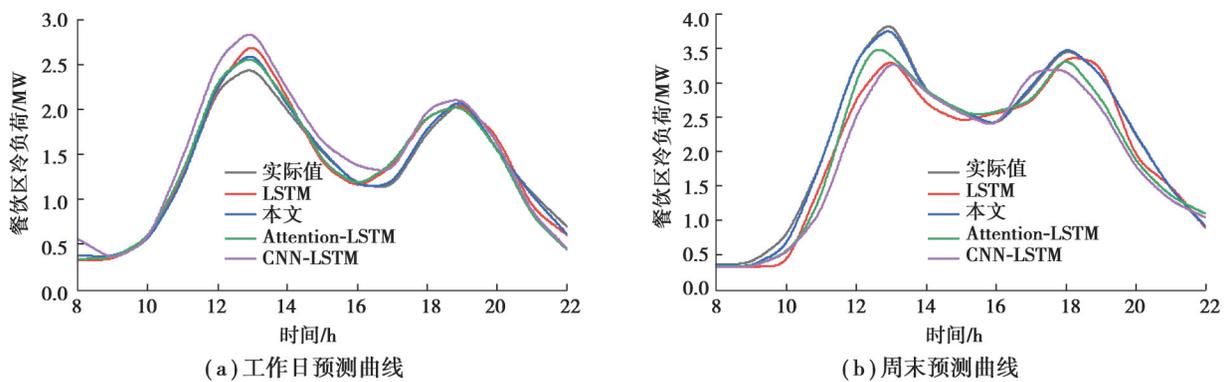


图12 餐饮区冷负荷预测曲线

Fig. 12 Prediction curve of cooling load in restaurant area

在对周末各功能区冷负荷的预测中,由图9~13预测曲线可知,3种预测模型的变化趋势都接近于真实趋势,但双重注意力机制LSTM模型贴合程度最高。具体评价指标,见表7。周末各功能区冷负荷周末平均绝对百分误差为3.12%、3.31%、2.34%、3.14%、2.57%,比LSTM模型、CNN-LSTM模型和Attention-LSTM模型误差小,均定系数 $R^2$ 分别为0.998、0.990、0.991、0.990和0.998,在3个模型中数值最高,RMSE在3个模型中数值最小,这说明周末依旧是双重注意力机制LSTM模型有更好的预测效果。

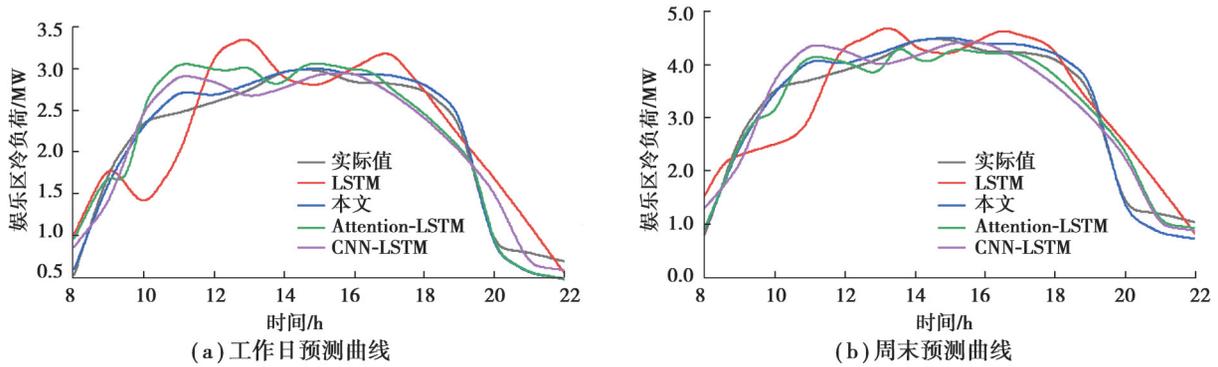


图 13 娱乐区冷负荷预测曲线

Fig. 13 Prediction curve of cooling load in entertainment area

表 6 工作日冷负荷预测误差表

Table 6 Cooling load prediction error at working days

| 指标    | 模型             | 功能区     |         |         |         |         |
|-------|----------------|---------|---------|---------|---------|---------|
|       |                | 餐饮区     | 超市区     | 服装区     | 娱乐区     | 珠宝区     |
| MAPE  | LSTM           | 4.69    | 5.96    | 4.87    | 6.28    | 5.76    |
|       | CNN-LSTM       | 4.34    | 5.55    | 4.60    | 4.19    | 5.02    |
|       | Attention-LSTM | 3.96    | 4.32    | 3.87    | 4.01    | 3.99    |
|       | 本文             | 3.23    | 3.41    | 3.41    | 3.39    | 3.52    |
| $R^2$ | LSTM           | 0.879   | 0.894   | 0.965   | 0.894   | 0.879   |
|       | CNN-LSTM       | 0.951   | 0.970   | 0.960   | 0.970   | 0.964   |
|       | Attention-LSTM | 0.987   | 0.972   | 0.964   | 0.976   | 0.982   |
|       | 本文             | 0.998   | 0.990   | 0.991   | 0.990   | 0.998   |
| RMSE  | LSTM           | 164.557 | 137.432 | 152.299 | 124.912 | 132.323 |
|       | CNN-LSTM       | 107.807 | 79.476  | 133.358 | 92.269  | 82.269  |
|       | Attention-LSTM | 73.698  | 68.125  | 128.346 | 73.698  | 63.426  |
|       | 本文             | 59.972  | 43.551  | 54.507  | 32.179  | 45.878  |

表 7 周末冷负荷预测误差表

Table 7 Cooling load prediction error at weekends

| 指标    | 模型             | 功能区     |         |         |         |         |
|-------|----------------|---------|---------|---------|---------|---------|
|       |                | 餐饮区     | 超市区     | 服装区     | 娱乐区     | 珠宝区     |
| MAPE  | LSTM           | 4.90    | 5.69    | 6.41    | 4.87    | 6.02    |
|       | CNN-LSTM       | 4.86    | 5.31    | 5.03    | 3.99    | 5.01    |
|       | Attention-LSTM | 4.23    | 3.98    | 4.12    | 3.68    | 3.57    |
|       | 本文             | 3.12    | 3.31    | 2.34    | 3.14    | 2.57    |
| $R^2$ | LSTM           | 0.938   | 0.879   | 0.953   | 0.949   | 0.949   |
|       | CNN-LSTM       | 0.973   | 0.955   | 0.948   | 0.956   | 0.980   |
|       | Attention-LSTM | 0.982   | 0.976   | 0.983   | 0.952   | 0.971   |
|       | 本文             | 0.991   | 0.999   | 0.995   | 0.990   | 0.993   |
| RMSE  | LSTM           | 168.474 | 213.484 | 232.972 | 149.120 | 244.634 |
|       | CNN-LSTM       | 124.917 | 133.171 | 222.885 | 140.050 | 153.622 |
|       | Attention-LSTM | 72.698  | 93.143  | 168.359 | 90.156  | 125.682 |
|       | 本文             | 59.972  | 35.878  | 119.862 | 63.646  | 90.018  |

综合工作日和周末冷负荷预测分析结果,双重注意力机制和LSTM网络预测模型相比较于传统LSTM预测模型、CNN-LSTM预测模型和Attention-LSTM预测模型具有更好的预测性能,其预测精度更高,稳定性更好。这是由于在LSTM网络模型基础上增加了两层注意力机制,不仅对多变量的输入通过特征注意力机制分析相关特征的重要性,优化输入特征,同时还通过时序注意力机制结合历史冷负荷信息,优化模型的输出。

## 4 结 论

针对大型商场各区域实际冷负荷需求问题,提出了基于双重注意力机制和LSTM网络分区冷负荷预测方法。通过对西安某大型商场的实际工程数据进行验证分析,得出以下结论:

1) 大型商场各功能分区冷负荷实际需求的差异性,在进行冷负荷预测时,需要对各功能区域进行区分,从而为冷负荷影响因素分析及预测模型提供支撑。通过灰色关联度分析,影响商场各功能分区冷负荷关键因素有所不同,关键因素的确定可以提高冷负荷预测的准确性并提升预测模型的泛化能力。

2) 在LSTM网络的基础上引入双重注意力机制,利用特征信息的关联性和时序信息的历史依赖性提升负荷预测准确度。实验结果表明,与传统的LSTM、CNN-LSTM预测模型、Attention-LSTM预测模型相比,对各功能区的工作日和周末均方根误差RMSE和平均绝对百分比误差MAPE均有明显降低,决定系数 $R^2$ 均高于0.99。

3) 基于分区冷负荷预测,能够更为准确地预测各功能区冷负荷值,为商场末端冷冻水按需供应提供了保障,对输配管网系统调节阀开度的优化提供有效参考信息,能够实现商场区域供冷系统的节能控制,符合实际工程的应用。

## 参考文献

- [ 1 ] Fan C, Xiao F, Zhao Y. A short-term building cooling load prediction method using deep learning algorithms[J]. Applied Energy, 2017, 195: 222-233.
- [ 2 ] 杨福,王衍金,王伟宵.基于eQUEST的某商业建筑空调系统节能分析[J].建筑节能,2020,48(5):76-79.  
Yang F, Wang Y J, Wang W X. Energy simulation analysis of a commercial building based on eQUEST[J]. Building Energy Efficiency, 2020, 48(5): 76-79.(in Chinese)
- [ 3 ] Ahmad T, Chen H X, Guo Y B, et al. A comprehensive overview on the data driven and large scale based approaches for forecasting of building energy demand: a review[J]. Energy and Buildings, 2018, 165: 301-320.
- [ 4 ] American Society of Heating, Refrigerating and Air-Conditioning Engineers, Inc., Atlanta, (United States)GA. Building on the shoulders of giants. Annual report, July 1, 1994-June 30, 1995[R]. Office of Scientific and Technical Information (OSTI), 1996.
- [ 5 ] Campana J P, Morini G L. BESTEST and EN ISO 52016 benchmarking of ALMABuild, a new open-source simulink tool for dynamic energy modelling of buildings[J]. Energies, 2019, 12(15): 2938.
- [ 6 ] Abasnezhad S, Soltani N, Markarian E, et al. Impact of building design parameters precision on heating and cooling load calculations[J]. Environmental Progress & Sustainable Energy, 2019, 38(2): 741-749.
- [ 7 ] Zhou X, Fan Z B, Liang L Q, et al. Comparison of four algorithms based on machine learning for cooling load forecasting of large-scale shopping mall[J]. Energy Procedia, 2017, 142: 1799-1804.
- [ 8 ] Fan C L, Ding Y F. Cooling load prediction and optimal operation of HVAC systems using a multiple nonlinear regression model[J]. Energy and Buildings, 2019, 197: 7-17.
- [ 9 ] Fan C L, Liao Y D, Zhou G, et al. Improving cooling load prediction reliability for HVAC system using Monte-Carlo simulation to deal with uncertainties in input variables[J]. Energy and Buildings, 2020, 226: 110372.
- [ 10 ] 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(中英文),2019,41(1):168-174.

- Yang X, Yu J Q, Guo C L, et al. Dynamic load forecasting model of ice storage air conditioning based on improved PSO-BP neural network[J]. Journal of Civil and Environmental Engineering, 2019, 41(1): 168-174. (in Chinese)
- [11] 周璇, 凡祖兵, 刘国强, 等. 基于多元非线性回归法的商场空调负荷预测[J]. 暖通空调, 2018, 48(3): 120-125, 95.
- Zhou X, Fan Z B, Liu G Q, et al. Cooling load prediction of shopping mall air conditioning based on multivariate nonlinear regression method[J]. Heating Ventilating & Air Conditioning, 2018, 48(3): 120-125, 95. (in Chinese)
- [12] 邵必林, 史洋博, 赵煜. 融合注意力机制与 LSTM 的建筑能耗预测模型研究[J]. 软件导刊, 2021, 20(10): 61-67.
- Shao B L, Shi Y B, Zhao Y. Research on building energy consumption prediction model by integrating attention mechanism and LSTM[J]. Software Guide, 2021, 20(10): 61-67.(in Chinese)
- [13] 李慧, 段培永, 刘凤英. 大型商场建筑夏季冷负荷动态预测模型[J]. 土木建筑与环境工程, 2016, 38(2): 104-110.
- Li H, Duan P Y, Liu F Y. Prediction model of dynamic cooling load for shopping mall building in summer[J]. Journal of Civil, Architectural & Environmental Engineering, 2016, 38(2): 104-110. (in Chinese)
- [14] 解海翔, 陈芳芳, 刘易, 等. 基于改进灰色关联分析和 CMPSO-LSSVM 算法的短期电力负荷预测[J]. 现代电子技术, 2021, 44(8): 177-181.
- Xie H X, Chen F F, Liu Y, et al. Short-term power load prediction based on improved grey relational analysis and CMPSO-LSSVM algorithm[J]. Modern Electronics Technique, 2021, 44(8): 177-181. (in Chinese)
- [15] 田浩含, 撒奥洋, 于立涛, 等. 基于 GRA-LSTM 神经网络的区域综合能源系统多元负荷短期预测模型[J]. 广东电力, 2020, 33(5): 44-51.
- Tian H H, Han A Y, Yu L T, et al. Research on multi-load short-term forecasting model of regional integrated energy system based on GRA-LSTM neural network[J]. Guangdong Electric Power, 2020, 33(5): 44-51. (in Chinese)
- [16] 周雨佳, 窦志成, 葛松玮, 等. 基于递归神经网络与注意力机制的动态个性化搜索算法[J]. 计算机学报, 2020, 43(5): 812-826.
- Zhou Y J, Dou Z C, Ge S W, et al. Dynamic personalized search based on RNN with attention mechanism[J]. Chinese Journal of Computers, 2020, 43(5): 812-826. (in Chinese)

(编辑 郑洁)