

基于混合深度学习模型的企业中央空调蒸汽预测

王 可¹, 卢焕达², 郑军红¹, 何利力¹

(1. 浙江理工大学信息学院, 浙江 杭州 310018)

(2. 浙大宁波理工学院计算机与数据工程学院, 浙江 宁波 315100)

[摘要] 为解决企业生产车间多空调能耗与生产任务、气候环境匹配的精准供能问题, 实现多台大型中央空调机组蒸汽消耗预测, 提出一种基于 GRU 和 3DConv-PredRNN++ 的混合深度学习预测模型。针对多台空调机组动态联动关系, 使用三维卷积和 PredRNN++ 方法提取机组间蒸汽损耗关系作为空间因素特征参与模型预测; 为捕捉蒸汽消耗量序列的总体趋势和局部变化, 数据集采用平滑过程模式、趋势性模式和周期性模式作为模型输入; 为提高模型预测性能, 基于门控循环单元 (GRU) 耦合外部因素特征并捕捉时间因素特征; 最后通过参数矩阵融合方式来构建模型。通过与多种预测模型的对比实验, 证明混合深度学习模型预测精度的优越性和空间因素特征参与模型预测的必要性。与现有模型相比, 所提模型平均能耗折标 (ASEC) 降低了 60.09%。

[关键词] 空调蒸汽消耗, 三维卷积, PredRNN++, 门控循环单元, 空间特征

[中图分类号] TP181 **[文献标志码]** A **[文章编号]** 1672-1292(2022)03-0053-10

Steam Prediction of Central Air Conditioning Based on Hybrid Deep-learning Model

Wang Ke¹, Lu Huanda², Zheng Junhong¹, He Lili¹

(1. School of Information Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China)

(2. School of Computer and Data Engineering, NingboTech University, Ningbo 315100, China)

Abstract: In order to solve the steam consumption prediction problem of several large central air-conditioning units, a hybrid deep-learning prediction model based on GRU and 3DConv-PredRNN++ is proposed. Aiming at the dynamic linkage relationship of multiple air conditioning units, the relationship between steam consumption of units is extracted by convolutions over volumes and PredRNN++ method, which is used as a feature of spatial factors to participate in model prediction. In order to capture the overall trend and local variation of the steam consumption series, smooth process model, trend model and periodic model are used as model inputs in the data set. In order to improve the prediction performance of the model, a GRU is used to combine the external factor features and capture the temporal factor features. Finally, the model is constructed by parameter matrix fusion. Through comparison experiments with various prediction models, it is proved that the prediction accuracy of the model is superior and that it is necessary to extract spatial factors to participate in model prediction. Compared with the current model, the average standard energy consumption of this model is reduced by 60.09%.

Key words: air conditioning steam consumption, convolutions over volumes, PredRNN++, GRU, spatial feature

工业企业普遍存在能源利用率偏低、能耗偏高的问题,降低能源工业消耗比重是企业首要考虑的问题之一。中央空调的蒸汽供应模块作为能源供应中的重要一环,与企业能源消耗结构息息相关。由于生产工况不稳定、多台空调机组相互作用、系统产生数据分析复杂等问题,传统的蒸汽能源供应策略往往不易获得最佳效果,致使工业企业能耗居高不下^[1-3]。

目前对蒸汽消耗预测问题多采用统计学方法、传统机器学习方法和深度学习方法。文献[4]采用自回归移动平均对造纸厂蒸汽消耗需求进行预测,对未来生产的汽耗需求提供了理论指导;文献[5]提出使用机器学习方法对火力发电蒸汽量预测展开研究,实现了锅炉运行过程模拟,提高了整体工艺水平;文献

收稿日期: 2020-10-15.

基金项目: 浙江省重点研发计划项目 (2021C01110).

通讯作者: 卢焕达, 博士, 副教授, 研究方向: 机器学习、数据分析. E-mail: huandalu@163.com

[6]通过构建梯度提升机模型,对气体脱硫过程的蒸汽消耗精准预测,减少了电量损耗.

本文对某大型企业卷包车间空调蒸汽消耗预测问题展开研究. 由于蒸汽供应策略的实施与策略生效之间有一定的滞后效应,因此必须预测每个班次中的蒸汽消耗量的变化趋势,尽快实施工业策略消除滞后效应对生产造成的影响. 空调消耗量的动态变化过程中,各种因素之间存在复杂的相互作用,故需要考虑多种因素特征来构建预测模型. 最后力求达到根据预测结果系统自动调控多空调蒸汽消耗量的目的,实现节能降耗.

1 蒸汽空调机理分析与问题描述

空调给车间生产提供了良好的环境条件,不同空调机组的运作方式直接影响着空调的蒸汽消耗量. 空调系统处理空气的简易流程如图 1 所示. 通过回风阀和新风阀调节支管的风量,将新风与回风混合调节送入过滤器中. 表冷器利用冷水通过冷却盘管使盘管表面呈现低温状态,过滤后的空气通过表冷器盘管达到降温效果. 当空气温度降到露点温度,水蒸气分压大于饱和蒸汽压,出现结露,达到除湿效果. 加热器是由干蒸汽加热盘管对过滤后的空气进行加温,干蒸汽加湿器则对空气进行等温加湿. 处理好的空气通过送风机送入生产车间.




图 1 空调系统处理空气的简易流程
Fig. 1 Process of handling air by air conditioning unit

全年空气处理过程如图 2 所示,符号含义如表 1 所示. 室内恒温恒湿状态点 N 和 $N1$ 由自控系统自动设置. 过程 1 和过程 2 是夏季机组空气处理流程,过滤后的空气通过表冷盘管冷冻除湿降至露点,除湿后的低温空气经过蒸汽加热升温,达到送风状态点,由送风机送到车间,此过程中会出现冷源与热源相互抵消的情况. 过程 3-6 是过渡季节机组空气处理流程,通过降温加湿或升温除湿操作达到送风状态点. 冬季机组空气处理流程为过程 7 和过程 8,新回风通过过滤器过滤为干净空气,经蒸汽加热后,由干蒸汽加湿器等温加湿后满足送风状态.




图 2 全年空调焓湿图
Fig. 2 Annual air conditioning psychrometrics

表 1 焓湿图符号表示含义

Table 1 Meaning of psychrometrics symbol

符号	含义	符号	含义
W1-W8	全年室外可能出现的状态点(顺序为夏-春-秋-冬)	N、N1	车间恒温恒湿状态点
C	新回风混合状态点	O、O1	车间送风状态点
S	加热器和加湿器间的状态点	H	冷源和热源相互抵消的热能焓值
L	夏季露点		

由图 2 可知,空调机组 8 种处理方式的蒸汽消耗量都不相同,其原因为机组工作方式受时间因素、外部因素和空间因素的共同影响. 时间因素表现在历史蒸汽消耗量对预测蒸汽消耗量的影响. 外部因素包

括气候、生产班次等,其中生产班次分为早中晚班,早班时间为 7:00—15:30,中班时间为 15:30—0:00,晚班时间为 0:00—7:00,每个班次相应的生产计划不同. 空间因素是指调控区域无间隔,多台大型空调机组存在动态联动关系,共同作用来维持车间生产环境条件的稳定. 本文的目标是对未来班次中每分钟的蒸汽消耗量进行准确预测,实现瞬时动态预测防止产生滞后效应,给空调系统自动调控提供策略依据,实现节能降耗. 该问题可用公式(1)描述:

$$F=f(X,E,I,W), \quad (1)$$

式中, F 为预测蒸汽消耗量; f 为混合深度学习模型; X 为历史蒸汽消耗量输入; E 为外部因素特征输入; I 为空间因素特征输入; W 为学习权重.

2 模型构建

该企业车间具有大面积无隔断的特点,相邻机组互相影响,存在一个生产机械设备分布在两台机组调控区域之间的情况,因此每台机组的蒸汽消耗量不能单独计算预测. 每个班次的任务量不同会导致不同班次的蒸汽消耗量不同,外界环境条件、厂房温湿度环境等外部条件也同样影响蒸汽消耗量. 目前存在的制造企业对蒸汽预测方法不能解决本文中基于复杂环境下的空调蒸汽预测问题. 文献[5]利用多元线性回归、支持向量回归、树模型和改进模型融合构建模型,主要为验证最合理的工艺参数来提升设备精度. 文献[7]使用基于混沌时间序列的支持向量机来构建预测模型,只考虑了时间因素单方面的影响. 本文采用一种混合模型来解决复杂环境下的空调蒸汽预测问题,从时间因素、外部因素和空间因素多角度综合考虑,以提升预测模型的准确性并降低企业能耗.

2.1 模型架构

时间因素、空间因素和外部因素共同作用影响空调蒸汽消耗量,本文采用不同方法提取 3 种因素特征,作为预测模型的输入:采用平滑过程模式、趋势性模式和周期性模式结合门控循环单元(gate recurrent unit, GRU)捕捉时间因素特征;采用 GRU 和两层全连接网络耦合外部因素特征;利用三维卷积(convolutions over volumes)和 PredRNN++提取空间因素特征. 最后根据 3 个部分的影响程度采用参数矩阵方法进行融合,计算公式为:

$$\hat{Y}=\sigma(W_1 \odot X_T+W_2 \odot X_E+W_3 \odot X_S), \quad (2)$$

式中, \hat{Y} 为预测空调蒸汽消耗量; W_1 、 W_2 、 W_3 为学习权重; X_T 为时间因素特征输出; X_E 为外部因素特征输出; X_S 为空间因素特征输出; \odot 为哈达玛积. 整体模型结构如图 3 所示.

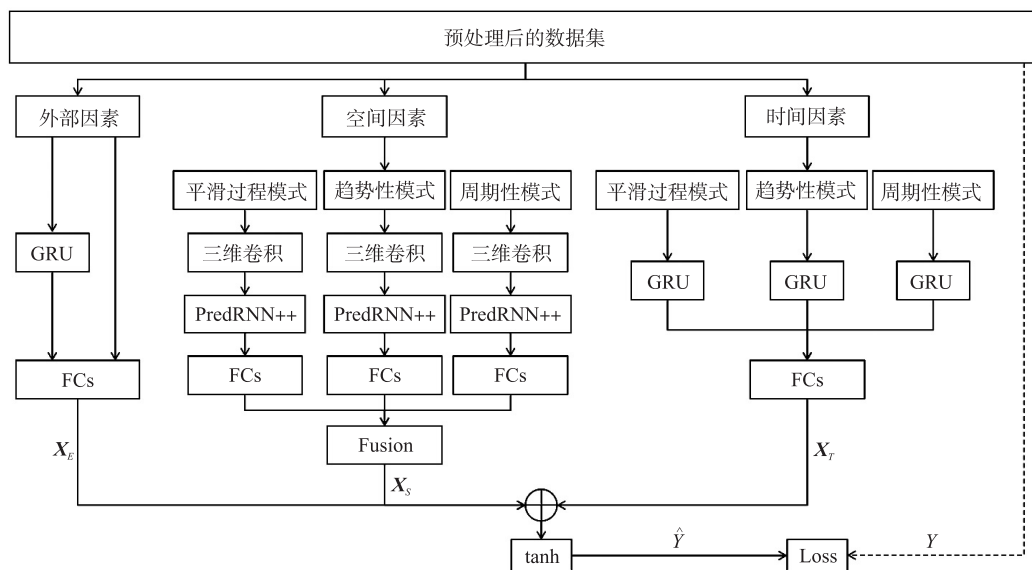


图3 空调蒸汽消耗量预测模型整体结构

Fig. 3 Overall structure of air conditioning steam consumption prediction model

2.2 基于 GRU 捕捉 3 种模式时间特征、耦合外部因素特征

时间特征体现的是历史蒸汽消耗量对预测蒸汽消耗量的影响. 为提高模型的预测精度,将时间特征

输入分为平滑过程模式、趋势性模式和周期性模式^[8-9]. 不同模式的特征结合可以获取时间序列的总体趋势和局部变化,提取出时间特征 X_T . 设定平滑过程模式的周期为 8.5 h,另外两种模式的周期制定与平滑过程模式输入数据量保持一致. 若预测某天某班次中某 0.5 h 的空调蒸汽量,平滑过程模式输入预测班次前 8.5 h 的蒸汽瞬时消耗量,趋势性模式输入前 17 天该班次该时段的蒸汽瞬时消耗量,周期性模式输入前 17 周该天该班次该时段的蒸汽瞬时消耗量.

GRU 属于循环神经网络的一种,具有参数少更容易收敛的优点^[10]. GRU 模型简单,只有一个重置门和一个更新门,更新门决定要丢弃的信息和添加的新信息,重置门是另一个来决定要忘记多少过去的信息. GRU 的工作原理为:

$$\begin{aligned} z_t &= \sigma(W_z \cdot [h_{t-1}, x_t]), \\ r_t &= \sigma(W_r \cdot [h_{t-1}, x_t]), \\ \tilde{h}_t &= \tanh(W \cdot [r_t \odot h_{t-1}, x_t]), \\ h_t &= (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t. \end{aligned} \quad (3)$$

式中, z_t 、 r_t 、 \tilde{h}_t 、 h_t 分别为更新门、重置门、候选隐藏状态和隐藏状态; W 为权重矩阵; x_t 为当前时刻的原始输入; σ 表示 Sigmoid 函数; \tanh 表示双曲正切函数; \odot 为哈达玛积. GRU 内部结构图如 4 所示.

外部因素特征包括室内温湿度、室外温湿度、露点温度、生产班次、生产日期(工作日与非工作日). 通过 GRU 对温湿度和露点温度进行时间序列分析,预测得到其在待预测班次的相应值,结合生产安排得到班次和日期信息,将全部特征作为第一层全连接层的输入,然后链接一个激活函数 ReLU;第二层全连接网络用于维度映射,耦合出外部特征 X_E .




图 4 GRU 内部结构图

Fig. 4 GRU internal structure diagram

2.3 基于三维卷积与 PredRNN++提取多空调联动的空间特征

为增加超大空间恒温恒湿空调系统的稳定性和可靠性,车间环境采取多台大型空调机组协同控制策略. 调控区域无间隔且相邻区域间相互影响,存在同一生产设备分布在两台独立空调设备调控区域之间的情况. 因此,对空调蒸汽消耗量的预测不能只根据时序相关性进行建模,还应考虑空调设备之间的动态联动关系. 车间中空调设备和生产设备的分布如图 5 所示.




图 5 生产车间空调设备和生产设备分布图

Fig. 5 Distribution of air conditioning equipment and production equipment in production workshop

为提取影响空调蒸汽消耗量的空间因素特征,采用基于三维卷积与 PredRNN++方法来构建神经网络模型. 首先构造一个三维卷积神经网络^[11-12],将空调历史蒸汽消耗量数据转化为三维图像,通过三维卷积来细化参数间的影响关系,并将结果按第一维度展开作为 PredRNN++过程的输入. PredRNN++能够自适应地捕获短期和长期相关性,有强空间相关性和短期动态的建模能力,还解决了梯度消失问题^[13]. 将 PredRNN++过程

的输出送至全连接层,得到空间因素特征 \mathbf{X}_s 。提取空间因素特征的模型框架如图 6 所示。

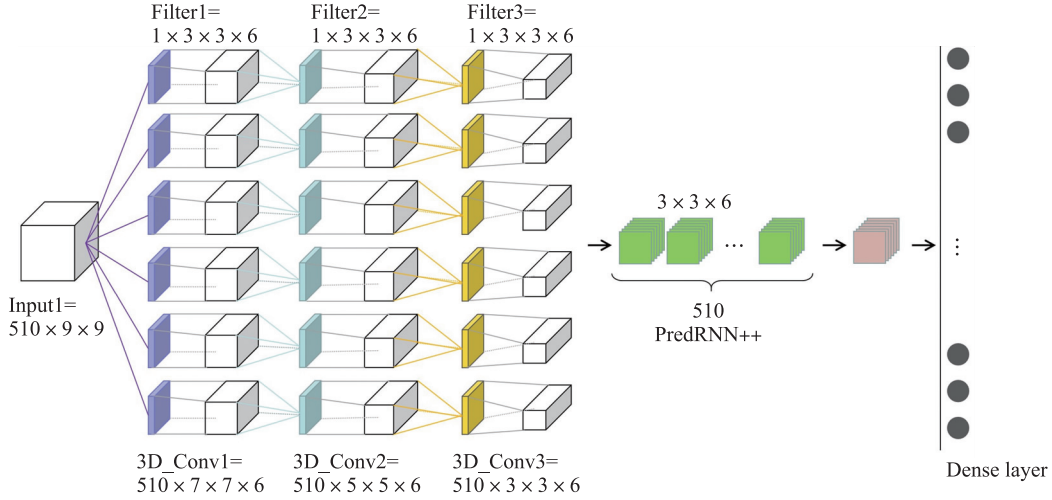


图 6 基于三维卷积与 PredRNN++ 的神经网络模型框架

Fig. 6 Neural network model framework based on 3D convolution and PredRNN++

2.3.1 卷积提取过程

由于空调蒸汽的消耗量是一个连续动态过程,且与同一区域的其他空调机组蒸汽消耗量之间存在复杂的相互作用,用精确的数学模型来描述存在很大困难。为了得到各参数之间的不确定关系,首先将 9 个关联空调机蒸汽消耗量组成的原始向量乘以其转置得到一个 9×9 的单通道矩阵,表达任意两个机组消耗量的所有组合,9 个原始参数被细化为 $9 \times 9 = 81$ 个参数。假设 $S_1 \sim S_9$ 表示 9 个空调机组的蒸汽消耗量,设 $\mathbf{S} = [S_1, S_2, \dots, S_8, S_9]^T$, 则

$$\mathbf{S} \times \mathbf{S}^T = \begin{bmatrix} S_1 \times S_1 & S_1 \times S_2 & \cdots & S_1 \times S_8 & S_1 \times S_9 \\ S_2 \times S_1 & S_2 \times S_2 & \cdots & S_2 \times S_8 & S_2 \times S_9 \\ \vdots & \vdots & & \vdots & \vdots \\ S_8 \times S_1 & S_8 \times S_2 & \cdots & S_8 \times S_8 & S_8 \times S_9 \\ S_9 \times S_1 & S_9 \times S_2 & \cdots & S_9 \times S_8 & S_9 \times S_9 \end{bmatrix}, \quad (4)$$

再结合班次数据组成一个 $510 \times 9 \times 9$ (深度 \times 长度 \times 宽度) 的三维矩阵。

而后采用卷积运算来提取特征。连续卷积过程的目的是为了细化参数,进一步确认其间的潜在关系,因而不需要添加池化层来简化计算。3 个连续的卷积过程如图 7 所示。




图 7 连续卷积过程

Fig. 7 Continuous convolution process

第一层卷积使用 6 个大小为 $1 \times 3 \times 3$ 的过滤器,设置其步幅为 1, padding 为 0。其中,“1”为过滤器的深度,用以表示对 9 台机组潜在关系的细化。以 A_{11} 为例,第一次卷积的运算公式为:

$$A_{11} = F \left(\sum_{i=1}^3 \sum_{j=1}^3 Z_{ij} \mathbf{W}_{ij}^{L_1} + D_{L_1} \right), \quad (5)$$

式中, F 为 ReLu 非线性函数; Z_{ij} 表示输入矩阵第 i 行第 j 列参数; L_k 表示输出矩阵的通道深度, 3D_Conv1 的通道深度用 $L_1 \sim L_6$ 表示; $\mathbf{W}_{ij}^{L_k}$ 为 L_k 层的共享权值, 每个过滤器都有 $3 \times 3 = 9$ 个共享权值; D_{L_1} 表示 L_1 层的

共享偏差.

第二层卷积和第三层卷积同样使用 6 个大小为 $1 \times 3 \times 3$ 的过滤器, 设置其步幅为 1, padding 为 0. 3D_Conv2 的通道深度用 L_7-L_{12} 表示, 3D_Conv3 的通道深度用 $L_{13}-L_{18}$ 表示. 以 $B_{51}^{L_7}$ 和 $C_{13}^{L_{13}}$ 为例, 第二次卷积和第三次卷积的运算公式为:

$$B_{51}^{L_7} = F \left(\sum_{i=5}^7 \sum_{j=1}^3 \sum_{k=1}^6 A_{ijk} W_{ijk}^{L_7} + D_{L_7} \right), \quad (6)$$

$$C_{13}^{L_{13}} = F \left(\sum_{i=1}^3 \sum_{j=3}^5 \sum_{k=1}^6 B_{ijk} W_{ijk}^{L_{13}} + D_{L_{13}} \right). \quad (7)$$

卷积后得到通道数为 6 的 $510 \times 3 \times 3$ 三维矩阵. 将三维矩阵以第一维度展开, 作为 PredRNN++过程的输入, 来进一步提取空间特征.

2.3.2 PredRNN++过程

PredRNN++主要组成部分包括 Casual LSTM(时空记忆单元的级联操作)和 GHU(梯度高速公路单元). 这两种单元能够建立很深的网络进行学习, 自适应地捕捉长期与短期特征. 其内部结构如图 8 所示.

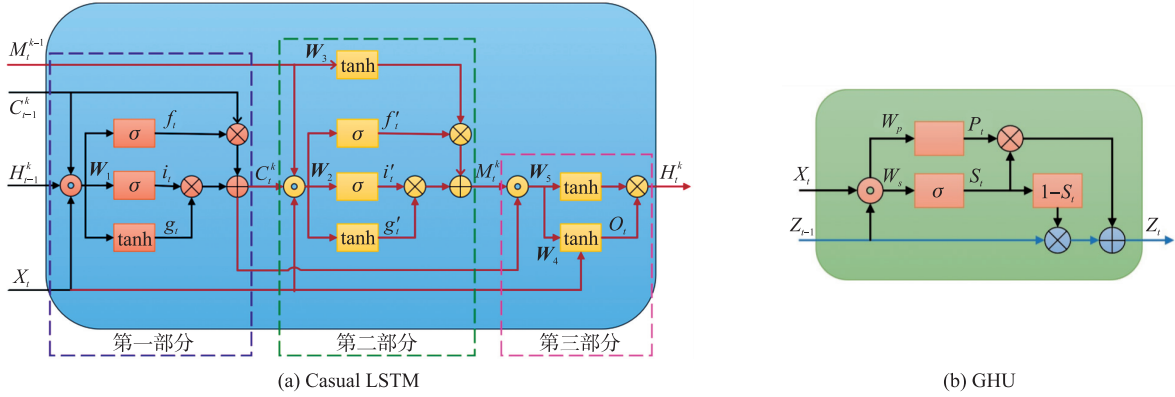


图 8 PredRNN++主要组成部分的内部结构图

Fig. 8 Internal structure diagram of PredRNN++ main components

GHU 直接通过高速公路相传, 不经历漫长的记忆单元传播, 在反向传播时易保留梯度, 避免梯度消失. GHU 的 S_t 命名为 Switch Gate, 可在转换输入 P_t 和隐藏状态 Z_t 之间进行自适应学习. 其计算公式为:

$$\begin{aligned} P_t &= \tanh(W_{px} * X_t + W_{pz} * Z_{t-1}), \\ S_t &= \sigma(W_{sx} * X_t + W_{sz} * Z_{t-1}), \\ Z_t &= S_t \odot P_t + (1 - S_t) \odot Z_{t-1}. \end{aligned} \quad (8)$$

Casual LSTM 可在不增加层的基础上增加非线性操作, 使特征放大并能捕捉到短期动态变化和突发情况, 同时也增加网络从一种状态到另一种状态的深度. 其计算公式为:

$$\begin{aligned} \begin{pmatrix} g_t \\ i_t \\ f_t \end{pmatrix} &= \begin{pmatrix} \tanh \\ \sigma \\ \sigma \end{pmatrix} W_1 * [X_t, H_{t-1}^k, C_{t-1}^k], \\ C_t^k &= f_t \odot C_{t-1}^k + i_t \odot g_t, \\ \begin{pmatrix} g'_t \\ i'_t \\ f'_t \end{pmatrix} &= \begin{pmatrix} \tanh \\ \sigma \\ \sigma \end{pmatrix} W_2 * [X_t, C_t^k, M_{t-1}^{k-1}], \\ M_t^k &= f'_t \odot \tanh(W_3 * M_{t-1}^{k-1}) + i'_t \odot g'_t, \\ o_t &= \tanh(W_4 * [X_t, C_t^k, M_t^k]), \\ H_t^k &= o_t \odot \tanh(W_5 * [C_t^k, M_t^k]), \end{aligned} \quad (9)$$

式中, σ 表示 Sigmoid 函数; \tanh 表示双曲正切函数; X_t 是时间 t 时刻的输入值; H_t^k 为时间 t 时刻第 k 层的

输出值; C_t^k 是时间 t 时刻第 k 层的细胞状态, 也称作时间状态; M_t^k 为时空记忆状态, 与空间维度有关; W 为权重矩阵; \odot 为哈达玛积; g_t 为时间 t 时刻的细胞新状态; i_t 为输入门; f_t 为遗忘门; o_t 为输出门。

从图 8(a) 可知, 每个门是由 X 、 H 和 C 共同决定。每个细胞都是在进行输入门和遗忘门操作之后输出该细胞的细胞状态。Casual LSTM 存在两个记忆结构, 即 C 与 M , 其中 C 与时间维度有关, 属于时间状态, 输入上一个时刻的值; M 是时空记忆状态, 输入上一层的值。第一部分细胞与 LSTM 结构类似。 M 通过遗忘门之前进行 \tanh 非线性操作, 作为第二部分的细胞输入。输出门采用 \tanh 激活, 输入为前两个级联细胞的输出 C_t^k 、 M_t^k 以及 X_t 。最终输出的 H 取决于两个细胞的时间状态和空间状态。PredRNN++ 架构如图 9 所示。

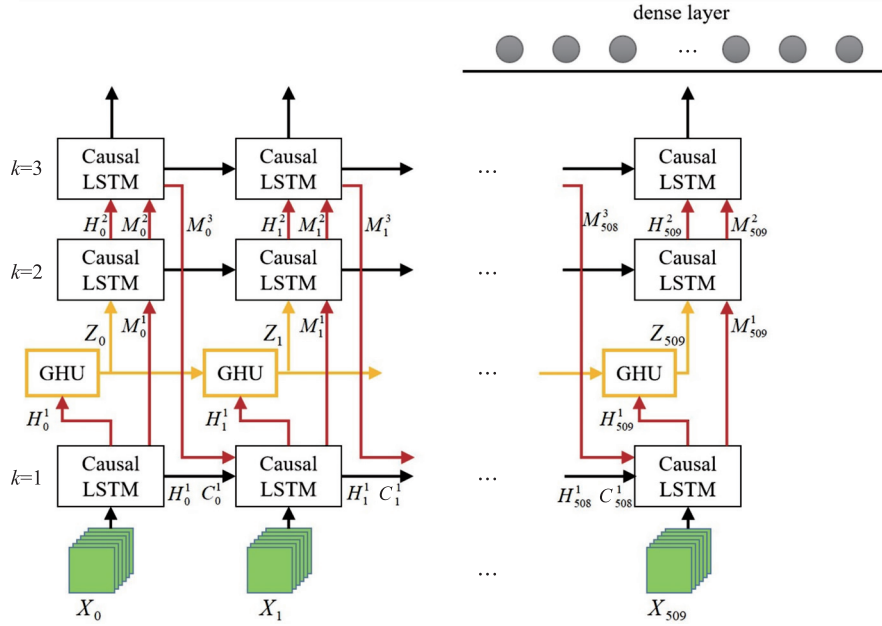


图 9 基于 PredRNN++ 的多维矩阵处理过程

Fig. 9 Multidimensional matrix processing based on PredRNN++

PredRNN++ 计算公式为:

$$\begin{aligned} H_t^1, C_t^1, M_t^1 &= \text{CausalLSTM}_1(X_t, H_{t-1}^1, C_{t-1}^1, M_{t-1}^1), \\ Z_t &= \text{GHU}(H_t^1, Z_{t-1}), \\ H_t^2, C_t^2, M_t^2 &= \text{CausalLSTM}_2(Z_t, H_{t-1}^2, C_{t-1}^2, M_{t-1}^2), \\ H_t^k, C_t^k, M_t^k &= \text{CausalLSTM}_k(H_{t-1}^{k-1}, H_{t-1}^k, C_{t-1}^k, M_{t-1}^{k-1}). \end{aligned} \quad (10)$$

3 仿真实验

从中央空调系统中获取 2019 年 1 月 1 日零时至 2021 年 6 月 1 日零点生产车间空调机组产生的数据集。生产车间共有 9 台空调机组, 共同维持生产环境的稳定。蒸汽消耗量采集间隔为 1 min, 每天共产生 1 440 条数据, 每个生产班次平均为 8.5 h。模型输入需统一平滑过程模式、趋势性模式和周期性模式的数据量, 若预测目标为周一早班中 7:00—07:30 蒸汽瞬时消耗量, 平滑过程模式的输入是前 8.5 h 的蒸汽消耗量, 趋势性模式的输入是前 17 天早班中 07:00—07:30 的蒸汽瞬时消耗量, 周期性模式的输入是前 17 个周一早班中 07:00—07:30 的蒸汽瞬时消耗量。因此从 2019 年 1 月 1 日开始划分数据集, 以 18 周为一个单位, 训练集选自前 17 周数据, 验证集选自第 18 周数据, 以此得到空调蒸汽预测模型。

3.1 数据预处理与评价指标

在数据采集过程中, 传感器故障会导致某些数据存储失败, 造成单值缺失和连读多值缺失的情况。单值缺失采用上下平均值填补法对其进行处理; 多值缺失中缺失特征较少, 故采用样条插值法进行处理。

模型从预测精度和能源损耗两方面进行综合评价。模型预测精度的评价指标选用均方根误差 (root-mean-square error, RMSE)、平均绝对误差 (mean absolute error, MAE)、平均绝对百分比误差 (mean absolute percentage error, MAPE), 计算公式为:

$$\begin{aligned} \text{RMSE} &= \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \\ \text{MAE} &= \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \\ \text{MAPE} &= \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\%, \end{aligned} \tag{11}$$

式中, y_i 为实际空调蒸汽消耗量; \hat{y}_i 为预测空调蒸汽消耗量; n 为时间切片总量; i 为某一时间片.

车间生产的能源损耗^[14-15]主要由用电量、蒸汽消耗、冷量构成,其中耗电量=冷量/COP. COP (coefficient of performance) 为空调的性能系数. 电力折标煤系数为 0.123,蒸汽折标煤系数为 0.094,平均能耗折标 (average standard energy consumption, ASEC) 计算公式为:

$$\text{ASEC} = \frac{0.123 \times (Q_1 + Q_2) + 0.094 \times S}{H}, \tag{12}$$

式中,ASEC 为平均折损能耗,其单位为千克标准煤 (kgce); Q_1 为用电量; Q_2 为冷量的耗电量; S 为蒸汽用量; H 为空调运行时长.

3.2 实验环境与模型参数

本文实验的运行环境为 python3.8.3 和 Matlab,使用 python 库 keras、scikit-learn、tensorflow 来搭建本文模型和部分对比模型. 使用 Matlab 设计工具 APP 构建部分机器学习对比模型. 在空间因素特征提取中,经过三维卷积操作之后,进入 PredRNN++ 部分,其中 Casual LSTM 与 GHU 中设置 stride = 1、padding = same,选取 16/32/128/256 调整 batch size,最终确定 batch size = 32 时有最小损失. 在时间因素特征提取和外部因素提取中,GRU 神经元个数选取 64/128/256/512 进行调整,最终确定神经元数分别为 512 和 256. 3 种因素由全连接层处理后输出的神经元个数为 16. 最后根据参数矩阵进行特征融合输出预测结果.

3.3 模型对比与结果分析

本文选用 SVM、RNN+GRU、LightGBM、多元线性回归 4 种对比模型. 文献[7]中的 SVM 模型^[16-17]目前在制造企业中应用广泛,以此对比预测性能的提升;选用 RNN+GRU^[18-20]组合模型用以验证提取空间特征的必要性;选取文献[5]中的机器学习模型^[21-25]用以验证本文模型更符合实际需求. 所有模型的预测结果如图 10 所示,误差结果如表 2 所示.




图 10 模型预测结果

Fig. 10 Model prediction results

表 2 模型误差结果

Table 2 The error results of the model

预测模型评价指标	RMSE/kg	MAE/kg	MAPE/%	运行时间/s
本文模型	107.3	80.1	6.4	35
RNN+GRU	116.7	85.0	6.9	30
SVM(现用模型)	290.3	201.5	14.7	50
LightGBM	426.7	345.1	37.3	28
多元线性回归	593.1	498.8	52.5	50

由图 10 和表 2 可知,SVM 模型的预测曲线中存在间隔性“锯齿”,在该时刻的预测结果与实际结果差距很大,存在不稳定性. 相较于 SVM 模型,本文模型 RMSE 值降低了 63.04%、MAE 值降低了 60.25%、MAPE 值降低了 56.46%,运行时间也有所缩短,说明本文模型的预测精度、效率和稳定性都优于 SVM 模型. 相较于 RNN+GRU 模型,本文模型虽运行时间略增,但 RMSE 值降低了 8.05%、MAE 值降低了 5.76%、MAPE 值降低了 7.25%,证明空间特征对模型的影响程度是不可忽略的. LightGBM 模型虽运行时间有所减少,但其误差值远远高于本文模型. 多元线性回归模型预测精度和运行效率都不及本文模型. 综上,本文的混合深度学习模型更贴合实际,可实现在复杂环境中对空调蒸汽的准确实时预测.

将本文模型应用于空调管控系统中,以此减少空调的运行时间和电量损耗,并减少不必要的蒸汽消耗. 现用模型(SVM 模型)ASEC 值为 534.48 kgce,本文模型 ASEC 值为 213.33 kgce,本文模型相较于现用模型 ASEC 降低了 60.09%.

4 结论

为解决企业生产车间多空调能耗与生产任务匹配、气候环境匹配的精准供能问题,实现多台大型空调机组的蒸汽预测,提出了一种基于 GRU 和 3DConv-PredRNN++的混合深度学习预测模型. 首先通过分析空调机理得出蒸汽消耗量与机组的 8 种工作方式相关,而机组的工作方式受到时间因素、空间因素和外部因素影响,因此需要提取 3 部分特征来构建预测模型. 为进一步提升模型的预测精度,将时间特征因素和空间特征因素以 3 种不同模式进行输入,以此获取蒸汽消耗量序列的总体趋势和局部变化. 时间因素特征通过 GRU 提取,空间因素特征利用三维卷积和 PredRNN++提取,通过 GRU 提取时间序列外部因素特征,再结合其余特征输入全连接层,最后通过参数矩阵融合构建蒸汽消耗模型. 本文模型的 RMSE 值为 107.3 kg,MAE 值为 80.1 kg,MAPE 值为 6.4%. 与多种模型对比,验证了本文模型预测精度的优越性,证明了进行空间特征提取参与模型预测的必要性. 与现用 SVM 模型相比,本文模型的 ASEC 降低了 60.09%.

随着企业生产链的不断运转,中央空调系统会继续产生大量数据,需要不断补充数据集对模型进行校正,进一步提升模型的预测精度. 后续将进一步对中央空调开机台数进行预测,并制定策略控制每台空调的开启,减少能源浪费,实现企业节能降耗的目标.

[参考文献] (References)

- [1] CHOWDHURY H, CHOWDHURY T, HOSSAIN N, et al. Exergetic sustainability analysis of industrial furnace: a case study[J]. Environmental Science and Pollution Research, 2021, 28: 12881–12888.
- [2] 杨裔. 中央空调节能技术综述[J]. 现代信息科技, 2019(13): 193–194.
- [3] CHEN X, SHUAI C Y, WU Y, et al. Understanding the sustainable consumption of energy resources in global industrial sector: Evidences from 114 countries[J]. Environmental Impact Assessment Review, 2021, 90: 106609.
- [4] 刘亚东. 造纸厂蒸汽消耗需求预测研究及预测系统开发[D]. 广州: 华南理工大学, 2013.
- [5] 刘文华. 基于机器学习的火力发电蒸汽量预测方法研究[D]. 太原: 太原科技大学, 2019.
- [6] MOGHADASI M, OZGOLI H A, FARHANI F. Steam consumption prediction of a gas sweetening process with methyldiethanolamine solvent using machine learning approaches[J]. International Journal of Energy Research, 2021, 45(1): 879–893.
- [7] 王梦柯. 大型制造企业蒸汽智能供应策略优化的研究与应用[D]. 杭州: 浙江理工大学, 2020.
- [8] 彭桐歆, 韩勇, 王程, 等. 面向短时地铁客流量预测的混合深度学习模型[J]. 计算机工程, 2022, 48(5): 297–305.
- [9] ZHANG J B, ZHENG Y, QI D K. Deep Spatio-temporal residual networks for citywide crowd flows prediction[C]//AAAI'17: Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence. San Francisco, USA: AAAI Press, 2016: 1655–1661.
- [10] CHO K, MERRIENBOER B V, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). Doha, Qatar: ACL, 2014.
- [11] 查玉坤, 张其林, 赵永标, 等. 基于三维卷积和 CLSTM 神经网络的水产养殖溶解氧预测[J]. 应用科学学报, 2021, 39(4): 615–626.
- [12] DIBA A, FAYYAZ M, SHARMA V, et al. Temporal 3D ConvNets: new architecture and transfer learning for Video classifica-

- tion[J/OL]. arXiv preprint arXiv:1711.08200,2017.
- [13] WANG Y B,GAO Z F, LONG M S, et al. PredRNN++:towards a resolution of the deep-in-time dilemma in spatiotemporal predictive learning[J/OL]. arXiv preprint arXiv:1804.06300,2018.
- [14] 国家市场监督管理总局,国家标准化管理委员会. 综合能耗计算通则:GB/T 2589-2020[S]. 北京:中国标准出版社,2020.
- [15] 简毅文,江亿. 住宅供暖空调能耗计算模式的研究[J]. 暖通空调,2005,35(2):11-14.
- [16] JALAL M,JALAL H. Retracted;behavior assessment,regression analysis and support vector machine(SVM) modeling of waste tire rubberized concrete[J]. Journal of Cleaner Production,2020,273:122960.
- [17] XU L,HOU L,ZHU Z Y, et al. Midterm prediction of electrical energy consumption for crude oil pipelines using a hybrid algorithm of support vector machine and genetic algorithm[J]. Energy,2021,222(1):119955.
- [18] EAPEN J,VERMA A,BEIN D. Improved big data stock index prediction using deep learning with CNN and GRU[J]. International Journal of Big Data Intelligence,2021,7(4):202-210.
- [19] 陈聪,候磊,李乐乐,等. 基于 GRU 改进 RNN 神经网络的飞机燃油流量预测[J]. 科学技术与工程,2021,21(27):11663-11673.
- [20] 党建武,从筱卿. 基于 CNN 和 GRU 的混合股指预测模型研究[J]. 计算机工程与应用,2021,57(16):167-174.
- [21] LIU L J,WANG L,YU Z. Remaining useful life estimation of aircraft engines based on deep convolution neural network and LightGBM combination model[J]. International Journal of Computational Intelligence Systems,2021,14:165.
- [22] MUSLIM M A,DASRIL Y,ALAMSYAH A, et al. Bank predictions for prospective long-term deposit investors using machine learning LightGBM and SMOTE[J]. Journal of Physics:Conference Series,2021,1918(4):042143.
- [23] WEI J,LI Z Q,PINKER R T, et al. Himawari-8-derived diurnal variations in ground-level PM_{2.5} pollution across China using the fast space-time Light Gradient Boosting Machine(LightGBM)[J]. Atmospheric Chemistry and Physics,2021,21(10):7863-7880.
- [24] FARID M. Data-driven method for real-time prediction and uncertainty quantification of fatigue failure under stochastic loading using artificial neural networks and Gaussian process regression[J]. International Journal of Fatigue,2022,155:106415.
- [25] REN C H,YANG Y X,DONG X, et al. Prediction of the maximum temperature of sulfur-containing oil using gaussian process regression for hazards prevention[J]. International Journal of Performability Engineering,2018,14(12):2951-2959.

[责任编辑:严海琳]

(上接第 29 页)

- [8] 丁晓亮,沈辉,曲鹏超. 增强型双中间电容压电能量回收电路的优化设计[J]. 青岛大学学报(自然科学版),2021,34(1):54-58.
- [9] FANG S,XIA H,XIA Y, et al. An efficient piezoelectric energy harvesting circuit with series-SSHI rectifier and FNOV-MPPT control technique[J]. IEEE Transactions on Industrial Electronics,2020,68(8):7146-7155.
- [10] 汪若尘,焦宇,钱金刚,等. 混合悬架半主动控制器设计与试验[J]. 农业机械学报,2017,48(6):334-340.
- [11] ZHANG X,MI C. Vehicle power management:modeling,control and optimization[M]. London:Springer Science & Business Media,2011.
- [12] BAGLIONE M,DUTY M,PANNONE G. Vehicle system energy analysis methodology and tool for determining vehicle subsystem energy supply and demand[R/OL]. SAE Technical Paper,2007. [2022-07-01]. <http://doi.org/10.4271/2007-01-0398>.
- [13] SEGEL L,LU X. Vehicular resistance to motion as influenced by road roughness and highway alignment[J]. Australian road Research,1982,12(4):211-222.
- [14] SMITH M C,SWIFT S J. Power dissipation in automotive suspensions[J]. Vehicle System Dynamics,2011,49(1):59-74.

[责任编辑:陈 庆]