

文章编号: 1671-6612 (2022) 06-870-06

基于改进长短期记忆网络的空调负荷预测方法

孙春艳

(中煤科工集团北京华宇工程有限公司平顶山分公司 平顶山 467000)

【摘要】 空调在长期使用过程中, 负荷值会随时间量的增加不断提升, 在此过程中, 受到时间变量与负荷噪声的影响, 生成长短期特征不同的波动, 在波动作用下负荷特征个体对应的预测网络细胞预测精准度会有所降低, 进而增大空调负荷预测记忆网络的预测误差。导致预测方法输出预测量误差同步增大。为了解决误差问题, 提升预测值准确度, 利用对长短期记忆网络加以改进, 并将改进后的长短期记忆网络应用于空调负荷的预测计算, 通过对空调负荷的加权灰色关联计算、基于改进后长短期记忆网络预测量确定与空调负荷预测结果输出, 完成对空调负荷预测精度优化的计算过程。通过与两种预测模型的数据对比表明: 提出预测方法在负荷预测值准确度提升方面具有确切效果, 且稳定性较好, 达到了提出方法的预期效果。

【关键词】 长短期记忆网络; 空调; 负荷; 预测方法

中图分类号 TP391 文献标识码 A

Air-conditioning Load Forecasting Method Based on Improved Long and Short-term Memory Network Sun Chunyan

(Pingdingshan Branch of China Coal Science and Industry Group Beijing Huayu Engineering Co., Ltd, Pingdingshan, 467000)

【Abstract】 Air conditioning in the process of long-term use, load value will increase with the increase of time, in the process, under the influence of time variables and load noise, generate long and short-term characteristics of different fluctuations, under the action of fluctuation load characteristics of individual prediction network cell prediction accuracy will be reduced, and increase the air conditioning load prediction memory network prediction error. Increase of the output premeasurement error of the prediction method synchronously. In order to solve the error problem, improve the prediction accuracy, use the short-term memory network to improve, and apply the improved long-short-term memory network to the prediction of air conditioning load, based on the improved short-term memory network prediction and air conditioning load prediction output, complete the calculation process of air conditioning load prediction accuracy optimization. By comparing with the data of the two prediction models, it is shown that the proposed prediction method has an accurate effect in improving the accurate load prediction value, and has a good stability, which achieves the expected effect of the proposed method.

【Keywords】 long and short-term memory network; air conditioning; load; forecast method

0 引言

准确地获得分析空调运行负荷数据, 能够为空调后期维护、电力资源分配以及运行参量控制提供有力依据。因此在需要利用负荷预测方法, 对其空调运行过程中, 负荷相关参量进行非线性向量分析^[1,2], 对输出参量变化趋势加以预测, 获得下一

时间点的负荷数值。现有研究成果中, 文献[3]提出一种基于长短期记忆神经网络的短期负荷预测模型。选取并量化电力负荷变化影响因素; 采用皮尔逊相关系数分析相关性较强的主要影响因素; 利用主成分分析法进行特征降维, 简化长短期记忆网络模型的输入, 分析输入数据的时间序列, 构建预测

相空间，通过模型训练实现短期电力负荷预测。该方法使用的长短期记忆网络受到网络结构能量负荷个体误差偏大的影响，预测精准度不高；文献[4]方法基于日周期性特点设计了 ARMA 模型和 SVR 模型相结合的预测方法。分析原始能耗数据的日周期性特点，利用 ARMA 模型进行线性预测；利用 SVR 模型进行非线性部分的预测，修正 ARMA 模型的预测结果。该方法整体预测量的加权系数偏大，导致输出的预测结果与实际负荷系数相比误差较大，可参考价值不高。

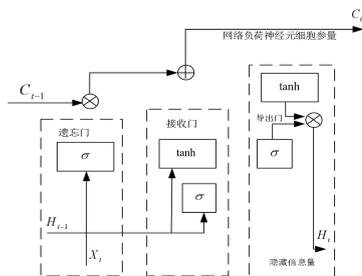
为了解决上述成果的不足，本文提出基于改进长短期记忆网络的空调负荷预测方法。创新性地对长短期记忆网络加以改进，结合空调负荷周期变化特征，优化了长短期记忆网络隐藏层的分布结构，并将改进后的长短期记忆网络应用于实际预测当中，解决误差偏大问题。

1 基于改进长短期记忆网络的空调负荷预测方法实现

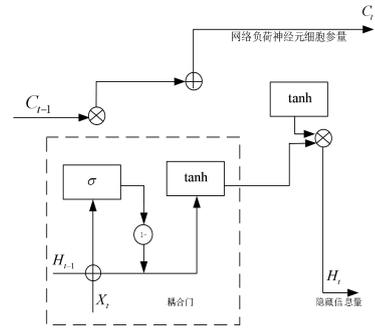
1.1 空调负荷的长短期记忆网络改进

长短期记忆网络是一种具有时间周期记忆的特殊属性的神经网络。通过长短期记忆网络可以对不同时间周期范围内的数据特征进行学习训练，进而实现不同时间周期下的不同参量数据的分析处理。提出方法中引入长短期记忆网络，同时结合空调负荷周期变化特征，对其进行相应改进，改进前后的长短期记忆网络结构图如图 1 所示。

图 1 (a) 所示为改进前的长短期记忆网络结构，其结构分为三部分，其中隐藏层中包含接收门、导出门与遗忘门，一般情况下，改进前的长短期记忆网络隐藏层会对导入信息特征进行数据比对^[5,6]，通过根据比对结果选择训练样本特征是学习还是遗忘，以此实现网络学习功能，同时能够避免训练特征梯度消失导致的传播爆炸问题，其传播属性可以通过正向传播函数进行描述^[7,8]。



(a) 优化前长短期记忆网络结构



(b) 优化后长短期记忆网络结构

图 1 改进前后的长短期记忆网络结构

Fig.1 Long-term and short-term memory network structure before and after improvement

$$H_t = o_t \tanh(C_t) \tag{1}$$

其中，

$$\begin{aligned} i_t &= \sigma(W_i \cdot [H_{t-1}, X_t] + b_i) \\ f_t &= \sigma(W_f \cdot [H_{t-1}, X_t] + b_f) \\ C_t &= f_t \cdot C_{t-1} + i_t \tanh \sigma(W_c \cdot [H_{t-1}, X_t] + b_c) \\ o_t &= \sigma(W_o \cdot [H_{t-1}, X_t] + b_o) \end{aligned} \tag{2}$$

式中： i_t 、 f_t 、 o_t 分别对应 t 时间点下长短期记忆网络的接收门、遗忘门与导出门的即时参量； X_t 、 C_t 、 H_t 代表 t 时间点下长短期记忆网络的导入空间符合参量、网络负荷神经元细胞参量与导出系数； C_{t-1} 、 H_{t-1} 代表 $t-1$ 时间点下网络负荷神经元细胞状态与导出参量； W_i 、 W_f 、 W_c 、 W_o 代表负荷记忆网络长短记忆的加权矩阵； b_i 、 b_f 、 b_c 、 b_o 代表网络信息量的即时偏差系数； \tanh 代表触发阈值函数； \cdot 代表哈达玛积运算^[9]。

与上述传统长短期记忆网络不同，改进的长短期记忆网络主要对隐藏层分布结构进行了三方面优化，具体如下：

(1) 将记忆网络前一时间点导入的负荷记忆量 H_{t-1} 与即时导入的空调负荷信息量 X_t 进行记忆卷积^[10,11]，经过卷积计算后的空调负荷记忆细胞与即时导入的符合信息时序进行特征系数的关联。

(2) 根据历史经验可知，导出速率对输出参量误差有着影响作用，因此在优化处理上，将前一时间点对应符合记忆细胞状态系数 C_{t-1} 加入原有导入信息量中，充分激发训练细胞中历史记忆细胞

对其特征信息的遗忘选择, 加强记忆网络对个体数据特征细胞的挖掘能力。

(3) 利用耦合门替换原有接收门、遗忘门、导出门的记忆训练模式, 提升隐藏层固有变量的训练速度, 快速输出负荷特征模型。

具体改进方法的对应函数如下:

t 时间点下改进的长短期记忆网络接收门参量 i_t 更新为:

$$i_t = \sigma(W_x * X_t + W_h * H_{t-1} + W_c * C_{t-1} + b_i) \quad (3)$$

式中: * 代表记忆卷积函数。

t 时间点下负荷记忆细胞参量 C_t 更新:

$$C_t = i_t \cdot C_{t-1} + (1 - i_t) \cdot (W_x * X_t + W_h * H_{t-1} + W_c * C_{t-1} + b_c) \quad (4)$$

t 时间点下接收门即时信息 o_t 更新:

$$o_t = \sigma(W_x * X_t + W_h * H_{t-1} + W_c * C_{t-1} + b_o) \quad (5)$$

t 时间点下关于空调负荷的改进长短期记忆网络模型输出函数为:

$$H_t = o_t \cdot \tanh(C_t) \quad (6)$$

1.2 空调负荷的加权灰色关联计算

在优化的记忆网络输出模型中, 由于存在不同负荷扰动因素, 因此在负荷预测计算结果上无法做到系数的量的统一, 将具备影响能力的扰动因素系数称之为灰色系数。为了避免灰色系统对预测结果的影响, 利用加权关联的办法, 将记忆细胞特征以负荷模型中每一个特征权值进行关联, 增强样本个体的预测能力, 提出预测特征能力弱的灰色细胞权值量, 进而完成对空调负荷的加权灰色关联, 提升预测能力。具体步骤如下:

(1) 初始化全局记忆网络数据, 利用归一计算消除量纲扰动。

(2) 将模型输出的空调负荷长短期记忆样本定义为初始样本, 记作序列 X_0 , 在初始样本序列中, 前 n 个原始负荷信息样本 X 定义为从属序列, x_{ij} 代表第 i 个原始样本中的第 j 个负荷细胞信息量, m 代表对应样本负荷细胞量的总数。 X_0 、 X 对应灰度参量的分布结构, 可以通过序列关系分别描述为^[12]:

$$X_0 = [x_{01}, x_{02}, \dots, x_{0m}] \quad (7)$$

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{nm} \end{bmatrix} \quad (8)$$

(3) 计算初始样本序列与从属序列之间的灰色关联值 ξ_{ik} 后, 将计算值与记忆网络相结合, 获得灰色关联矩阵 ξ , 其函数关系表达如下:

$$\xi_{ik} = \frac{\min_i |x_{0k} - x_{ik}| + \rho \max_i |x_{0k} - x_{ik}|}{|x_{0k} - x_{ik}| + \rho \max_i |x_{0k} - x_{ik}|} \quad (9)$$

式中: ξ_{ik} 代表第 i 个样本的第 k 个扰动因素对应的灰色系数值; ρ 代表灰色细胞的关联指数, 对计算结果具有决定性作用, 根据历史经验一般情况下将其对应值设定为 0.3。

$$\xi = \begin{bmatrix} \xi_{11} & \xi_{12} & \dots & \xi_{1m} \\ \vdots & \vdots & \ddots & \vdots \\ \xi_{n1} & \xi_{n2} & \dots & \xi_{nm} \end{bmatrix} \quad (10)$$

式中: ξ 代表从属序列与初始序列之间的灰色关联矩阵。

(4) 对关联系数进行权重计算, 并将计算所得加权值整理为加权向量, 其计算过程分别对应如下公式:

$$r_{ij} = \frac{x_{ij}}{\sum_{i=1}^n x_{ij}} \quad (11)$$

$$E_j = -\frac{1}{\ln m} \sum_{j=1}^m r_{ij} \ln r_{ij} \quad (12)$$

$$\gamma_j = \frac{1 - E_j}{\sum_{j=1}^m (1 - E_j)} \quad (13)$$

$$\gamma = [\gamma_1, \gamma_2, \dots, \gamma_m] \quad (14)$$

式中: r_{ij} 代表第 i 个样本中的第 j 个负荷细胞记忆特征的灰色权重值; E_j 代表第 j 个负荷细胞记忆特征的信息熵; γ_j 代表第 j 个负荷细胞记忆特征的加权系数; γ 代表输出关联量的记忆状态。

1.3 基于改进后长短期记忆网络预测量确定

基于上述计算参量, 对其展开长短期记忆网络下的预测量计算, 通过计算确定空调负荷预测量, 具体计算如下:

利用均值计算方法, 对加权向量进行加权均值计算, 得到^[13]:

$$\hat{P}^t = \frac{P^t_{LSTM} + P^t_{RAM}}{2} \quad (15)$$

式中： \hat{P}^t 代表长短期记忆网络预测模型在组 t 时间点下的预测量； P^t_{LSTM} 代表改进后的长短期记忆网络预测模型在组 t 时间点下的预测量； P^t_{RAM} 代表负荷信息条件处于极限参量下通过 MEQ 获得的 t 时间点下空调负荷预测量。考虑到加权均值计算可以精简计算流程，但是无法实现对预测条件参量的优化，因此为了进一步提升预测量精度，引入时变自适应参量对其继续优化。

时变自适应参量的函数关系式如式(16)所示，其中采用待预测负荷信息点前 k 个负荷节点个体修正系数的计算公式为^[14]：

$$\hat{P}^t = C_1^t P^t_{LSTM} + C_2^t P^t_{RAM} + C^t \quad (16)$$

式中： C_1^t 代表改进后的长短期记忆网络在 t 时间点下的预测量加权组合系数； C_2^t 代表负荷信息条件处于极限参量下 t 时间点所对应的预测量加权组合系数； C^t 代表预测量优化系数，主要作用于补偿固有系数带来的预测误差，进一步提升预测量加权组合系数的精准度。

$$C_i^t = \frac{\left(\sum_{i=1}^k e_{i,t}^2 \right)^{-1}}{\sum_{j=1}^2 \left(\sum_{i=1}^k e_{i,t}^2 \right)^{-1}} \quad (17)$$

$$C^t = \frac{\sum_{i=1}^k (P^t - C_1^t P^t_{LSTM} - C_2^t P^t_{RAM})}{k} \quad (18)$$

式中： $e_{i,t}$ 代表第 i 个负荷预测个体在 t 时间点下的预测量与空调负荷实际值之间的差值； P_t 代表 t 时间点下空调负荷的实际值。为了避免预测量与实际值之间误差过大，将前 k 个原始负荷个体与实际值之间的差值作为补偿系数，融合到预测值当中，达到预测值的平衡修正，获得高精度预测量。

1.4 空调负荷预测结果输出

完成预测量精度优化计算后，对其进行输出操作，为了防止输出融合器对输出量扰动，利用损失函数对其输出预测量进行误差控制，损失函数以优化器 Adam Optimizer 的形式引入^[15]，其计算结构如图 2 所示。具体控制输出过程如下所示：

步骤 1 将带输出预测量进行初始化整理，其中控制量优化阈值精度设定为 0.001；

步骤 2 将待输出预测结果总量阈值设定为 7700，并按照优化规模划分成大小为 385 的 batch；

步骤 3 抽取一个 batch 载入优化器 Adam Optimizer 进行差量输出补偿；

步骤 4 通过改进的长短期记忆网络对预测量 batch 系数值的特征提取，获得 Adam Optimizer 优化器权值误差补偿值，通过与网络导出层的连接，生成输出预测结果补偿分类器 softmax，并输出补偿后的预测结果。

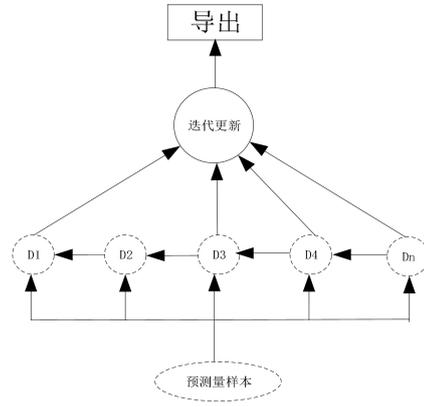


图 2 Adam Optimizer 优化器计算结构

Fig.2 Calculation structure of Adam optimizer

2 仿真测试

对提出的预测方法进行仿真数据对比测试，目的在于验证提出预测方法的有效性。测试在仿真场景下完成。仿真数据来源于某空调房的中央空调系统七月份连续七天的逐时负荷数据。该中央空调系统由三台型号为 19XL5151455CQ 型离心式冷水机组组成，系统的设备参数如表 1 所示。

表 1 中央空调系统设备参数

Table 1 Equipment parameters of central air-conditioning system

名称	参数
制冷量/kW	2074
输入功率/kW	500
冷凝器流量/(m ³ /h)	411
冷凝器进/出水温度/°C	32/37
冷凝器压头损失/kPa	31
制冷剂	R22

为了更好地展现测试结果，测试过程中引入两种预测模型作为对比，分别为文献[3]方法与文献[4]方法，与提出预测方法一同进行实验测试。通过对比相同环境下空调负荷预测值精准度，获得提出方法有效性结论。

2.1 空调负荷参量获取测试

按照上述设定的实验条件,在仿真测试环境下分别通过文献[3]方法、文献[4]方法与预测方法对测试空调运行负荷数据进行数据采集,获得数据如图 3 所示。

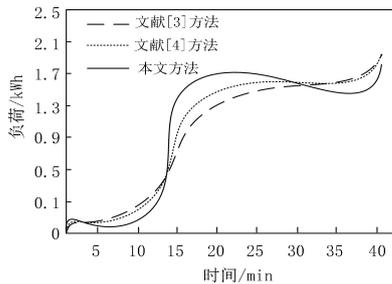


图 3 空调运行负荷数据获取测试结果

Fig.3 Air conditioning operating load data obtain test results

由图 3 负荷曲线可知,文献[3]方法获得负荷数据波动较为平缓,负荷值上升幅值与下降幅值之间的差量很小,说明该方法在数据获取上具有较好的精度控制能力,但是其获取精度上可控范围较小,文献[4]方法获得负荷数据波动相较文献[3]方法数值有所增大,但整体模型基本与文献[3]方法曲线保持一致,说明文献[4]方法在数据导入层精度上有所提升,且整体控制性不变。本文提出的预测方法获取的空调运行负荷数据整体波动较大,但在大波动数据获取控制上具有较好的控制性,曲线起伏过程中没有抖动,说明数据具有连续性,且没有受到第三方因素的干扰。

2.2 预测精准度测试

将上述 3 组获取数据导入 Attention 机制的测试工具中进行数据泛化处理,处理后的数据结果 L_i 与测试空调运行负荷实际值 M_i 进行对比,计算预测精准度:

$$P = \frac{L_i - M_i}{\sum_{i=1}^n (L_i - M_i)} \times 100\% \quad (19)$$

通过以上计算公式得到时间分别为 5min、10min、15min、20min、25min、30min、35min、40min 的预测精准度结果,具体数据如表 2 所示。

表 2 空调负荷预测结果精准度对比

Table 2 Comparison of accuracy of air conditioning load forecasting results

测试空调实际运行负荷 /kWh	预测结果精准度%		
	文献[3]方法	文献[4]方法	提出预测方法
0.04	87.62	86.53	97.62
0.05	88.64	86.42	95.26
1.27	86.23	85.78	95.68
1.68	86.12	87.62	96.87
1.65	85.47	85.42	97.62
1.5	85.62	86.32	97.26
1.37	86.01	85.42	97.62
1.31	86.24	84.33	98.24

由表 2 中的数据对比可以看出,参测的三种预测方法。提出的预测方法与测试空调实际运行负荷数据最为接近,且数值波动相较文献[3]方法与文献[4]方法差量几乎保持一致,在此基础上整体准确率数值提升明显,说明提出的预测方法在长短期记忆网络构建中,负荷个体特征量对应系数较高且与实际值误差在可控范围内,比历史预测方法误差控制范围小。基于以上几点,足以证明提出方法的有效性。

3 结束语

通过对现有预测方法存在问题的分析,结合空调负荷预测网络结构特点,针对性的对长短期记忆网络进行了改进,并将改进后的长短期记忆网络应用于空调负荷预测的计算当中,实验数据表明,此方法取得的预测结果达到了预期效果,预测精准度提升明显且稳定。设计方法的提出,为空调负荷预测研究与长短期记忆网络的融合应用,提供了有力的数据支持。但是,不能否认提出的预测方法仍然存在不足,通过对负荷变化曲线的分析,发现,当负荷波动较为频繁且剧烈时,个体特征细胞的收敛性随之变弱,预测精度会有所降低,虽然差值在可控范围内,但仍然需要在后期不断修正网络耦合门个体特征量,不断优化个体细胞记忆学习能力,使预测效果达到最佳。

参考文献:

[1] 杨胜维,吴利瑞,刘东.基于随机森林的航站楼负荷预测

- 及特征分析[J].建筑热能通风空调,2021,40(12):1-6.
- [2] 顾春锋,罗其华,奚培锋,等.基于 PCA-LSTM 神经网络的建筑空调负荷预测方法研究[J].现代建筑电气,2021,12(10):1-7.
- [3] 邓惟绩,肖辉,李金泽,等.基于改进长短期记忆网络和高斯过程回归的光伏功率预测方法[J].电器与能效管理技术,2021,(8):51-57.
- [4] 易礼秋,谷云东.基于长短期记忆神经网络的短期电力负荷预测[J].中州大学学报,2021,38(4):109-116.
- [5] 甘中学,喻想想,许裕粟,等.基于周期性 ARMA-SVR 模型的空调冷热负荷预测[J].控制工程,2020,27(2):6.
- [6] 李建华,周亚明,陈建业.基于用地规划的远景空调空间负荷预测方法研究[J].电力设备管理,2021,(4):165-167.
- [7] 王雅,黄芙蓉,江熙,等.计及楼宇综合能源规划系统中负荷预测方法研究[J].仪器仪表用户,2021,28(2):1-5,81.
- [8] 田剑刚,张沛,彭春华,等.基于分时长短期记忆神经网络的光伏发电超短期功率预测[J].现代电力,2020,37(6):629-638.
- [9] 吴嘉华,王怀远.结合长短期记忆网络的电力系统功率缺额预测方法[J].福州大学学报(自然科学版),2020,48(6):727-732.
- [10] 卫炳坤,王庆锋,刘家赫,等.基于动态长短期记忆网络的设备性能退化预测方法[J].北京化工大学学报(自然科学版),2020,47(6):92-99.
- [11] 刘永强,续毅,贺永辉,等.基于双向长短期记忆神经网络的风电预测方法[J].天津理工大学学报,2020,36(5):49-54,59.
- [12] 袁福帅,崔崇立,朱臣,等.基于加权灰色关联度分析与集对分析组合推理模型的航材消耗预测[J].信息工程大学学报,2021,22(4):6.
- [13] 张倩昀,陈华友,江立辉.加权算术平均组合预测方法均方误差的分解[J].合肥学院学报:综合版,2020,37(2):7.
- [14] 魏惠芳,王丽梅.永磁直线同步电机自适应模糊神经网络时变滑模控制[J].电工技术学报,2022,37(4):9.
- [15] 刘俐,李勇,曹一家,等.基于支持向量机和长短期记忆网络的暂态功角稳定预测方法[J].电力自动化设备,2020,40(2):129-139.

(上接第 827 页)

- [4] 中国制冷学会数据中心冷却工作组.中国数据中心冷却技术年度发展研究报告 2019[R].北京:中国建筑工业出版社,2020.
- [5] 李婷婷.干燥地区热通道封闭式数据中心气流组织优化模拟研究[D].西安:西安工程大学,2019.
- [6] 彭殿贞.绿色数据中心空调设计[M].北京:中国建筑工业出版社,2015.
- [7] 顿喆,秦赞,关欣.基于 Fluentairpak 的数据中心机房的气流组织模拟优化[J].建筑节能,2015,43(3):27-33.
- [8] 闻发凡,涂淑平,李林星,等.数据中心露点间接蒸发冷却气流组织模拟分析[J].能源研究与利用,2016(4):43-45,48.
- [9] 杨超,黄赟,丁聪.采用 CFD 仿真优化数据中心气流组织[J].电信工程技术与标准化,2018,31(9):89-92.
- [10] 肖新文,魏赠,曾春利.间接蒸发冷却空调箱机组制冷的数据中心气流组织探讨[J].制冷与空调,2020,34(1):62-69.
- [11] 董曾南,章梓雄.非粘性流体力学[M].北京:清华大学出版社,2003.
- [12] 蔡增基,龙天渝.流体力学泵与风机[M].北京:中国建筑工业出版社,2009.