



基于 SSA-VMD-BP-LSSVM 冷负荷预测模型的 辐射供冷加新风系统 MPC 策略

蒙荷洁, 王志毅, 白雪松

(浙江理工大学建筑工程学院, 杭州 310018)

摘要: 辐射供冷加新风系统因其舒适度高、优势在夏热冬冷地区得到广泛应用,但其非线性、滞后性及能耗协调矛盾等特性,导致传统反馈控制策略难以实现动态负荷下的温湿度精准控制与节能运行。为此,以辐射供冷加新风系统为研究对象,建立了一种冷负荷预测模型,并在此基础上设计相应的模型预测控制(Model predictive control, MPC)策略。首先,通过斯皮尔曼秩相关系数法筛选输入特征,结合麻雀搜索算法(Sparrow search algorithm, SSA)优化的变分模态分解(Variational mode decomposition, VMD)算法分解冷负荷序列,并分别采用 BP 神经网络和最小二乘支持向量机(Least squares support vector machine, LSSVM)模型对子序列建模,构建了 SSA-VMD-BP-LSSVM 冷负荷预测模型;其次,结合改进的多目标粒子群算法(Improved multi-objective particle swarm optimization, IMOPSO)和最优控制量筛选原则设计 MPC 策略;最后,以杭州某办公室辐射供冷加新风系统为例,搭建 TRNSYS-MATLAB 联合仿真平台,验证 SSA-VMD-BP-LSSVM 冷负荷预测模型的准确性以及 MPC 策略的温湿度控制效果和节能性。结果表明:与 BP 等 4 个模型相比,SSA-VMD-BP-LSSVM 冷负荷预测模型具有更高精度;相对湿度稳定在舒适区间的前提下,与反馈控制策略相比,采用 MPC 策略时,室内空气温度更加接近设定值且更加稳定,空调系统运行能耗降低 8.05%。该研究引入 SSA 优化 VMD 算法,避免传统分解的模态重叠和信息丢失问题,并采用 BP 和 LSSVM 分频段建模,提高了冷负荷预测模型对异常波动值和非线性数据处理的适应性;同时,IMOPSO 算法在传统 MOPSO 算法基础上增加了混沌粒子初始化策略和粒子位置变异操作,提高了 MPC 策略在动态负荷下的全局搜索能力和收敛稳定性。该研究可为动态负荷下辐射供冷加新风系统的控制提供参考。

关键词: 模型预测控制;辐射供冷;新风;节能;冷负荷预测;温湿度控制

中图分类号: TP183

文献标志码: A

文章编号: 1673-3851(2026)03-0219-10

引文格式: 蒙荷洁, 王志毅, 白雪松. 基于 SSA-VMD-BP-LSSVM 冷负荷预测模型的辐射供冷加新风系统 MPC 策略[J]. 浙江理工大学学报(自然科学), 2026, 55(2): 219-228.

Reference Format: MENG Hejie, WANG Zhiyi, BAI Xuesong. MPC strategy of radiative cooling combined with fresh air system based on SSA-VMD-BP-LSSVM cooling load prediction model[J]. Journal of Zhejiang Sci-Tech University, 2026, 55(2): 219-228.

MPC strategy of radiative cooling combined with fresh air system based on SSA-VMD-BP-LSSVM cooling load prediction model

MENG Hejie, WANG Zhiyi, BAI Xuesong

(School of Civil Engineering and Architecture, Zhejiang Sci-Tech University, Hangzhou 310018, China)

Abstract: The radiative cooling combined with fresh air system has been widely applied in hot summer and cold winter areas because of its high comfort level. But its nonlinear nature, lag, and energy consumption coordination issues make it tough for traditional feedback control strategies to achieve precise temperature and humidity control and energy-saving operation under dynamic loads. A cooling load

收稿日期: 2025-04-22 网络出版日期: 2025-09-17

基金项目: 国家自然科学基金项目(72072165)

作者简介: 蒙荷洁(1999—), 女, 南宁人, 硕士研究生, 主要从事建筑节能和建筑热环境方面的研究。

通信作者: 王志毅, E-mail: zywang-wf@163.com

prediction model was established with the radiative cooling combined with fresh air system as the research object, and the corresponding model predictive control (MPC) strategy was designed on this basis. Firstly, the input features were screened by Spearman rank correlation coefficient method, and the variational mode decomposition (VMD) algorithm was combined with the sparrow search algorithm (SSA) to decompose the cold load sequence, and the BP neural network and the least squares support vector machine (LSSVM) model were used respectively to model the subsequences, and to construct the SSA-VMD-BP-LSSVM cooling load prediction model. Secondly, the MPC strategy was designed by combining the improved multi-objective particle swarm optimization algorithm (IMOPSO) and the optimal control quantity screening principle. Finally, taking the radiative cooling combined with fresh air system of an office in Hangzhou as an example, the TRNSYS-MATLAB joint simulation platform was built to verify the accuracy of the SSA-VMD-BP-LSSVM cooling load prediction model and the temperature and humidity control effect and energy saving of the MPC strategy. The results show that the SSA-VMD-BP-LSSVM cooling load prediction model has higher accuracy compared with the four models such as BP. Under the condition that the relative humidity is stable within the comfort zone, compared to the feedback control strategy, adopting the MPC strategy results in the indoor air temperature being closer to the set value and more stable, and the energy consumption of the air conditioning system is reduced by 8.05%. In this study, SSA is introduced to optimize VMD to avoid the problems of modal overlap and information loss caused by traditional decomposition, and BP and LSSVM sub-band modeling are used to improve the adaptability of the cooling load prediction model to abnormal fluctuation values and nonlinear data processing. At the same time, IMOPSO adds the chaotic particle initialization strategy and particle position variation on the basis of the traditional MOPSO, which improves the global search ability and convergence stability of the MPC strategy in dynamic load scenarios. This study can provide reference for the control of radiative cooling combined with fresh air system under dynamic loads.

Key words: model predictive control; radiation cooling; fresh air; energy saving; cooling load prediction; temperature and humidity control

0 引言

辐射供冷加新风系统凭借其噪声低、吹风感弱、舒适度高等优势^[1],在夏热冬冷地区获得越来越广泛的应用。然而,辐射供冷系统具有非线性强、热响应滞后及结露风险等问题,引入新风系统虽然提高了除湿能力,但是增加了温湿度控制难度和能耗协调矛盾,因此传统的反馈控制策略难以在动态负荷工况下同时满足温湿度控制和节能要求^[2-3]。模型预测控制(Model predictive control, MPC)通过集成预测模型、滚动优化和时域更新机制,在处理空调系统的高热惯性和运行环境动态变化方面表现出显著优势^[4-6]。

准确的预测模型是 MPC 策略构建并实际应用的前提。近年来,研究者在预测模型构建方面不断探索新方法以提高模型预测精度,常用方法包括神经网络^[7-8]、支持向量机^[7,9]、时间序列^[9]等。祁鑫等^[10]利用奇异值分解对高校学生宿舍空调负荷数据进行降噪处理,并将处理后的数据用于训练长短期记忆神经网络(Long short-term memory,

LSTM)模型,发现该模型显著提升了空调负荷预测精度。Wang 等^[11]提出了一种基于预测优化控制的数据中心空调水系统全局优化方法,采用时间序列模型优化设备设定值,有效提高了空调系统的节能效果。王承凯等^[12]提出了一种基于注意力机制的双向 LSTM 模型和基于雁群算法的短期负荷预测模型,有效提高了智能设备负荷预测精度。上述预测模型的精度虽有所提高,但仍存在对异常波动值和非线性数据处理不足等问题。

基于预测的 MPC 策略应用研究呈现算法融合和研究对象特异性强的特点^[13-15]。Chen 等^[3]提出了一种针对吊顶辐射供冷系统的 MPC 策略,采用平衡截断方法简化模型,实现了连续和间歇运行模式下区域空气温度的精确跟踪。Ra 等^[16]在工厂建筑中应用基于深度神经网络(Deep neural network, DNN)模型的实时 MPC 策略,通过优化空调系统运行参数,在显著降低能耗的同时维持了室内温度的稳定性。白雪松等^[17]提出了一种基于变分模态分解(Variational mode decomposition, VMD)优化的反向传播(Back propagation, BP)神经网络预测模

型,结合多目标粒子群算法(Multi-objective particle swarm optimization, MOPSO),实现了辐射供冷加新风空调系统控制的节能优化。尽管研究对象已经从单一系统向复杂系统过渡,但现有研究仍侧重于单一的温度控制,对湿度参数关注较少。MOPSO 算法在处理多目标优化问题时表现出色,但其性能依赖初始参数设置,容易陷入局部最优,难以适应动态负荷变化。

鉴于现有预测模型和 MPC 策略在应对动态负荷变化时的局限性,本文以辐射供冷加新风系统为研究对象,提出了一种新的冷负荷预测模型,并基于该模型设计了相应的 MPC 策略。首先,采用麻雀搜索(Sparrow search algorithm, SSA)优化的 VMD 算法分解冷负荷序列,并分别采用 BP 神经网络和最小二乘支持向量机(Least squares support vector machine, LSSVM)模型对不同特征的子序列建模,构建 SSA-VMD-BP-LSSVM 冷负荷预测模型;其次,设计改进多目标粒子群算法(Improved multi-objective particle swarm optimization, IMOPSO),在传统 MOPSO 算法上增加了混沌粒子初始化和粒子位置变异策略,再将 IMOPSO 算法和最优控制量筛选原则结合,形成 MPC 策略的滚动优化模块,用于求解最优控制参数;最后,将 SSA-

VMD-BP-LSSVM 冷负荷预测模型和滚动优化模块嵌入 MPC 策略框架,并以杭州某办公楼辐射供冷加新风系统为例,搭建 TRNSYS-MATLAB 联合仿真平台,验证该冷负荷预测模型的准确性和所提 MPC 策略的温湿度控制效果与节能性。

1 方法设计

1.1 辐射供冷加新风系统描述

本文的研究对象为杭州某办公楼的辐射供冷加新风系统。杭州属夏热冬冷地区,夏季高温高湿,办公建筑冷负荷受人员流动、设备散热及湿热环境影响显著,具有动态负荷的典型性。实验房间常驻人员 6 人,配备 6 台计算机及 13 组灯具,带有茶桌等湿源。该系统的结构示意图如图 1 所示,冷源采用空气源制冷机组,配备定频水泵;辐射供冷末端选用 G 型聚丙烯毛细管网(管径 4.3 mm,间距 20 mm),敷设于吊顶内,通过混水三通阀调节进水温度(0~100%),配备的变频水泵采用 PWM 变速调节控制,调节范围为 10%~84%,最小单次调节间隔为 2%左右;除湿新风机风量为 300 m³/h,除湿能力为 93 L/d(处理干球温度为 30 °C、相对湿度为 80%的室外空气),除湿新风机的冷水进水流量由电磁二通阀控制。

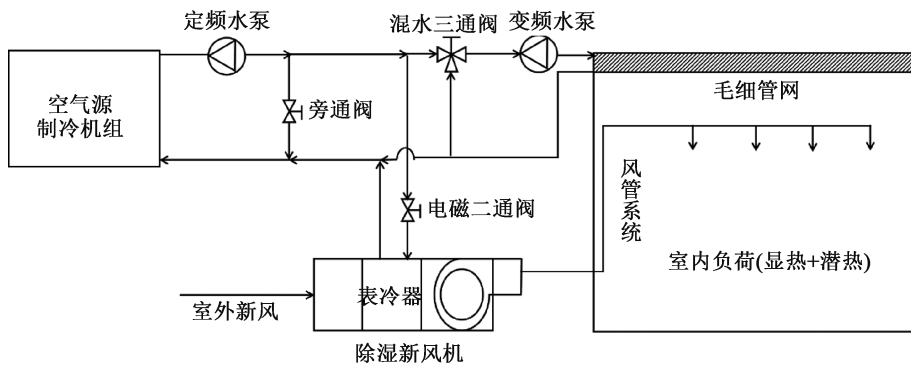


图 1 辐射供冷加新风系统结构示意图

1.2 冷负荷预测模型

采集了 2023 年 6 月 1 日至 7 月 30 日辐射供冷加新风系统的运行数据,包括室内外温湿度、太阳辐射强度、太阳方位角、室外风速、室内设备耗电量、空调系统水流量和水温等。采用 PC-4 光伏电站环境监测系统采集太阳辐射强度(±5%)、室外温湿度(±0.1 °C, ±2%)和风速风向(±0.3 m/s, ±3°);使用 JHT-P 温湿度传感器测量室内和送风温湿度(±0.3 °C, ±3%);通过 SIN-LDG-DN25 电磁流量计和 RSDS19 温度传感器分别监测水流量(±0.5%)和水温(±0.1 °C)。采集时间为每天 7:30—17:30,每

15 min 采集一组数据,得到 2400 组数据。

1.2.1 输入特征选择

由于冷负荷不服从正态分布,本文采用斯皮尔曼(Spearman)秩相关系数法^[18]筛选输入特征,相关性分析结果如表 1 所示。当前时刻 t 的室外空气干球温度 $T_w(t)$ 、室外空气相对湿度 $H_w(t)$ 、太阳辐射强度 $R(t)$ 、室内设备功率 $P(t)$ 、室内空气温度 $T_n(t)$ 、室内空气相对湿度 $H_n(t)$ 、室内目标空气干球温度 $T_{n, set}(t)$ 、室内目标空气相对湿度 $H_{n, set}(t)$ 与冷负荷的相关性较高 ($|\text{Spearman 秩相关系数}| > 0.3$ ^[19]),用作预测下一时刻空调系统负荷 $Q(t+1)$

的输入特征。不考虑与冷负荷相关性较弱的室外风速 $v(t)$ 和太阳方位角 $\theta(t)$ 。

表 1 输入参数 Spearman 秩相关系数表

变量	Spearman 秩相关系数	变量	Spearman 秩相关系数
$H_{n, set}(t)$	-0.826	$T_n(t)$	-0.556
$H_n(t)$	-0.756	$T_w(t)$	0.485
$R(t)$	0.739	$H_w(t)$	-0.469
$T_{n, set}(t)$	-0.645	$v(t)$	0.282
$P(t)$	0.582	$\theta(t)$	0.249

1.2.2 SSA 优化的 VMD 算法参数寻优

采用 SSA 优化 VMD 算法, 设定 VMD 的参数寻优范围, 设定分解层数 D 和惩罚因子 β 的寻优范围分别为 $[3, 6]$ 和 $[200, 3000]$, 麻雀的种群规模为 30, 迭代次数为 20, 发现者、跟随者和预警者比例为 $5:4:1$ 。同时设定 VMD 的中心频率 $\omega_0=0$, 采样频率 $f_s=9600$, 收敛判据为 $r=1 \times 10^{-7}$ 。随着 SSA 迭代, 包络熵在经过了 43 次迭代后保持在 7.4029 不变, 此时的最优解为 $[D, \beta]=[4, 2142]$ 。

为了验证该方法的分解效果, 采用中心频率观察法对 VMD 的分解层数进行递增试验。当 $D=4$ 时, 不同子序列的中心频率分布相对均匀, 没有因分解层数过多发生模态重叠, 也没有因分解层数过少而丢失信息。

将最优解代入 VMD 中, 将原始冷负荷序列分解为如图 2 所示的 4 个子序列和残差序列。IMF1 能够表现出原始冷负荷序列的周期性, 非线性特征不明显。IMF2 虽然波动性较强, 但仍具有一定的规律性。IMF3、IMF4 振幅较大, 规律性难以观察。因此, 使用 BP 神经网络对 IMF1 和 IMF2 进行预测, 使用 LSSVM 模型对 IMF3 和 IMF4 进行预测。




图 2 冷负荷序列分解波形图

1.2.3 BP 神经网络结构参数

选用三层神经网络结构对 IMF1 和 IMF2 进行预测, 并使用贝叶斯正则化法^[20]对 BP 神经网络的权值更新方式进行优化。训练步数设为 1000 Epochs, 学习率设为 0.15, 训练目标误差设为 1×10^{-7} 。输入层神经元数量根据输入特征参数数量设置为 8, 输出层神经元设置为 1, 隐含层神经元数量范围设定为 $[4, 14]$ 。IMF1 和 IMF2 的平均绝对百分比误差(MAPE)随隐含层神经元数量变化趋势如图 3 所示, 从图中可以看出, 当隐含层神经元数量在 12 个时, IMF1 和 IMF2 的 MAPE 值最小。因此, 确定 IMF1 和 IMF2 的 BP 神经网络结构均为 8-12-1。




图 3 IMF1 和 IMF2 的 MAPE 随隐含层神经元数量变化曲线

1.2.4 LSSVM 模型参数

选择泛化能力最强的 RBF 核函数将数据集映射到高维空间。正则化参数 γ 决定了模型的训练速度与误差, 核函数系数 g 决定了模型的复杂度, 其设定值并非固定值, 需要根据样本集合进行设定。使用网格搜索法对 IMF3 和 IMF4 的 LSSVM 模型的 γ 和 g 进行寻优, 并分析了不同参数组合对 LSSVM 模型 MAPE 的影响。LSSVM 参数寻优图如图 4 所示, IMF3 的最优参数为 $[\gamma_1, g_1]=[2, 0.06]$, IMF4 的最优参数为 $[\gamma_2, g_2]=[2, 0.02]$ 。

1.3 MPC 策略

1.3.1 室内空气温湿度预测模型

MPC 策略是基于预测冷负荷对空调系统的提前控制, 以室内空气温度接近目标值为控制目标, 并将室内空气相对湿度限制在 $[40\%, 65\%]$ 作为控制约束。

为了验证室内空气温度预测模型和室内空气相对湿度预测模型的预测效果, 随机选取了 100 组数据对两个模型的预测值与实际值进行对比。

室内空气温湿度预测值与实际值对比情况如图 5 所示,从图中可以看出,基于控制量及室内外环境,训练后的室内空气温度预测模型和室内空气

相对湿度预测模型可以较好地跟随室内空气温度和室内空气相对湿度的实际变化趋势,可以满足 MPC 策略建模需求。

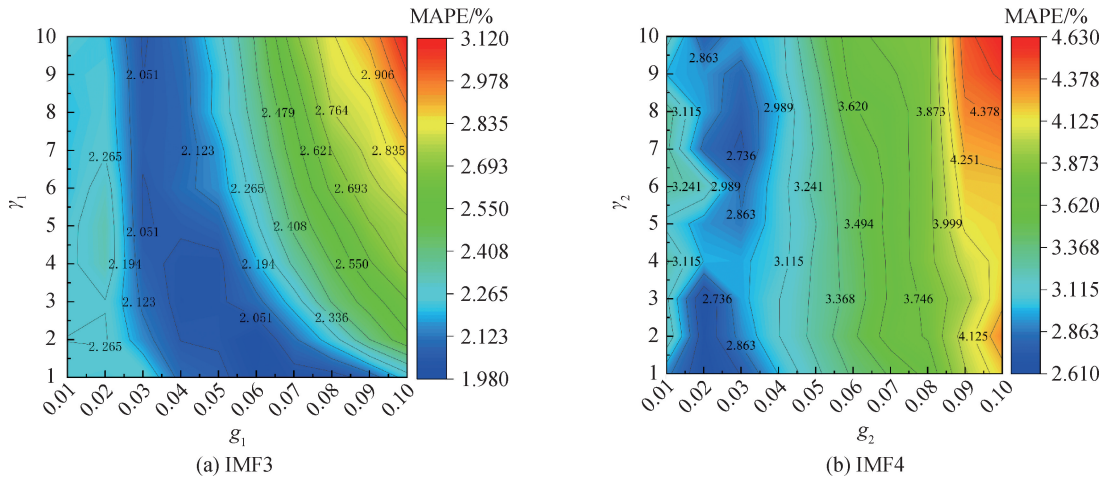


图 4 LSSVM 参数寻优热力图




图 5 室内空气温湿度预测值与实际值变化曲线

1.3.2 MPC 策略实现流程

MPC 策略包含 3 个核心模块:预测模型、滚动优化和时域更新。其中,滚动优化模块采用改进的 IMOPSO 算法,在保留传统 MOPSO 算法精细搜索能力的基础上,增加了混沌粒子初始化策略和粒子位置变异策略,防止寻优过程过早陷入局部最优,提升了算法搜索能力。同时,该模块还集成了最优控制量筛选原则,确保滚动优化始终逼近全局最优解。

MPC 策略实现流程如图 6 所示,通过 TRNSYS-MATLAB 联合仿真平台进行验证。首先,初始化空调系统运行参数,包括 IMOPSO 参数、实时工况(室外环境参数 $z_0[t]$ 、室内环境参数 $z_1[t]$ 、空调系统运行参数 $z_2[t]$)、室内设定工况 $z_{set}[t]$ 和冷负荷预测值 $Q[t+1]$;其次,采用 IMOPSO 算法进行优化计算,基于 Circle 混沌映射初始化寻优变量(制冷机组的出水温度 T_{out} 、除湿新风机组水流量 m_x 、辐射管网水流量 m)的初始位置

$X_i(1)$ 和初始飞行速度 $V_i(1)$,评价适应度并混合变异和传统更新策略迭代寻优,输出 Pareto 最优解集;再次,将最优控制量筛选原则确定的最优控制量输入 TRNSYS 模型;最后,判断模拟是否结束,若未结束,则进行下一轮最优控制量寻优。

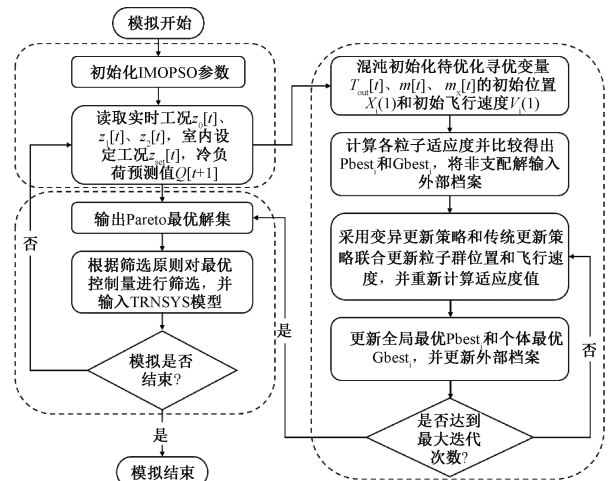



图 6 MPC 策略实现流程图


MPC策略的目标函数为室内空气温度接近目标值和空调系统运行能耗低。当室内空气温度偏离目标值时,MPC策略根据能耗和温度的动态关系筛选最优控制量。IMOPSO初始参数设置情况为:初始粒子数 $N_p=200$,最大迭代数 $T_{max}=100$,精英库容量 $N_r=100$,惯性权重 $\omega_0=0.4$,学习因子 $c_1=2$,学习因子 $c_2=2$,粒子最大搜索速度 $v_{max}=5$,粒子初始变异率 $d=0.2$ 。为了验证MPC策略的有效性,采用高于和低于目标温度的两种工况作为试验工况,典型工况输入参数如表2所示,包括冷负荷 Q 、室外空气干球温度 T_w 、室外空气相对湿度 H_w 、室

表2 典型工况输入参数

典型工况	Q/W	$T_w/^\circ C$	$H_w/\%$	$T_n/^\circ C$	$T_{in}/^\circ C$	$T_{n,set}/^\circ C$
1	4302	28.05	82.02	25.92	17.19	26
2	7528	32.24	71.35	26.23	11.24	26



(a) 典型工况1



(b) 典型工况2

图7 IMOPSO寻优Pareto前沿图

表3 典型工况多目标优化结果

典型工况	$T_{out}/^\circ C$	$m_x/(kg \cdot h^{-1})$	$m/(kg \cdot h^{-1})$	$P/(kW \cdot h)$	$T_n(t+1)/^\circ C$
1	16	290.06	844.21	1.58	25.956
2	8.55	1025.16	3271.89	2.73	26.194

2 结果与分析

2.1 冷负荷预测模型预测结果分析

使用处理后的冷负荷数据集对SSA-VMD-BP-LSSVM、SSA-VMD-BP、SSA-VMD-LSSVM、BP和LSSVM的模型进行训练,并对实际值和各模型预测值进行比较与分析。考虑到负荷预测模型预测效果会受到不同天气条件的影响,分别选取单日冷负荷偏低的6月7日与单日冷负荷偏高的7月22日的冷负荷数据进行模型预测效果验证,单日有40组数据,采用其他日期的数据集对模型进行训练。

6月7日冷负荷序列预测结果对比情况如图8

内空气温度 T_n 、制冷机组的进水温度 T_{in} 、室内目标空气干球温度 $T_{n,set}$ 。

图7展示了2种工况下IMOPSO算法优化得到的Pareto前沿图。结果显示,当室内温度低于 $26^\circ C$ 时,能耗增加会使温度进一步偏离目标值;而当温度高于 $26^\circ C$ 时,能耗增加会使温度更接近目标值。这表明2个目标存在冲突,需要根据预设的筛选原则确定最优控制量。

IMOPSO优化结果如表3所示,MPC策略可有效控制室内空气温度向目标值靠近,且不会引起系统能耗过大。

所示,从图中可以看出:BP和LSSVM模型能捕捉实际冷负荷变化趋势,但预测值普遍低于实际值,尤其是在高频波动区(数据组25—40)偏差更加显著;与单一模型相比,SSA-VMD优化后的混合模型(SSA-VMD-BP和SSA-VMD-LSSVM)更接近实际冷负荷,但总体仍偏低,这是因为SSA-VMD分解将原始冷负荷序列分解为代表不同信息的子序列,有效提升了特征提取和降噪能力,从而提高了预测精度;SSA-VMD-LSSVM误差更小但平滑了局部突变,SSA-VMD-BP保留负荷突变但误差更大,这是因为BP可能对高频序列(噪声或细节)过拟合,而LSSVM因结构风险最小化倾向平滑;SSA-VMD-BP-LSSVM模型表现最佳,特别是在高频波

动区域,有效提升了预测精度和稳定性,这是因为 SSA-VMD-BP-LSSVM 模型对 SSA-VMD 分解的子序列采取“分治策略”,采用 LSSVM 模型对非平稳子序列进行预测,采用 BP 模型对平稳子序列进行预测,避免了过拟合或拟合不足的问题。




图 8 6月7日冷负荷序列预测结果对比曲线

本文采用了 MAPE、均方根误差变异系数 (CVRMSE)、决定系数(R^2)和预测运行时间等 4 个指标对不同模型进行对比分析,以 6 月 7 日为例,结果如表 4 所示。从表 4 可以看出:SSA-VMD-BP-

LSSVM 模型的预测时间相较于其他模型有所增加,这是模型复杂度提高导致计算量增大造成的,但模型预测效果是提升的,并且所提出的模型的运行时间远小于空调系统的调控时间,不对实际工程造成控制滞后的影响。

7 月 25 日 5 种预测模型的预测结果如图 9 所示,所有模型均能捕捉实际负荷变化趋势,但单一模型偏差最大。SSA-VMD 优化后的混合模型更接近实际冷负荷,其中 SSA-VMD-BP-LSSVM 模型表现最佳。这进一步证明了 SSA-VMD 分解和 BP-LSSVM 分治策略的有效性。

6 月 7 日和 7 月 25 日各预测模型的预测相对误差图如图 10 所示,从图中可以看出:与其他模型相比,SSA-VMD-BP-LSSVM 模型相对误差较小,尤其是在 6 月 7 日(冷负荷较低且波动频繁)和 7 月 25 日早晨(冷负荷突然升高)表现更加优异。通过对各模型在不同天气条件下的对比可以得出结论,提出的 SSA-VMD-BP-LSSVM 模型具有更加优秀的预测效果和稳定性,在处理非线性冷负荷变化和冷负荷突变具有独特优势,可为辐射供冷加新风系统预测控制提供基础。

表 4 不同预测模型预测结果评价(6月7日)

模型	MAPE/%	CVRMSE	R^2	预测运行时间/s
BP	13.03	0.1375	0.9757	3.2613
LSSVM	9.51	0.1089	0.9822	4.6921
SSA-VMD-BP	9.49	0.1125	0.9815	4.2302
SSA-VMD-LSSVM	7.01	0.0833	0.9871	5.6919
SSA-VMD-BP-LSSVM	3.13	0.0392	0.9896	6.0472

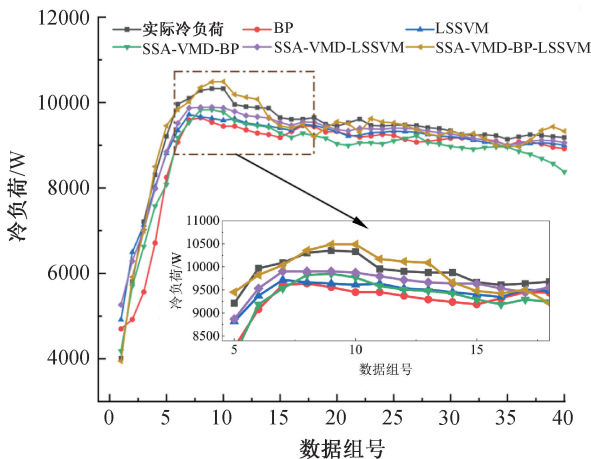


图 9 7月25日冷负荷序列预测结果对比曲线

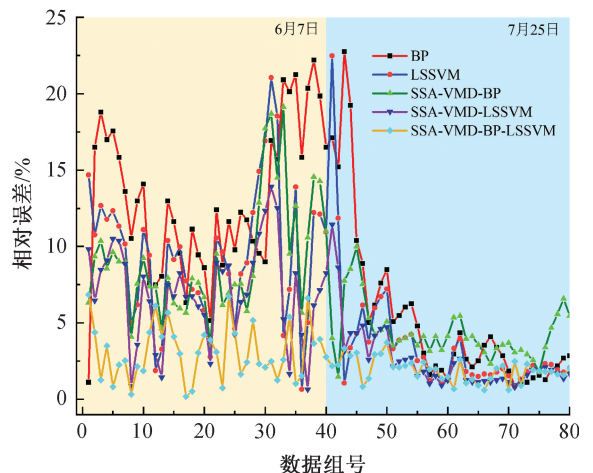


图 10 冷负荷预测相对误差对比曲线

2.2 MPC策略的温湿度控制效果与节能性分析

2.2.1 温湿度控制效果分析

MPC策略和反馈控制策略下的室内空气温度变化情况如图11所示,从图中可以看出:反馈控制策略下的室内空气温度波动频繁,尤其在较低负荷工况(50%~70%)下振幅更加明显,而MPC策略下的室内空气温度在不同负荷工况下均能更快接近并维持目标温度,这表明MPC策略下的室内空气

温度相较于反馈控制策略更加稳定。这是因为在反馈控制策略下,制冷机组关闭后出水温度不断提高,只有当室内空气温度超过一定温度后,制冷机组才能获得反馈信号重新开启,造成了控制的延迟,进而引起室内空气温度的波动;在MPC策略下,制冷机组可以根据预测冷负荷提前调节出水温度,使得空调系统供冷量和冷负荷实现动态平衡,缩小了室内空气温湿度波动范围。

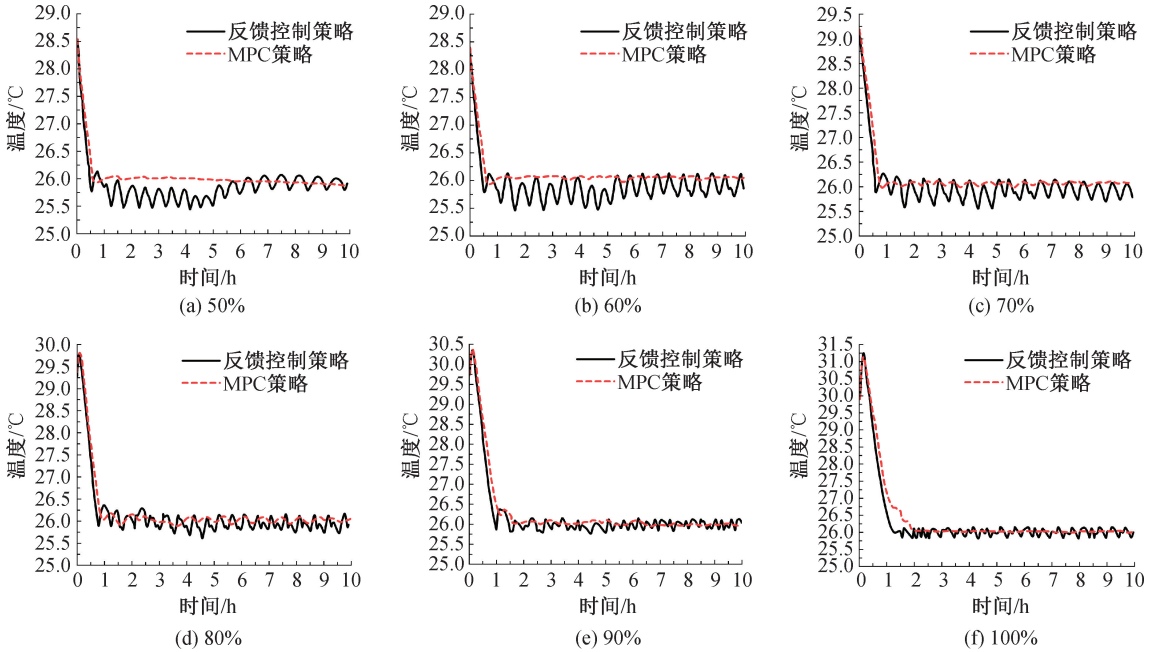


图11 不同工况MPC策略和反馈控制策略下室内空气温度变化曲线

MPC策略和反馈控制策略下的室内空气相对湿度变化情况如图12所示,MPC策略下的室内空

气相对湿度稳定在40%~65%,满足相对湿度的约束条件,并且比反馈控制策略下的室内空气相对湿

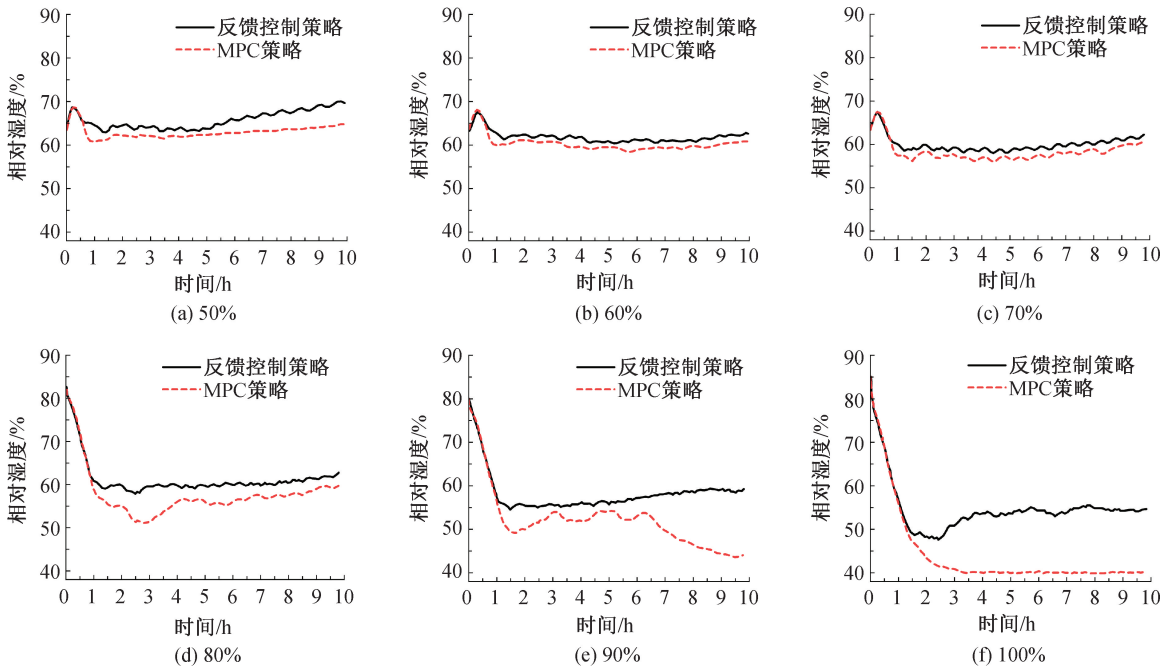


图12 不同工况MPC策略和反馈控制策略下室内空气相对湿度变化曲线

度更低。这是因为 MPC 策略下的制冷机组始终保持在较低的出水温度,使新风除湿机组的送风含湿量稳定在较低的状态。

与反馈控制策略相比,MPC 策略控制下的室内空气温度波动范围更小,相对湿度范围稳定在 40%~65%,可以保证室内人员的热湿环境舒适感,验证了所提出的 MPC 策略可根据人员的主观需求实现对室内空气温湿度的有效控制。

2.2.2 节能性分析

不同日平均负荷率下空调系统设备运行能耗如




图 13 不同日平均负荷率下空调系统设备运行能耗柱状图

6 月和 7 月空调系统运行能耗情况如图 14 所示,MPC 策略的系统单日运行能耗相均低于反馈控制策略。反馈控制策略 6 月和 7 月的空调系统总运行能耗为 1001.21 kW·h,而 MPC 策略 6 月和 7 月的系统总运行能耗为 920.63 kW·h,空调系统运行能耗降低了 8.05%,实现了辐射供冷加新风系统的有效节能。




图 14 6 月和 7 月空调系统运行能耗变化曲线

图 13 所示,从图中可以看出:不同日平均负荷率下两种控制策略的风机能耗和水泵能耗变化不大,其中水泵运行能耗占空调系统总运行能耗比例略有提升;与反馈控制策略相比,MPC 策略在平均负荷率 50%、60%、70%、80%、90%和 100%下的制冷机组运行能耗分别降低了 11.15%、15.89%、11.31%、7.80%、3.58%和 1.76%,空调系统总运行能耗分别降低了 9.02%、12.81%、9.26%、6.58%、3.11%和 1.50%,说明制冷机组的运行能耗是影响空调系统节能的主要方面。

提出了一种基于 SSA-VMD-BP-LSSVM 冷负荷预测模型的 MPC 策略,并搭建 TRNSYS-MATLAB 联合仿真平台对冷负荷预测模型的准确性和 MPC 策略的温湿度控制效果及节能性进行验证。本文构建的 SSA-VMD-BP-LSSVM 冷负荷预测模型,与 BP、LSSVM、SSA-VMD-LSSVM 和 SSA-VMD-BP 预测模型相比,拥有较好的预测精度并具有更强的泛化能力;本文设计的 MPC 策略,滚动优化模块采用了增加混沌粒子初始化策略和粒子位置变异策略的 IMOPSO 算法和最优控制量筛选原则,提高 MPC 策略对动态负荷的适应性。验证结果表明,在保证室内空气相对湿度稳定在舒适区间的情况下,相较于反馈控制策略,MPC 策略控制下的室内空气温度更加接近设定值且波动较小,同时空调系统运行能耗有所降低,表明该策略在动态负荷工况下温湿度控制和节能优化的有效性。考虑到本文实验数据仅基于杭州地区的夏季运行工况,未来需进一步验证模型与策略在多气候区和多季节中的适用性。

3 结 语

本文针对夏热冬冷地区动态负荷工况下辐射供冷加新风系统的温湿度精准控制及节能优化问题,

参考文献:

- [1] Su M, Liu J, Kim M K, et al. Predicting moisture condensation risk on the radiant cooling floor of an office using integration of a

- genetic algorithm-back-propagation neural network with sensitivity analysis[J]. *Energy and Built Environment*, 2024, 5(1): 110-129.
- [2] Ren J, Liu J, Zhou S, et al. Experimental study on control strategies of radiant floor cooling system with direct-ground cooling source and displacement ventilation system; A case study in an office building[J]. *Energy*, 2022, 239: 122410.
- [3] Chen Q, Li N. Model predictive control for energy-efficient optimization of radiant ceiling cooling systems[J]. *Building and Environment*, 2021, 205: 108272.
- [4] Talib A, Joe J. Analyzing the overrated performance of model-based predictive control and energy saving strategies in building energy management: A review [J]. *Journal of Building Engineering*, 2025, 101: 111909.
- [5] Xin X, Zhang Z, Zhou Y, et al. A comprehensive review of predictive control strategies in heating, ventilation, and air-conditioning (HVAC): Model-free VS model[J]. *Journal of Building Engineering*, 2024, 94: 110013.
- [6] Yao Y, Shekhar D K. State of the art review on model predictive control (MPC) in heating ventilation and air-conditioning (HVAC) field [J]. *Building and Environment*, 2021, 200: 107952.
- [7] 邓晓红, 官磊, 刘兴民. 基于 PSO-LS-SVMR 的公共建筑能耗短期预测模型[J]. *建筑节能*, 2019, 47(4): 120-124.
- [8] 杨旭, 赵旭磊, 涂壤, 等. 基于改进粒子群寻优的数据中心精密空调无模型自适应预测控制[J]. *北京工业大学学报*, 2023, 49(4): 424-434.
- [9] 于军琪, 边策, 赵安军, 等. 考虑频域分解后数据特征的空调负荷预测模型[J]. *控制理论与应用*, 2022, 39(6): 1149-1157.
- [10] 祁鑫, 王福忠, 张丽, 等. 基于 SVD-LSTM 的高校学生宿舍空调负荷预测[J]. *电子科技*, 2020, 33(11): 59-66.
- [11] Wang P, Sun J, Yoon S, et al. A global optimization method for data center air conditioning water systems based on predictive optimization control [J]. *Energy*, 2024, 295: 130925.
- [12] 王承凯, 王巍, 刘大为, 等. 面向新能源调度控制的短期负荷预测算法[J]. *微型电脑应用*, 2025, 41(1): 100-102.
- [13] Adelekan D S, Ohunakin O S, Paul B S. Artificial intelligence models for refrigeration, air conditioning and heat pump systems[J]. *Energy Reports*, 2022, 8: 8451-8466.
- [14] Freund S, Schmitz G. Implementation of model predictive control in a large-sized, low-energy office building[J]. *Building and Environment*, 2021, 197: 107830.
- [15] Joe J, Karava P. A model predictive control strategy to optimize the performance of radiant floor heating and cooling systems in office buildings[J]. *Applied Energy*, 2019, 245: 65-77.
- [16] Ra S J, Kim J H, Park C S. Real-time model predictive cooling control for an HVAC system in a factory building[J]. *Energy and Buildings*, 2023, 285: 112860.
- [17] 白雪松, 王志毅. 多气候区辐射+新风空调系统预测控制策略研究[J]. *理论数学*, 2024(2): 746-758.
- [18] Spearman C. The proof and measurement of association between two things[J]. *The American Journal of Psychology*, 1904, 15(1): 72-101.
- [19] Wu Y, Liu H, Li B, et al. Individual thermal comfort prediction using classification tree model based on physiological parameters and thermal history in winter [J]. *Building Simulation*, 2021, 14(6): 1651-1665.
- [20] MacKay D J C. A practical Bayesian framework for backpropagation networks[J]. *Neural Computation*, 1992, 4(3): 448-472.

(责任编辑:康 锋)