高原, 林尧林. 模型预测控制在暖通空调系统中的研究与应用综述[J]. 智能计算机与应用,2026,16(8):33-43. DOI:10.20169/j.issn.2095-2163.25011101

模型预测控制在暖通空调系统中的研究与应用综述

高 原, 林尧林
(上海理工大学 环境与建筑学院, 上海 200093)

摘 要: 由于暖通空调系统存在滞后性,能量浪费严重,导致用户成本上升。同时,建筑系统的动态特性、天气变化、模型误差及外部干扰等不确定性因素,使得空调实际控制精度下降、系统稳定性不足,进而影响室内舒适度。自模型预测控制(MPC)引入 HVAC 系统以来,已被认为是提升舒适度和降低能耗的有效手段之一。本文综述了 MPC 在 HVAC 系统中的研究进展与应用成果,分析了国内外研究中的不同变体,重点探讨了 MPC 的动态建模特点,如预测控制模型、滚动优化算法和反馈校正等。此外,本文还分析了不同设计方向对 MPC 效率的影响,并结合具体文献案例总结了 MPC 在 HVAC 系统中的实际应用效果。本文旨在为 HVAC 系统中的 MPC 应用提供参考,帮助选择合适的控制策略,并解决实际应用中的挑战。

关键词: 暖通空调; 模型预测控制; MPC 建模; 空调节能; 热舒适性
中图分类号: TU831.2 **文献标志码**: A **文章编号**: 2095-2163(2026)08-0033-11

Research and application of model predictive control in HVAC system

GAO Yuan, LIN Yaolin
(School of Environment and Architecture, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: Due to the lag of HVAC system, energy waste is serious, resulting in increased user costs. At the same time, the dynamic characteristics of the building system, weather changes, model errors and external interference and other uncertain factors, reduce the actual control accuracy, the system stability is insufficient, and then affect the indoor comfort. Since the introduction of Model Predictive Control (MPC) in HVAC systems, it has been recognized as one of the effective means to improve comfort and reduce energy consumption. This paper reviews the research progress and application results of MPC in HVAC system, analyzes the different variants in domestic and foreign research, and focuses on the dynamic modeling features of MPC, such as predictive control model, rolling optimization algorithm and feedback correction. In addition, this paper also analyzes the influence of different design directions on MPC efficiency, and summarizes the practical application effect of MPC in HVAC system based on specific literature cases. The purpose of this paper is to provide reference for MPC applications in HVAC systems, to help select appropriate control strategies, and to solve practical application challenges.

Key words: HVAC; Model Predictive Control; MPC modeling; air conditioning energy saving; thermal comfort

0 引 言

随着能源短缺问题日益加剧,构建绿色低碳发展体系迫在眉睫。作为建筑的重要组成部分,暖通空调(HVAC)系统在提升建筑能效中发挥着关键作用。然而,HVAC 系统受控制滞后和不确定性因素影响,导致能量浪费和舒适度下降,传统控制方法已难以满足现代社会对节能与舒适的双重需求。

尽管已有多种暖通空调控制方法,开/关控制和 PID 控制因其操作简便性仍被广泛应用。随着数据存储、计算能力和通信技术的进步,现代控制方法的实施变得更加可行,该方法能够有效解决暖通空调系统中固有的控制问题[1]。本文重点探讨暖通空调系统中的控制策略,特别是模型预测控制(MPC)的应用与发展。

模型预测控制(MPC)源于 20 世纪 60 年代的现代控制理论,作为一种约束优化方法,虽在建筑节能领域有潜力,但由于应用有限,开关控制和 PID 控制仍是主流。研究表明,MPC 可将能耗降低 7% 至 50%,并在不影响热舒适性的前提下降低运营成

作者简介: 高 原(1998—),男,硕士研究生。主要研究方向:VAV 系统基于热分区的多目标最优温度控制。
通信作者: 林尧林(1976—),男,博士,副教授。主要研究方向:可持续建筑与建筑节能。Email:ylin@usst.edu.cn。

收稿日期: 2025-01-11

本[2]。

MPC 并非单一方法,而是一类控制策略。暖通空调系统通常面临多种不确定性因素,尽管 MPC 已被应用于此领域,但依然存在挑战。例如,在多区域系统中,可以采用分布式模型预测控制[3];对于受大量随机干扰影响的建筑能耗,随机模型预测控制[4]则更适合用来优化系统的未来成本函数。目前,MPC 主要集中于控制理论的研究,然而实验结果表明,其对不确定性因素较为敏感。为此,Arroyo[5]提出的增强预测控制(RL-MPC)算法,通过结合 MPC 与强化学习(RL)的优势,显著提升了控制性能,更有效地平衡了能源消耗与热舒适度,具有更强的理论与实际应用潜力。

在本文之前,已有学者对暖通空调领域中的模型预测控制(MPC)进行了综述。Afram 等[1]对 MPC 的理论和应用进行了详细讨论,并与其他 HVAC 控制方法进行了性能比较。Yao 等[6]探讨了 MPC 建模技术和优化算法,强调了参数设计的重要性。Taheri 等[7]讨论了影响 MPC 性能的多个设计因素,如预测时域和建筑类型。尽管已有研究综述了 MPC 在 HVAC 系统中的应用,但仍需进一步探索。一方面,缺乏对 MPC 变体的系统对比;另一方面,MPC 在实际应用中面临计算复杂度、建模难度和参数调节等挑战。未来可聚焦于新模型和优化算法,以提升 MPC 的控制效果。

本文探讨了模型预测控制(MPC)在暖通空调(HVAC)系统中的研究与应用,涵盖 MPC 的分类、建模方法、性能影响因素及具体应用。通过比较不同 MPC 变体,本文为 HVAC 系统中的 MPC 应用提供了参考框架,并帮助用户根据场景选择合适的控制方法。同时,综述了 MPC 的最新发展,分析了现有技术的不足,推动该领域的优化与发展。

1 研究方法

本文回顾了模型预测控制(MPC)在暖通空调系统中的研究进展,认为 MPC 是暖通空调控制领域最具潜力的控制方法之一。通过检索中国知网、百度学术、ScienceDirect 和 SpringerLink 等平台的文献,关键词包括“模型预测控制方法”和“MPC 在暖通空调系统中的研究”,重点分析了 MPC 的发展历程、原理、类型及优缺点。研究涉及建模、控制、优化、节能和用户舒适度等方面,共筛选出 1 560 篇相关文献,并聚焦于 MPC 在暖通空调系统中的具体应用方向,如建模、控制与优化等,相关文献数量随年份变化,如图 1 所示。

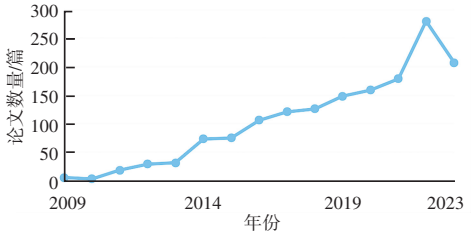


图 1 相关论文数量

Fig. 1 Number of related papers

经过第一轮筛查,筛选出 483 篇与模型预测控制(MPC)在暖通空调系统中应用相关的文章。这些文章需要进一步评估其质量和适用性。本文将重点整理 MPC 的建模、优化、控制,以及不同 MPC 变体的分类,包括 RMPC、SMPC、AMPC、HMPC、Data-driven MPC、Occupancy-based MPC、DMPC 和 EMPC。通过对这些类别的文章进行整理,将综述 MPC 在暖通空调系统中的应用与研究进展。

2 MPC 的不同变体

暖通空调系统受模型差异、天气不确定性、干扰因素等影响,易出现控制精度下降、能耗增加等问题。MPC 通过不同的优化组合方法衍生出多种变体,以适配不同场景需求,本文总结了常见的 MPC 类型,具体见表 1 所示。

2.1 RMPC 和 SMPC

RMPC 通过优化计算应对扰动问题,解决了极端情况下的控制挑战。然而,鲁棒控制方法仅关注扰动边界,忽略了模型不确定性[8],主要考虑最坏情况。如 Solopert 等[8]提出了一种针对状态依赖不确定性的线性 RMPC 方法,利用状态依赖不确定性的特性提升闭环控制性能。结果表明,该方法有效提升了系统稳定性和性能。所提出的方法在可行集范围与闭环性能上均优于 Chisci 等[9]的方法。

在暖通空调系统的实际运行过程中很少发生极端情况[7],而随机模型预测控制(SMPC)可以很好地规避这一情况的发生。SMPC 通过考虑所有工况可能发生的概率来确定最优行动,因此随机模型预测控制被认为是鲁棒模型预测控制的一种替代方案[6]。如 Liu 等[10]使用 SMPC 优化太阳能集成建筑的运行,通过引入新的概率时间序列自回归模型和近似动态规划方法,量化考虑太阳辐照度预测不确定性。结果显示,SMPC 在冬季一个月内节省了 44%的用电量。

RMPC 和 SMPC 均为应对扰动问题的有效方

法，但因系统复杂性和计算难度不同，存在应用限制。RMPC 能够有效提升系统鲁棒性，但计算复杂度高；SMPC 通过分段线性建模方式适配非线性系统，计算成本高且对模型精度要求较为严苛。

表 1　不同 MPC 变体的对比研究

Table 1　Comparison of different MPC variants

文献	名称	描述
[11]	鲁棒模型预测控制(RMPC)	将鲁棒控制与 MPC 相结合，针对系统的扰动特性求解最优控制量，以此抵消极端工况带来的影响
[12]	随机模型预测控制(SMPC)	MPC 通过整合预测不确定性优化控制发生的概率，确定最优行动
[13]	自适应模型预测控制(AMPC)	根据控制对象和环境变化，自动调整控制器参数以优化性能，同时处理模型不确定性并实时更新模型
[14]	混合模型预测控制(HMPC)	控制连续、离散值的状态分量，运用动态切换与混合整数、二元整数等控制变量，发挥逻辑状态扩展能力，达成动态交互
[15]	数据驱动模型预测控制(Data-driven MPC)	通过使用现有的历史数据，使模型与数据高度覆盖所有可能的操作情况从而进行建模和预测。
[16]	基于占用的模型预测控制(Occupancy-based MPC)	通过测量居住者的行为信息，根据信息的占用状态调节室内温湿度，通过预测占用状态在入住之前达到设定的舒适度
[17]	分布式模型预测控制(DMPC)	将建筑动态解耦成许多可以独立求解的离散小方程来减少控制器的计算负担，可以减少控制系统建设成本。
[18]	经济模型预测控制(EMPC)	在模型预测控制应用于暖通空调系统时，当成本包含在目标函数中时，最优控制问题可以称为经济模型预测控制。

2.2　AMPC 和 Occupancy-based MPC

AMPC 在 RMPC 基础上进一步应对模型不确定性，主要解决建筑模型精细化和系统扰动问题。通常，AMPC 与 RMPC 结合使用，以提高系统性能。如 Yang 等[19]提出自适应鲁棒模型预测控制(ARMPC)通过引入自适应函数，利用在线建筑数据估计模型不确定参数，解决了参数不确定性问题。实验表明，ARMPC 相比恒温箱控制方法节能约 10%。

在建筑运行过程中居住者是建筑能耗的主要影响因素之一[7]，根据建筑的占用状态控制系统可以依据先前的入住率信息控制不同的设备。如根据入住率进行照明控制、根据入住率进行区域温度控制等[20]。Dobbs 等[21]将占用预测控制算法结合建筑热性能、天气预测和自调优占用模型，可减少空调系统能耗并保持舒适度。与传统方法相比，占用率模型无需手动调整，能适应占用模式变化，有效降低能耗。

AMPC 和 Occupancy-based MPC 均属于自适应控制技术，前者调整控制策略以应对环境变化，后者通过传感器优化室内设定，提升舒适性并处理不确定性。

2.3　HMPC 和 DMPC

随着建筑模型日益复杂，尤其在 MPC 控制问题中，涉及模型动态、目标与约束的复杂性日渐突出，导致在控制系统中常出现连续和离散的混合问题。为此，HMPC 成为解决这一类问题的有效方法[22]。Fiorentini 等[23]通过引入分级策略，将 HMPC 分为高级控制和多个低级控制层次，实现了系统的整体预测控制。结果表明，HMPC 在暖通空调系统中的应用取得了良好的效果。此外，在建筑能源管理中，为了优化能效与成本，HMPC 同样能有效处理涉及整数或二进制决策变量的控制与预测问题。

与此同时，当 MPC 应用于大规模、多区域建筑时，优化问题的规模变得非常庞大，并且计算难度较大[24]，此时需要使用 DMPC。例如 Scherer 等[25]采用一种分布式模型预测方案，用于建筑物内能量分布的高效管理，涉及可再生能源的生产及各个房间空调系统的能量配送。

HMPC 和 DMPC 是应对大型复杂建筑系统常用的控制方法，相较于传统 MPC，提高了系统稳定性并优化了计算时间。HMPC 基于线性模型，适用于工况相对较简单的场景；DMPC 则对非线性模型适应性更强。

2.4　Data-driven MPC 和 EMPC

模型预测控制提高了暖通空调系统的运行性能、节能水平与室内热舒适度，但仍面临滞后时长、热惯性以及外界不确定干扰等问题[26]。同时，模型预测准确性与数据质量密切相关，因此需要将优化算法与 MPC 结合。例如 Maddalena 等[2]以医院手术中心暖通空调系统为研究对象，采用高斯过程驱动的数据驱动模型(Data-driven MPC)方法，在保障室内热舒适指标的同时有效降低系统能耗。结果显示，该方法在保证系统功率稳定的前提下相校传统控制技术可降低 4.76%的电能消耗。

尽管常规 MPC 已实现一定的成本节约和优化，

但在暖通空调运行中仍需更低能耗、更低运维成本的控制方案,此时可以考虑采用经济模型预测控制(EMPC)。如 Vivian 等[27]通过实验验证 EMPC 方法,模拟屋顶光伏系统降低供暖成本,同时保证热舒适性。结果表明,相比传统控制系统可节省 10%~17%的电力。

Data-driven MPC 依托历史运行数据完成建模与滚动预测,全面提升系统运行稳态性能与综合能效;EMPC 以全周期能源经济性为优化目标,结合预测模型与智能优化算法,动态调整控制策略,在满足室内环境需求的同时实现深度节能降耗。

3 MPC 的建模方法

3.1 预测控制模型

暖通空调系统得到广泛应用,随着技术进步,MPC 建模方法不断改进以平衡系统节能性与舒适度。建筑的非线性特性和环境扰动增加了建模难度。MPC 控制以设备运行状态和温度设定为关注对象,输出为能耗与温度指标。考虑扰动、功耗与温度的建模较为复杂,且模型可能与系统不完全匹配,影响成本控制效果。因此,需根据实际特性优化建模方法以提高模型的准确性与可靠性。

MPC 控制方法主要是通过求解每个过程的最优控制模型、最小化成本函数,从而确定目标函数的动作,其目标函数及约束条件如下式[7]:

目标函数:

$$I(x) = \min \sum_{t=0}^{T-1} f(x_t, u_t) \tag{1}$$

初态:

$$x_0 = x \tag{2}$$

计算输出:

$$x_{t+1} = l(x_t, u_t),\ t \in \{1,2,\cdots,T\} \tag{3}$$

约束:

$$P_n(x_t, u_t) \leqslant 0,\ t \in \{1,2,\cdots,T\},\ n \in \{1,2,\cdots,N\} \tag{4}$$

式中:T 表示预测范围,t 表示采样时间(即 T 预测范围内的每个时间步长),式(1)为包含状态变量 x 与控制变量 u 的目标函数方程,l 是通过计算系统更新的状态变量函数,系统通过每个时间步 t 的状态更新实现滚动优化,P_n 为第 n 个系统约束函数,N 为约束条件的总数。

3.1.1 目标函数

前文提到的 8 种 MPC 变体中,目标函数的变化直接影响 MPC 功能。例如,当模型中包含扰动 d 时,传统 MPC 模型将成为鲁棒 MPC 或随机 MPC[7],当成本被计入目标函数时,MPC 优化控制问题可以称为经济 MPC[27]等,表 2 比较了几种 MPC 方法的目标函数差异。

表 2 不同 MPC 类型的目标函数

Table 2 Objective functions of different types of MPC

文献	能源成本	热舒适	温度	湿度/潜热	入住率/占用	居住者行为	储能系统	节能/%
[19]	★	★						10.0
[28]	★				★	★		25.0
[29]	★		★					35.1
[30]	★	★	★					7.7
[31]	★	★						13.4
[32]	★	★			★	★		30.0
[33]	★			★				9.5
[34]	★	★		★				5.0
[35]	★	★			★		★	3.8
[36]	★						★	34.0~42.0
[4]	★	★					★	46.6

MPC 控制以预测模型为基础,通过优化目标函数找到最优控制序列,目标函数直接决定系统的控制结果。在暖通空调系统中,目标函数需要平衡热舒适与能耗,确保控制方案的可行性与现实性。总体而言,目标函数的选择与优化对 MPC 效果至关重要。

3.1.2 约束条件

暖通空调系统会受到环境和天气等因素的干扰,存在不确定性。同时,系统具有多变量特性,需要同时对多个变量进行控制。模型预测控制(MPC)通过考虑这些不确定性和约束条件,能够优化控制策略,实现最佳控制效果。

MPC 中的约束可分为硬约束(需严格满足)和软约束(可提供灵活性,能针对目标调整)。然而,多输入控制和约束耦合问题会降低 MPC 计算效率,影响控制性能。因此,解决约束耦合问题是提升 MPC 性能的关键,表 3 总结了当前解决约束条件相互耦合的典型方法。

表 3　解决约束条件相互耦合的方法

Table 3　Methods to solve the coupling of constraints

文献	内容	结果
[37]	提出一种基于模糊模型的多变量预测控制方法，借鉴预测功能控制(PFC)原理，适用于强非线性、多变量和长传输延迟的过程	FMBMPC 算法相比 PI 方法，温度控制优于 12%，相对湿度控制优于 30%
[38]	采用灵活模块化的混合整数线性规划(MILP)模型，将复杂的非线性优化问题转化为计算上可分解的序列方法	MILP+MPC 将能耗降低 2.14%，且支持解耦控制
[39]	设计了一种加速分布式 MPC 的 HVAC 系统，考虑相邻区域热耦合，并通过鲁棒优化应对未知热扰动	数值仿真验证了分布式 MPC 算法的有效性，计算时间比集中式快近 20 s
[40]	提出了一种基于灵敏度分析的暖通空调建筑系统分解方法，考虑相邻子系统控制器的灵敏度和耦合信息，并制定了协调策略	可以适应不同系统成本函数的可分性和子系统之间的耦合
[41]	提出了一种新型多蒸发器冷却系统控制架构，采用灵活的两级结构，在两个级别应用模型预测控制实现各自目标	可以适应不同情况下的用户要求，同时提高能源效率
[42]	使用两级控制结构：嵌入模糊 MPC(FMPC)用于用户舒适度优化和一个整数 MPC (MI-MPC)能源供应优化	FMPC 控制的解耦在于能源供应和用户舒适度与单个节点耦合

3.1.3　模型的应用研究

MPC 的预测性依赖于动态建模来生成控制命令，因此，构建准确的模型对其至关重要。目标函数和约束条件反映了建模方法的多样性。然而，要确保模型的适用性和精度，必须通过实际验证来优化系统性能，只有这样，才能最大限度地提升运行效率。表 4 展示了不同 MPC 模型的应用效果。

暖通空调系统模型验证需要考虑控制效果、运行稳定性等多项目标与性能指标。可通过实验或仿真数据进行验证分析，确认模型是否符合要求并进行优化。验证优化过程通常需要经过多次迭代调整，最终既要确保模型满足既定性能要求，也要预留一定裕度，保障系统能够长期稳定运行。

表 4　不同 MPC 模型的应用效果

Table 4　Application effects of different MPC models

文献	使用的模型	内容	结果
[34]	数据驱动模型	开发了一个数据驱动的低阶模型，预测空气温湿度，并且开发了一个高精度的数据驱动模型模拟建筑。	与普通 MPC 相比，SMPC 能节省约 5%的能源。
[37]	T-S 模糊模型	建立 T-S 模糊模型，通过聚类和模糊识别工具箱由实测数据求取数学模型，并完成局部线性模型的参数聚类。	温度控制性能提高 12%，湿度控制提高 30%。
[43]	灰盒模型和神经网络	提出一种新型模型识别方法，处理建筑模型识别过程中占用引起的未测量热干扰，以实现 MPC 控制。	实现 4－5% 的额外能源成本节约。
[44]	非线性灰盒(RC)模型和线性 ARX 模型	比较了两种模型识别技术与 MPC 结合后的性能：ARX-MPC 线性模型和 RC-NMPC 非线性模型。	电能使用节能 10%～40%，热能使用节能 21%～55%。
[45]	瞬态灰盒模型	采用 MPC 控制器基于瞬变灰盒模型和分层控制体系结构，以满足热舒适同时最小化活跃的能量需求。	分层 MPC 架构的控制性能优于标准的 22.7%。
[46]	人工神经网络(ANN)	BNMI 算法通过多次迭代优化，提升了不同模型的拟合优度，预测性能提高了 6%－59%。	使用 ANN 模型后 MPC 节省 6%～73%的运营成本。
[31]	深度神经网络(DNN)	使用 DNN 开发了 10 个模拟模型：一个预测暖通空调系统的空气温度，而另一个预测 9 个区域的室内温度。	较基线周期的能耗降低了 35.1%。
[47]	非线性自回归神经网络(NARX)	提出了一种建模和优化技术，以优化暖通空调系统的控制，从而实现合适的室内环境条件和降低能源消耗。	可以降低总能量的 7.8%。

3.2　滚动优化算法

3.2.1　MPC 滚动优化过程

在模型预测控制中，滚动优化不同于离散最优控制，因为 MPC 不依赖固定全局最优目标，而是在每个时间步内通过有限时间窗口进行动态优化。如图 2 所示，滚动优化仅考量当前时刻到未来的有限

时域,且优化窗口会随着时间推移不断向前滑动。每一步 MPC 都会通过优化性能指标,计算得到当前的最优控制量,并在下次采样时调整策略。通过反馈修正机制,系统实时更新模型、完成在线优化,同时能够充分兼顾未来时域信息与系统不确定性。

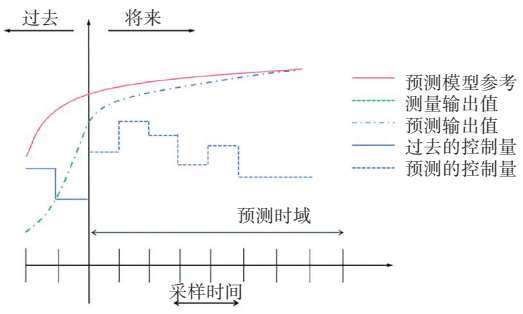


图 2 滚动优化过程

Fig. 2 Rolling optimization process

MPC 的滚动优化依赖于可靠的优化算法,该算法在众多备选方案中找到最优解。由于空调系统存在干扰且具有多个控制变量,其本身具备非线性特性,因此采用非线性控制方法更加适配。

这类优化方法通过高效筛选备选方案锁定最优解,避免穷举搜索。其性能依赖于温度、湿度、压力等控制变量,以及与 MPC 目标相关的经济性函数与舒适性函数。优化过程中需考虑能源消耗、温度偏差等约束条件,只有选择合适算法才能满足系统需求并优化整体性能。

3.2.2 滚动优化算法的应用研究

MPC 依赖滚动优化算法寻求最优控制,在暖通空调系统中选择合适的优化算法至关重要,既影响运行性能,也关系到运行效率,目前国内外使用算法与 MPC 的具体案例见表 5。

表 5 HVAC 系统中滚动优化算法的应用

Table 5 Application of rolling optimization algorithms in HVAC systems

文献	优化方法	内容	结果
[48]	贝叶斯算法(BO)	通过评估低复杂度 MPC 控制器的闭环性能构建参考模型,并在 BO 中使用该模型调优 MPC 控制器	将 BO 与参考模型相结合,减少 MPC 调优计算时间 28%以上
[49]	遗传算法(GA)	使用遗传算法优化的 MPC (MPC-GA),结合神经网络时间序列多元预测模型与 MPC 框架	MPC-GA 相比 RBC,能量消耗降低 50%,不适感减少 80%以上
[50]	拉格朗日对偶算法	通过一个非线性试验台模型分析了所提策略 PNMPC 控制器加拉格朗日对偶优化算法的有效性	PNMPC 能保持所有房间的热舒适性,使得 PMV 指标值低于 0.1
[51]	最速下降算法	通过基于梯度的技术最小化 PMV、CO2 浓度和冷热负荷,优化室内空气条件	实时检测室内空气,保持 PMV 和 CO2 理想水平,降低能耗
[52]	内点算法	采用多层感知算法对 HVAC 系统建模,结合 MLP 和约束条件构建优化模型,使用内点法求解	结果表明可节约能耗 20.15%同时提升室内舒适度
[53]	分支限界算法	使用分支限界算法分别用来优化多能互补系统的供水温度以及室内设定温度	减少了需要的电网高峰电力生产,并降低运营成本的 7.8%
[54]	动态规划算法	根据居住者行为模式和天气预测,建立 NMPC 方法,通过动态规划算法实时优化供水温度	在供暖季节,与传统预定温度设定相比,能量减少了 30.1%

表 5 列出了常用的滚动优化算法及其在 HVAC 系统中的应用。合理的算法选择不仅能够提升 MPC 的控制性能,还能有效解决节能与舒适度的冲突。遗传算法、粒子群算法、贝叶斯优化等智能优化方法广泛应用于 HVAC 系统,同时,最速下降法、牛顿法、动态规划等方法在约束优化和子问题分解中也起到了关键作用。

3.3 反馈矫正

MPC 是一种开环优化方法,但实际应用中系统普遍存在非线性、时变性及外部干扰等不确定性因素,容易引发预测偏差。为应对上述不确定性,MPC 引入反馈校正机制,通过比较输出与预测值,校正误差,从而提高精度并增强鲁棒性和抗干扰能力,实现从开环优化到闭环优化的转变。

常用的反馈矫正方法包括预测模型矫正和预测误差补偿。预测模型矫正通过调整模型参数或结构,依据实际测量与预测误差提升预测精度。在暖通空调系统中,该方法能提高室内温湿度预测准确性。但其性能受限于模型结构、参数选择和训练数据质量,设计时需避免过拟合或欠拟合问题。

预测误差补偿则是在保持模型不变的情况下,通过预测并补偿未来时刻的误差来提升预测精度和系统鲁棒性。常见的补偿方法包括基于历史数据的平滑校正、模型自适应校正以及滤波器补偿等。这

些方法通过减少预测误差的积累，从而提高控制系统的稳定性与整体控制性能。

4　MPC 运行性能的影响因素

MPC 作为一种带约束的最优控制策略，利用系统的数学模型、当前状态测量值与天气预报信息对建筑的未来运行状态进行预测与优化控制[55]，在优化控制输入方面取得了很好的效果。MPC 的性能受系统模型准确度、约束条件、外部扰动及优化目标等多因素共同影响。尽管已有研究针对上述影响因素展开了相关探讨，但目前该领域仍缺乏对这些影响因素的系统性总结梳理。

4.1　控制系统的复杂度和动态特性

暖通空调系统由于建筑的多样性与非线性限制，通常有多种不同的系统结构，所以导致控制系统的结构也具有多样性。常见结构可以分为分层、级联、集中、分散以及分布式结构。

采用分层和级联的控制器是最常见的方案，该结构能够有效缩减控制系统的模型规模，缩短计算时间。例如，Široký 等[56]使用模型预测控制与 PID 控制相结合的方法在保证满足所有舒适性要求的同时，最小化能耗（或运营成本）。Wallace 等[57]研究了空调系统蒸汽压缩循环（VCC）的控制，提出串级控制结构。外环使用 PI 控制送风温度，内环采用 ARX-MPC 控制压缩机转速和阀门开度。结果表明，MPC 比传统方法更优，能将 VCC 能量需求降低 16%。

多区域暖通空调系统能更准确描述各区域热响应。分散式 MPC 对每个区域独立控制，但该方案忽略了不同区域间的热耦合效应，导致温度波动和控制性能差。集中式 MPC 则考虑了区域间的热耦合，但该结构会增加计算负担，对硬件计算能力提出了更高考验。

4.2　采样时间和控制周期

MPC 通过预测系统行为并优化控制策略实现控制，其控制性能受采样时间与控制周期参数选择直接影响。采样时间决定了控制器更新系统状态的时间间隔，需要结合系统动态特性与硬件计算能力进行选择。采样时间过短会降低模型准确性，过长则会拖累系统响应速度，影响控制稳定性。Kvasnica 等[58]建议采样时间应为系统最小模态周期的 2~10 倍。

控制周期是 MPC 完成一次控制策略计算的间隔，需要在系统动态特性、控制目标与计算复杂度之间做好平衡。控制周期过短会增加计算量，过长则会降低系统响应速度、控制精度与整体稳定性。通常为采样时间的 2~5 倍[59]。

采样时间与控制周期需要结合具体应用场景的系统特性与控制目标灵活调整，一般通过仿真或试验确定最优取值，参数的合理选择能够有效提升系统的控制精度、稳定性与自动化运行效率。

4.3　模型精度和准确性

MPC 是一种基于动态数学模型的控制算法，通过预测系统响应实现优化控制。因此，其性能受建筑建模精度影响，因模型中的能耗通常与实际不符[60]。MPC 通过预测室内温湿度变化来优化能耗和舒适性，但其精度受限于模型的准确性。

前文已讨论了 MPC 在暖通空调系统中的建模方法以及模型在运行中的重要性，本文将重点分析模型精度和准确性带来的问题。如 Zhao 等[61]提出了一种基于预测负荷和时滞的 MPC 模型，结合 TRNSYS 与 MATLAB 仿真平台，提升系统稳定性和准确性，降低能耗，优化能源供需匹配，减少能量峰值和总能耗。

近年来，模型创建取得重大进展，提升了能耗控制，但几乎所有模型都存在缺陷，通常源于假设、未观测扰动或系统不确定性。MPC 模型的精度与多个因素相关，如模型误差、控制效果和预测准确度等。

5　MPC 在 HVAC 系统中的应用与测试

MPC 作为一种出色的控制方法在各行各业中应用广泛，已有超过 2 000 套搭载 MPC 的工业装置方案，是当前过程控制策略中应用最广泛的技术[62]。MPC 通过建模与预测精确控制室内温湿度，提升能效与舒适性。为优化控制效果，需要通过仿真模拟与实验验证 MPC 模型，二者各有优缺点。当前，关于 MPC 在 HVAC 系统中的应用，国内外研究可分为两类。早期研究主要集中在软件仿真模拟，而近年来，随着研究的深入，更多的实验验证和案例研究突显了 MPC 在节能与控制方面的巨大优势。

5.1　仿真试验

MPC 在暖通空调中的研究主要集中于能耗调节和运行成本节约。与传统规则控制器相比，MPC 能同时满足低能耗、热舒适性和室内空气质量等冲突目标。然而，国内外研究大多停留在实验模拟阶段，且主要集中在办公室、学校等建筑，表 6 对现有相关仿真试验及对应结果进行了归纳总结。

从使用的仿真模拟软件来看，MATLAB 和

EnergyPlus 居多,具体使用哪种软件取决于应用场景和需求,不同软件具有不同的优劣势。因此,需要根据实际情况和具体需求选择合适的软件进行仿真和应用。

5.2 实际试验

在暖通空调系统中,MPC 控制器需根据不同建筑类型进行调整,以提高模型的适应性,表 7 展示了 MPC 在不同建筑中的应用效果。

表 6 MPC 仿真试验及结果

Table 6 MPC simulation test and results

文献	建筑类型	仿真模拟软件	模型	优化方法	特点	结果
[35]	高校建筑	JModelica	非线性模型	非线性 MPC	提出的 MPC 将建筑热质量作为 TES 进行	负载减少 8.8%,热量节省 2.8%。
[37]	工厂建筑	MATLAB/Simulink	模糊模型	FMBMPC	有效解决受控变量是耦合问题	保持很好的温度调节
[44]	教育建筑	Python	RC 和 ARX	ARX-MPC、RC-NMPC	可以控制室内温度和二氧化碳浓度	不能使用到其他建筑物上
[63]	大型建筑物	EnergyPlus	LP 和 MILP	滚动时域控制 MPC 策略	从原始舒适度约束无法满足的快速恢复	可以有效地应用于大规模应用
[64]	公共建筑	EnergyPlus	线性和非线性回归	Raspberry Pi 嵌入式系统	预测精度高,节能效果好	节能 30%
[65]	资料室	Simulink	NRE 模型	MPC	简化模型得到的结果的准确性很高	优化后的供液温度比优化前稳定
[66]	太阳能房屋	EnergyPlus	物理模型	动态规划算法	光伏组件集替代瓦片或覆层材料	验证了预测控制策略在太阳能房中的应用

表 7 MPC 在不同建筑中的应用

Table 7 Application of MPC in different buildings

文献	年份	建筑类型	模型	优化方法	特点	结果
[36]	2019	办公建筑	MicroCSP 系统的数学模型		MPC 设计用于优化控制 TES	节省了 37%的能源
[49]	2021	多区域建筑	神经网络 CAM- LSTM 模型	MPC-GA	计算时间减少	能量消耗和不适感分别降低了 50% 和 80% 以上
[67]	2022	商业建筑	低阶线性模型(ARX 模型)	基于云计算的监控平台	适用于所有的现代建筑管理系统,前期投资少	与基线相比改善了 1.7%的经济成本
[68]	2022	办公建筑	灰盒模型	MPCPy	在实际建筑中实现 MPC 的可行性	节省了约 40%的能量
[69]	2015	住宅建筑	自适应模型	NiQ	减小预测误差	平均节能 0.28%
[56]	2011	高校建筑	RC 建模、计算机辅助建模工具		MPC 主要在夜间预热混凝土降低能量峰值	节能潜力在 15% 至 28% 之间
[70]	2010	多区域建筑	过程模型	DMPC	在房间空置时不施加特定的温度设定值	验证了分布式 MPC 算法性能

尽管目前 MPC 控制系统在暖通空调领域已经开展了部分实测研究,但受实际实验中各类不确定性因素影响,其实际控制效果往往不及仿真模拟结果,因此 MPC 目前尚未在暖通空调领域实现广泛应用,现有相关研究也大多局限于小型实验室场景或特定建筑中。综上,仿真模拟具备便捷、低成本的优势,更适合用于模型优化;而实物实验更贴近实际应用场景,能够更好地适配不同建筑的实际需求。

6　结束语

模型预测控制应用于暖通空调系统，核心目标是平衡能源消耗与室内舒适性，进而实现系统能效与用户体验的双重提升，过去 20 年，MPC 在 HVAC 控制领域的研究不断深入，通过对不同控制变体的比较与分析，明确了不确定性因素对 MPC 控制效果的影响。本文梳理总结了 HVAC 系统建模的主要方法和分类，为后续的控制优化提供理论基础。同时，本文分析了不同算法的表现与适用场景，并比较了各类测试方法的优缺点。

然而，MPC 在 HVAC 系统中的应用仍存在一定的局限性，尤其是实验研究多集中于特定的环境设置。当前的研究主要聚焦于住宅和办公室建筑，针对大空间、综合性建筑以及医院等类型的应用研究较少。应对大规模建筑的复杂性和多样性，是 MPC 未来发展的重要挑战之一。此外，MPC 与楼宇自动化控制的结合尚处于初步阶段，而将 MPC 与 BAS 结合，挖掘其节能潜力，仍有待进一步探索。

参考文献

[1] Afram A, Janabi-sharifi F. Theory and applications of HVAC control systems-A review of model predictive control [J]. Building and Environment, 2014, 72: 343-355.

[2] Maddalena E T, Müller S A, Dos Santos R M, et al. Experimental data-driven model predictive control of a hospital HVAC system during regular use [J]. Energy and Buildings, 2022, 271: 112316.

[3] Ma S, Zou Y, Li S. Distributed model predictive control with priority coordination for limited supply multi-zone HVAC systems [J]. Journal of Process Control, 2022, 117: 157-168.

[4] Wang X, Liu Y, Xu L, et al. A chance-constrained stochastic model predictive control for building integrated with renewable resources [J]. Electric Power Systems Research, 2020, 184: 106348.

[5] Arroyo J, Manna C, Spiessens F, et al. Reinforced model predictive control for building energy management [J]. Applied Energy, 2022, 309: 118346.

[6] Yao Y, Shekhar D K. State of the art review on model predictive control in Heating Ventilation and Air-Conditioning field [J]. Building and Environment, 2021, 200: 107952.

[7] Taheri S, Hosseini P, Razban A. Model predictive control of heating, Ventilation, and Air Conditioning systems: A state-of-the-art review [J]. Journal of Building Engineering, 2022, 60: 105067.

[8] Solopert R, Müller M A, Trimpe S, et al. Learning-based robust model predictive control with state-dependent uncertainty [J]. IFAC-PapersOnLine, 2018, 51(20): 442-447. DOI:10.1016/J.IFACOL.2018.11.052.

[9] Chisci L, Rossiter J A, Zappa G. Systems with persistent disturbances: Predictive control with restricted constraints [J]. Automatica, 2001, 37(7): 1019-1028.

[10] Liu X, Paritosh P, Awalgaonkar N M, et al. Model predictive control under forecast uncertainty for optimal operation of buildings with integrated solar systems [J]. Solar Energy, 2018, 171: 953-970.

[11] Cai S, Xie Y, Wu Q, et al. Robust MPC-based microgrid scheduling for resilience enhancement of distribution system [J]. International Journal of Electrical Power & Energy Systems, 2020, 121: 106068.

[12] Zhang Y, Meng F, Wang R, et al. Uncertainty-resistant stochastic MPC approach for optimal operation of CHP microgrid [J]. Energy, 2019, 179: 1265-1278.

[13] Ooi S E, Fang Y, Lim Y, et al. Study of adaptive model predictive control for cyber-physical home systems [C]// Proceedings of the Lecture Notes in Electrical Engineering. 2019. 183-193.

[14] Li Z, Zhang J. Study on the distributed model predictive control for multi-zone buildings in personalized heating [J]. Energy and Buildings, 2021, 231: 110627.

[15] Paschke F, Huang C, Seidel S. MPC design for an auditorium building using data driven modeling [J]. IFAC-PapersonLine, 2022, 55(20): 103-108.

[16] Esrafilian-Najafabadi M, Haghighat F. Towards self-learning control of HVAC systems with the consideration of dynamic occupancy patterns: Application of model-free deep reinforcement learning [J]. Building and Environment, 2022, 226: 109747.

[17] Tabacek J, Havlena V. Distributed state estimation and fault diagnosis using reduced sensitivity to neighbor estimates with application to building control [J]. Journal of the Franklin Institute, 2023: 360 (12): 9216 - 9239. DOI: 10.1016/J.JFRANKLIN.2022.10.017.

[18] Adeodu O, Omell B, Chmielewski D J. On the theory of economic MPC: ELOC and approximate infinite horizon EMPC [J]. Journal of Process Control, 2019, 73: 19-32.

[19] Yang S, Wan M P, Chen W, et al. An adaptive robust model predictive control for indoor climate optimization and uncertainties handling in buildings [J]. Building and Environment, 2019, 163: 106326.

[20] Esrafilian-Najafabadi M, Haghighat F. Occupancy-based HVAC control systems in buildings: A state-of-the-art review [J]. Building and Environment, 2021, 197: 107810.

[21] Dobbs J R, Hencey B M. Model predictive HVAC control with online occupancy model [J]. Energy and Buildings, 2014, 82: 675-684.

[22] Pataro I M L, Gil J D, Guzmán J L, et al. Hierarchical control based on a hybrid nonlinear predictive strategy for a solar-powered absorption machine facility [J]. Energy, 2023, 271: 126964. DOI:10.1016/j.energy.2023126964.

[23] Fiorentini M, Cooper P, Ma Z, et al. Hybrid model predictive control of a residential HVAC system with PVT energy generation and PCM thermal storage [J]. Energy Procedia, 2015, 83: 21-30.

[24] Mork M, Xhonneux A, Müller D. Nonlinear distributed model predictive control for multi-zone building energy systems [J]. Energy and Buildings, 2022, 264: 112066.

[25] Scherer H F, Pasamontes M, Guzmán J L, et al. Efficient building energy management using distributed model predictive control [J]. Journal of Process Control, 2014, 24(6): 740-749.

[26] Ala′raj M, Radi M, Abbod M F, et al. Data-driven based HVAC optimisation approaches: A systematic literature review [J]. Journal of Building Engineering, 2022, 46: 103678.
[27] Vivian j, Croci 1, Zarrella A. Experimental tests on the performance of an economic model predictive control system in a lightweight building [J]. Applied Thermal Engineering, 2022, 213: 118693.
[28] Jazizadeh F, Joshi V, Battaglia F. Adaptive and distributed operation of HVAC systems: Energy and comfort implications of active diffusers as new adaptation capacities [J]. Building and Environment, 2020, 186: 107089.
[29] 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.
[30] Mahmood F, Govindan R, Bermac A, et al. Energy utilization assessment of a semi-closed greenhouse using data-driven model predictive control[J]. Journal of Cleaner Production, 2021, 324: 129172.
[31] Bünning F, Warrington J, Heer P, et al. Robust MPC with data-driven demand forecasting for frequency regulation with heat pumps[J]. Control Engineering Practice, 2022, 122: 105101.
[32] Mirakhorli A, Dong B. Occupancy behavior based model predictive control for building indoor climate: A critical review [J]. Energy and Buildings, 2016, 129: 499-513.
[33] Jiang Y, Wang X, Zhao H, et al. Dynamic modeling and economic model predictive control of a liquid desiccant air conditioning[J]. Applied Energy, 2020, 259: 114174.
[34] Raman N S, Devaprasad K, Chen B, et al. Model predictive control for energy-efficient HVAC operation with humidity and latent heat considerations [J]. Applied Energy, 2020, 279: 115765.
[35] Hou J, Li H, Nord N. Nonlinear model predictive control for the space heating system of a university building in norway [J]. Energy, 2022, 253: 124157.
[36] Toub M, Reddy C R, Razmara M, et al. Model-based predictive control for optimal Micro CSP operation integrated with building HVAC systems[J]. Energy Conversion and Management, 2019, 199: 111924.
[37] Preglej A, Rehrl J, Schwingshackl D, et al. Energy-efficient fuzzy model-based multivariable predictive control of a HVAC system[J]. Energy and Buildings, 2014, 82: 520-533.
[38] Dullinger C, Struckl W, Kozek M. A general approach for mixed-integer predictive control of HVAC systems using MILP [J]. Applied Thermal Engineering, 2018, 128: 1646-1659.
[39] Chen L, Zhang Y. Accelerated distributed model predictive control for HVAC systems [J]. Control Engineering Practice, 2021, 110: 104782.
[40] Darure T, Puig V, Yamé J, et al. Distributed model predictive control applied to a VAV based HVAC system based on sensitivity analysis[J]. IFAC-PapersOnLine, 2018, 51(20): 259-264.
[41] Elliott M S, Rasmussen B P. Decentralized model predictive control of a multi-evaporator air conditioning system[J]. Control Engineering Practice, 2013, 21(12): 1665-1677.
[42] Killian M, Mayer B, Kozek M. Hierachical fuzzy MPC concept for building heating control [J]. IFAC Proceedings Volumes, 2014, 47(3): 12048-12055.
[43] Kumar P, Rawlings J B, Wenzel M J, et al. Grey-box model and neural network disturbance predictor identification for economic MPC in building energy systems [J]. Energy and Buildings, 2023, 286: 112936.
[44] Merema B, Saelens D, Breesch H. Demonstration of an MPC framework for all-air systems in non-residential buildings [J]. Building and Environment, 2022, 217: 109053.
[45] De Araujo Passos L A, Ceha T J, Baldi S, et al. Model predictive control of a thermal chimney and dynamic solar shades for an all-glass facades building [J]. Energy, 2023, 264: 126177.
[46] Afram A, Janabi-Sharifi F, Fung A S, et al. Artificial neural network (ANN) based model predictive control (MPC) and optimization of HVAC systems: A state of the art review and case study of a residential HVAC system[J]. Energy and Buildings, 2017, 141: 96-113.
[47] Afroz Z, Shafiullah G M, Urmee T, et al. Predictive modelling and optimization of HVAC systems using neural network and particle swarm optimization algorithm[J]. Building and Environment, 2022, 209: 108681.
[48] Lu Q, González L D, Kumar R, et al. Bayesian optimization with reference models: A case study in MPC for HVAC central plants [J]. Computers & Chemical Engineering, 2021, 154: 107491.
[49] Mtibaa F, Nguyenk K, Dermardiros V, et al. Context-aware model predictive control framework for multi-zone buildings[J]. Journal of Building Engineering, 2021, 42: 102340.
[50] Álvarez J D, Redondo J L, Camponogara E, et al. Optimizing building comfort temperature regulation via model predictive control[J]. Energy and Buildings, 2013, 57: 361-372.
[51] Atthajariyakul S, Leephakpreeda T. Real-time determination of optimal indoor-air condition for thermal comfort, air quality and efficient energy usage[J]. Energy and Buildings, 2004, 36(7): 720-733.
[52] Kusiak A, Xu G, Zhang Z. Minimization of energy consumption in HVAC systems with data-driven models and an interior-point method[J]. Energy Conversion and Management, 2014, 85: 146-153.
[53] Weeratunge H, Narsilio G, De Hoog J, et al. Model predictive control for a solar assisted ground source heat pump system[J]. Energy, 2018, 152: 974-984.
[54] Dong B, Lam K P. A real-time model predictive control for building heating and cooling systems based on the occupancy behavior pattern detection and local weather forecasting [J]. Building Simulation, 2014, 7(1): 89-106.
[55] Drgoňa J, Arroyo J, Cupeiro Figueroa I, et al. All you need to know about model predictive control for buildings[J]. Annual Reviews in Control, 2020, 50: 190-232.
[56] Široký J, Oldewurtel F, Cigler J, et al. Experimental analysis of model predictive control for an energy efficient building heating system[J]. Applied Energy, 2011, 88(9): 3079-3087.
[57] Wallace M, Mcbride R, Aumi S, et al. Energy efficient model predictive building temperature control[J]. Chemical Engineering Science, 2012, 69(1): 45-58.
[58] Kvasnica M, Kouvaritakis B, Baotic J. Sampling time selection for model predictive control [J]. IEEE Transactions on Control Systems Technology, 2008, 16(1): 54-65.
[59] Maestre J M, Sala A. Model predictive control with a fixed sampling time: A survey [J]. IFAC-PapersOnLine, 2017, 50 (1): 8443-8448.

[60] Brandi S, Fiorentini M, Capozzoli A. Comparison of online and offline deep reinforcement learning with model predictive control for thermal energy management[J]. Automation in Construction, 2022, 135: 104128.

[61] Zhao J, Li J, Shan Y. Research on a forecasted load-and time delay-based model predictive control (MPC) district energy system model[J]. Energy and Buildings, 2021, 231: 110631.

[62] Qin S J, Badgwell T A. A survey of industrial model predictive control technology[J]. Control Engineering Practice, 2003, 11(7): 733-764.

[63] Bianchini G, Casini M, Pepe D, et al. An integrated model predictive control approach for optimal HVAC and energy storage operation in large-scale buildings[J]. Applied Energy, 2019, 240: 327-340.

[64] Aftab M, Chen C, Chau C K, et al. Automatic HVAC control with real-time occupancy recognition and simulation-guided model predictive control in low-cost embedded system[J]. Energy and Buildings, 2017, 154: 141-156.

[65] Karlsson H, Hagentoft C E. Application of model based predictive control for water-based floor heating in low energy residential buildings[J]. Building and Environment, 2011, 46(3): 556-569.

[66] Candanedo J A, Athienitis A K. Predictive control of radiant floor heating and solar-source heat pump operation in a solar house[J]. HVAC & R Research, 2011, 17(3): 235-256.

[67] Bird M, Daveau C, O'dwyer E, et al. Real-world implementation and cost of a cloud-based MPC retrofit for HVAC control systems in commercial buildings[J]. Energy and Buildings, 2022, 270: 112269.

[68] Blum D, Wang Z, Weyandt C, et al. Field demonstration and implementation analysis of model predictive control in an office HVAC system[J]. Applied Energy, 2022, 318: 119104.

[69] LindelöPf D, Afshari H, Alisafaae M, et al. Field tests of an adaptive, model-predictive heating controller for residential buildings[J]. Energy and Buildings, 2015, 99: 292-302.

[70] Moroşan P D, Bourdais R, Dumur D, et al. Building temperature regulation using a distributed model predictive control[J]. Energy and Buildings, 2010, 42(9): 1445-1452.