

基于模型预测控制与粒子群优化的雾化喷药控制方法研究

沈珈毅¹, 黄金城^{1*}, 王杰文², 史博文¹, 纪昊文¹, 张恩瑜³

¹盐城工学院信息工程学院, 江苏 盐城

²宾夕法尼亚州立大学计算机科学与工程系, 美国 斯泰特科利奇

³盐城师范学院历史与公共管理学院(法学院), 江苏 盐城

收稿日期: 2026年4月25日; 录用日期: 2026年5月18日; 发布日期: 2026年5月25日

摘要

传统喷药系统存在控制精度低、响应滞后及抗扰动能力不足等问题, 本研究提出了一种基于模型预测控制(Model Predictive Control, MPC)与粒子群优化(Particle Swarm Optimization, PSO)融合的智能雾化喷药控制系统。首先, 将该系统建立为二阶动力学模型, 建立其状态空间模型并描述喷雾浓度的动态变化过程; 其次, 构建MPC控制器, 通过滚动优化策略实现对系统输出的动态调节; 在此基础上, 构建多性能指标, 诸如均方误差、超调量和控制能量。引入PSO算法对MPC关键参数进行全局优化。最后, 在MATLAB环境下进行仿真实验, 结果表明, 该方法在跟踪精度、超调量及控制平滑性方面均优于单一MPC及开环控制策略, 但在控制能量方面略有增加。MPC + PSO的均方误差(MSE)为0.0409, 单一MPC和开环控制分别为0.0482和0.0655; MPC + PSO的超调量(overshoot)为21.65, 单一MPC和开环控制分别为25.37和35.12; MPC + PSO的能量(energy)为30.26, 单一MPC和开环控制分别为29.54和28.47。

关键词

MPC, PSO, 雾化喷药, 最优控制方法

A Model Predictive Control-Particle Swarm Optimization Integrated Approach for Atomized Spraying Control

Jiayi Shen¹, Jincheng Huang^{1*}, Jiewen Wang², Bowen Shi¹, Haowen Ji¹, Enyu Zhang³

¹School of Information Engineering, Yancheng Institute of Technology, Yancheng Jiangsu

²Department of Computer Science and Engineering, The Pennsylvania State University, State College, USA

³School of History and Public Administration (School of Law), Yancheng Teachers University, Yancheng Jiangsu

*通讯作者。

文章引用: 沈珈毅, 黄金城, 王杰文, 史博文, 纪昊文, 张恩瑜. 基于模型预测控制与粒子群优化的雾化喷药控制方法研究[J]. 建模与仿真, 2026, 15(5): 94-105. DOI: 10.12677/mos.2026.155074

Abstract

Traditional spraying systems suffer from problems such as low control accuracy, response delay, and insufficient disturbance rejection capability. To address these issues, this study proposes an intelligent atomization spraying control system based on the integration of Model Predictive Control (MPC) and Particle Swarm Optimization (PSO). First, the system is modeled as a second-order dynamic system, and a state-space model is established to describe the dynamic variation process of spray concentration. Second, an MPC controller is designed to achieve dynamic regulation of system output through a rolling optimization strategy. On this basis, multiple performance indices, including mean square error, overshoot, and control energy, are constructed. The PSO algorithm is then introduced to globally optimize the key parameters of the MPC controller. Finally, simulation experiments are conducted in the MATLAB environment. The results demonstrate that the proposed method outperforms both the standalone MPC and open-loop control strategies in terms of tracking accuracy, overshoot suppression, and control smoothness, although it slightly increases control energy consumption. Specifically, the mean square error (MSE) of MPC + PSO is 0.0409, compared with 0.0482 for standalone MPC and 0.0655 for open-loop control. The overshoot of MPC + PSO is 21.65, while standalone MPC and open-loop control achieve 25.37 and 35.12, respectively. In terms of energy consumption, MPC + PSO reaches 30.26, whereas standalone MPC and open-loop control consume 29.54 and 28.47, respectively.

Keywords

Model Predictive Control (MPC), Particle Swarm Optimization (PSO), Atomized Spraying Control, Optimal Control Method

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

三十多年来, 模型预测控制的理论和技术三十多年来, 得到了长足的发展, 但面对经济社会迅速发展对约束优化控制提出的不断增长的要求, 现有的模型预测控制理论和技术仍面临着巨大挑战[1]。随着现代农业智能化的发展, 精准喷药技术逐渐成为提高农作物产量和减少农药浪费的重要手段。传统喷药系统多采用开环或简单反馈控制方式, 存在控制精度低、响应速度慢以及对外界扰动敏感等问题, 难以满足复杂环境下的精准喷洒需求。

近年来, 智能控制技术在工业过程控制、机器人控制以及无人系统等领域得到了广泛应用。其中, 基于模型的预测控制是一系列先进的控制方法, 它利用过程模型来预测被控系统的未来行为。MPC 通过求解一个(可能受约束的)优化问题, 隐式地确定控制律[2]。然而, MPC 控制性能在很大程度上依赖于其参数设置, 如预测时域、控制时域以及权重系数等, 这些参数通常难以通过经验进行最优选取。

为了进一步提升控制性能, 粒子群优化算法被引入到控制系统参数优化中。粒子群优化(PSO)算法是一类随机全局优化技术, PSO 算法通过粒子间的相互作用发现复杂搜索空间中的最优区域。粒子群优化算法最初由 J. 等人在 1995 年提出, 随后被广泛应用于各种模型预测控制[3]。PSO 的优势在于简单容易实现而又功能强大, 且 PSO 已成为国际演化计算界研究的热点[4]。

随着智能优化算法的发展，粒子群优化与模型预测控制相结合的方法在复杂过程控制领域受到了广泛关注。相关研究显示，基于 PSO 优化的 MPC 在能源系统中被应用于光伏逆变器控制和最大功率跟踪，提高系统的响应速度和能量利用效率。MPC 能够在多约束条件下对农业系统进行动态优化控制，在农业自动化规划等方面具有良好的应用前景。Ryohei 等人曾提出了一种基于粒子群优化的模型预测控制自动参数整定方法，可在各种工业应用中实现实际控制[5]。Li 等人针对汽车主动悬架系统在复杂路况下的多目标协同优化问题，提出了一种基于粒子群优化算法的模型预测控制策略[6]。Erion Bwambale 等人探讨了 MPC 与精准农业机械的集成及其在自主农业系统中的作用。通过成功案例和案例研究，展示了 MPC 在实际应用中的积极作用，以及其对作物产量、资源利用和经济效益的显著影响[7]。Xu 等人针对传统模型预测控制难以适应果园等复杂工况下铰接式转向拖拉机的问题，本文提出了一种改进的 MPC 控制策略，该策略利用粒子群优化算法优化权重[8]。然而，现有研究大多集中于路径控制和资源调度等问题，针对喷药过程这一具有强非线性、时变性且受外界扰动显著的控制场景，相关研究相对有限。

本研究则提出一种基于 MPC 与 PSO 融合的智能雾化喷药控制方法。首先，构建雾化喷药系统的动态模型，其次，设计 MPC 控制器实现对喷雾浓度的精准调节，然后利用 PSO 算法对 MPC 关键参数进行优化，最后，通过仿真实验验证所提方法的有效性。研究结果表明，该方法能够显著提高系统响应速度，降低超调量，并增强系统的抗干扰能力，见图 1。

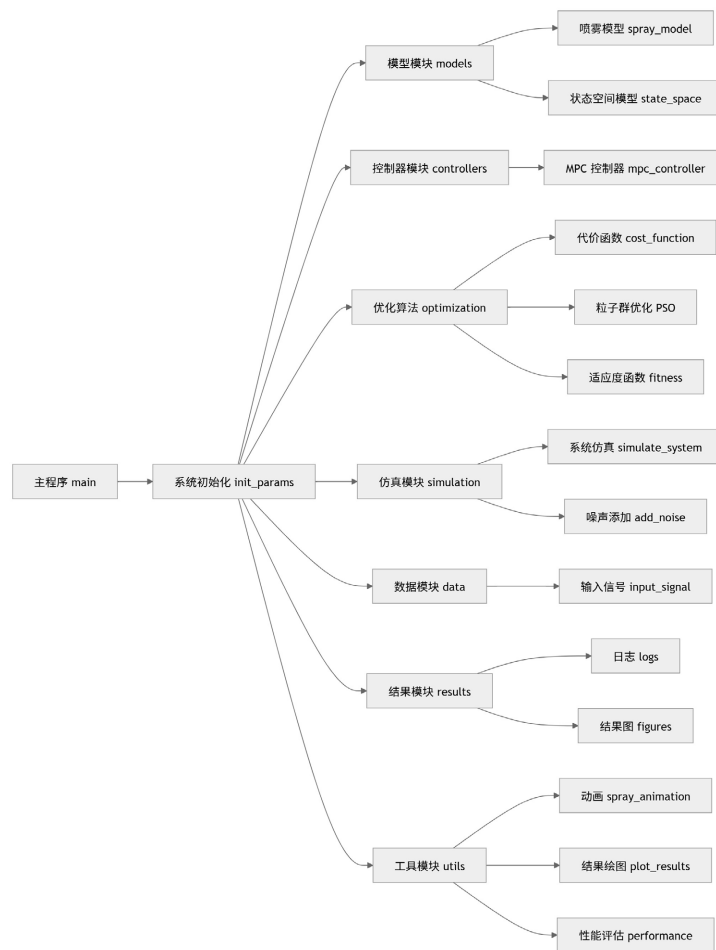


Figure 1. Algorithm framework
图 1. 算法框架结构

2. 系统建模

2.1. 系统背景与建模假设

本研究对所研究的雾化喷药系统进行了数学抽象, 将其建模为一个典型的二阶惯性系统, 如图 2 所示。在该模型中, 我们定义了以下状态变量来表征系统的内部特性:

$$x_1(t) = y(t), x_2(t) = \dot{y}(t)$$

系统的动态行为由以下状态方程进行描述:

$$\begin{cases} \dot{x}_1 = x_2 \\ \dot{x}_2 = -\frac{2\zeta}{T}x_2 - \frac{1}{T^2}x_1 + Ku + d(t) \end{cases}$$

其中: x_1 代表系统的喷雾浓度输出, x_2 表示浓度的瞬时变化速率, u 是系统的控制输入量(对应于喷药操作的强度), K 为系统的增益系数, T 是系统的时间常数, ζ 反映了系统的阻尼特性, $d(t)$ 则代表了作用在系统上的外界环境或未建模因素所带来的随机扰动。

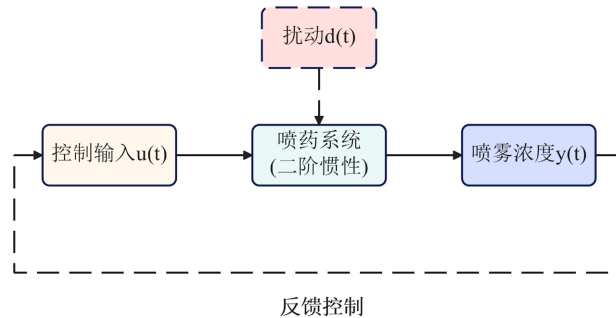


Figure 2. Schematic diagram of the atomized spraying system
图 2. 雾化喷药系统结构示意图

2.2. 系统数学模型

对于上述扰动项, 进一步将其建模为一个具有特定统计特性的随机过程:

$$d(t) = A \sin(\omega t) + n(t)$$

其中 $n(t)$, 代表一个均值为零、方差恒定的高斯白噪声过程, 用以模拟环境中的随机干扰。通过对上述连续时间系统进行离散化处理, 可以得到适用于模型预测控制算法框架的离散时间模型。

为了准确描述系统的动态特性, 通常可将其近似为一个典型的二阶惯性环节, 能够有效地捕捉系统的关键动态响应模式。该二阶惯性环节的传递函数可以具体表示为:

$$G(s) = \frac{K}{T^2 s^2 + 2\zeta Ts + 1}$$

其中, K 为系统增益, 反映了系统稳态输出与输入之间的比例关系; T 为时间常数则决定了系统响应速度的快慢, 体现了系统惯性的尺寸; 阻尼比 ζ 是描述系统振荡特性与稳定性的关键参数, 它影响系统的响应形态, 例如是否振荡及振荡的衰减程度。

2.3. 离散化模型

本研究将原始的系统模型从连续时间域转换到离散时间域, 并设置采样时间为 0.1 秒, 将其表述为

离散状态空间模型的形式:

$$\begin{aligned}x(k+1) &= A_d x(k) + B_d u(k) \\ y(k) &= Cx(k)\end{aligned}$$

在该离散状态空间模型中, $x(k)$ 通常用符号表示系统的状态变量, $u(k)$ 它包含了描述系统动态行为所需的关键信息; 符号代表系统的控制输入, $y(k)$ 即外部施加的作用信号; 而符号则对应系统的输出变量, 反映了实际观测或关注的系统响应。

离散化的过程与系统的采样时间 T_s 紧密相关, 其离散状态矩阵可以通过以下形式进行表达:

$$\begin{aligned}A_d &= e^{AT_s} \\ B_d &= \int_0^{T_s} e^{A\tau} B d\tau\end{aligned}$$

通过上述离散化处理, 系统模型可直接应用于模型预测控制框架中, 用于未来输出预测与优化控制输入的计算, 如图 3。

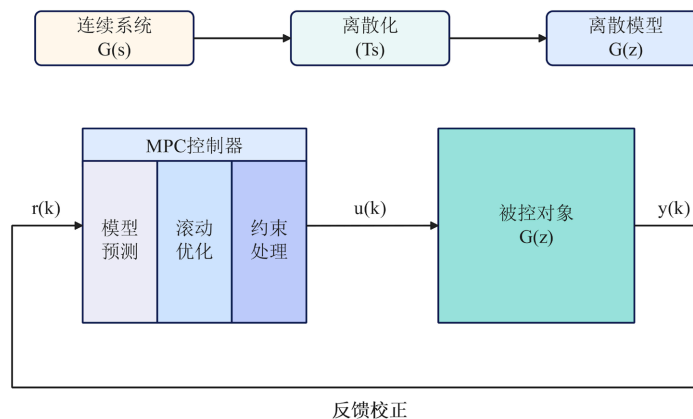


Figure 3. Schematic diagram of system discretization and MPC predictive control structure
图 3. 系统离散比与 MPC 预测控制结构图

3. 控制器的设计

3.1. MPC 控制器设计

3.1.1. MPC 基本原理

模型预测控制是一种基于数学模型的先进控制策略。其基本原理为: 在每一采样时刻, 系统会依据当前状态测量值及内部预测模型, 预测未来一段时间内(即预测时域)的过程输出或状态轨迹。随后, 控制器通过在线求解一个有限的时域最优控制问题来计算一系列未来的最优控制输入序列。该优化问题的目标通常是最小化一个包含跟踪误差、控制量变化以及约束违反惩罚等项的性能指标, 同时还需满足系统中各种过程约束(如输入输出幅值限制、速率限制等)。然而, MPC 并非将整个计算出的未来控制序列全部实施于被控对象, 而仅实施当前时刻的第一个控制量。至下一采样时刻, 系统将基于新的测量数据更新状态信息, 并重复上述预测、优化与滚动实施的过程。这种“滚动时域”的优化机制, 可以让 MPC 能够持续利用实时反馈信息来校正模型失配与外界扰动带来的影响。

3.1.2. 预测模型建立

本研究采用模型预测控制的方法, 通过对未来输出进行预测, 实现对系统的优化控制。其预测模型

可表示为:

$$Y = Fx(k) + \Phi U$$

其中, Y 为未来输出序列, U 为控制序列。

3.1.3. 目标函数设计

模型预测控制的核心目标在于通过在线求解一个有限时域内的优化问题来生成控制指令。其目标函数可具体表述为:

$$J = \sum_{k=1}^{N_p} (y_k - r)^2 + \lambda \sum_{k=1}^{N_c} u_k^2$$

其中: N_p 表示预测时域, N_c 它决定了控制器对未来系统状态进行预测的时间范围; 表示控制时域, λ 它限定了优化问题中控制序列的长度。

通过构建系统的预测模型矩阵, 可以将动态优化问题转化为一个标准的二次规划形式。在此基础上, 可推导出最优控制序列的解析解表达式:

$$U = (H^T Q H + R)^{-1} H^T Q (R - Fx)$$

在实际运行中, 控制系统并非一次性执行整个优化得到的控制序列。相反, 它在每个采样时刻仅执行序列中的第一个控制量, 然后在下一个采样时刻基于最新的系统状态测量值重新进行预测和优化计算。这种策略被称为滚动优化, 它使控制器能够持续地适应系统的实时变化并补偿外部扰动。

3.2. PSO 优化设计

3.2.1. PSO 算法原理

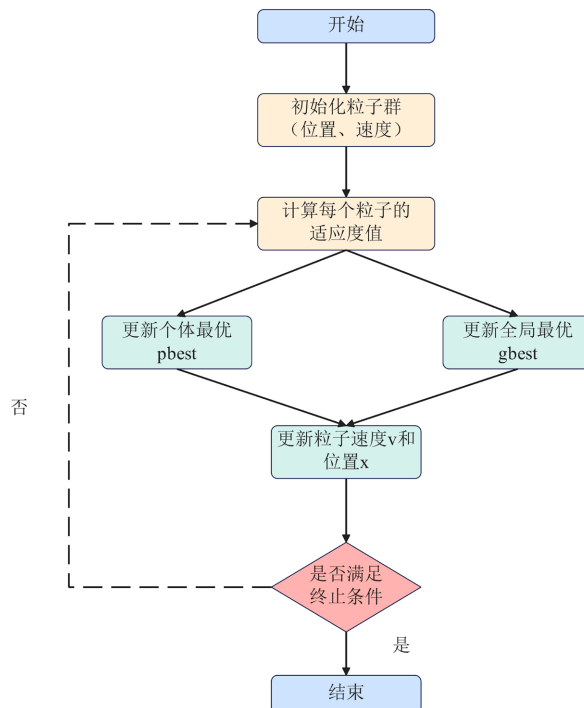


Figure 4. Flowchart of the Particle Swarm Optimization (PSO) algorithm
图 4. 粒子群优化(PSO)算法流程图

粒子群优化算法中的关键参数设定为：种群规模 N_p ， N_p 最大迭代次数 λ 。为评估粒子所代表解的质量，适应度函数被定义为：

$$J = \sum e^2 + 0.1 \sum u^2 + 0.5 \sum (\Delta u)^2$$

该函数的值直接反映了对应参数组合下控制系统的性能优劣。优化过程中，每个粒子根据个体历史最优位置和群体全局最优位置，按照特定的速度更新公式迭代地调整自身在参数空间中的位置。通过这种群体智能的协作与竞争机制，算法能够有效地在参数空间中探索和开发，逐步逼近并最终搜索到使适应度函数最优(即控制系统性能最佳)的参数组合，如图 4 所示。

3.2.2. 性能指标

为全面评价控制系统性能，引入以下关键指标：

均方误差 MSE ：用于衡量系统输出与参考信号之间的偏差，反映控制精度。

$$MSE = \frac{1}{N} \sum (y - r)^2$$

超调：用于描述系统响应过程中超过稳态值的程度，反映系统稳定性。

$$Overshoot = \frac{y_{max} - y_{ref}}{y_{ref}}$$

能量：用于衡量控制输入的变化幅度，反映控制平滑性及能耗。

$$Energy = \sum u(k)^2$$

3.2.3. 粒子群优化算法的动态更新机制

为了更有效地提升整体控制性能并改善系统响应效果，本研究采用了一种先进的粒子群优化算法来对系统的关键控制参数进行优化与调整，如图 5。该算法通过模拟鸟群或鱼群的社会行为，不断迭代更新每个粒子的状态：

$$v_i^{k+1} = wv_i^{k+1} + c_1r_1(pbest - x_i^k) + c_2r_2(gbest - x_i^k)$$

$$x_i^{k+1} = x_i^k + v_i^{k+1}$$

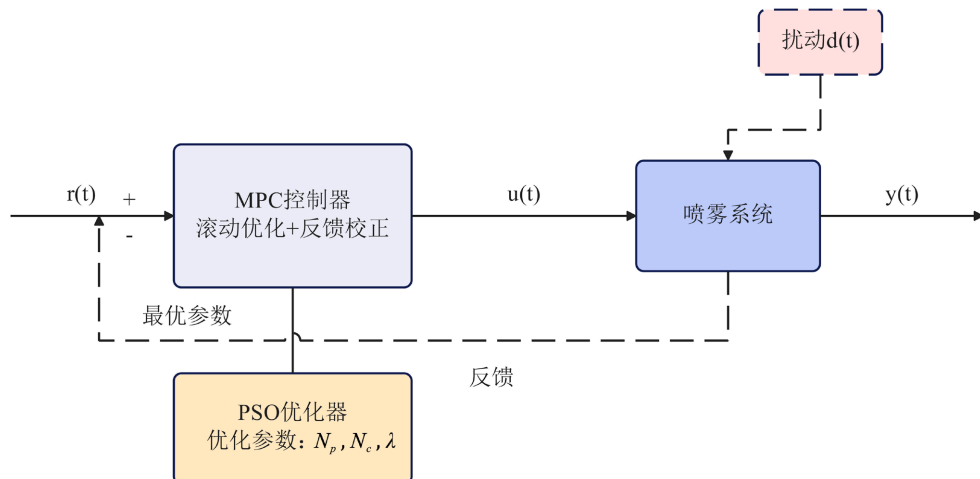


Figure 5. Schematic diagram of the MPC-PSO integrated optimization control structure
图 5. MPC-PSO 融合优化控制结构图

从而在参数空间中高效搜索最优解。其中， v_i 粒子速度的更新决定了其探索方向和时域， x_i 而位置的更新则反映了粒子在解空间中的移动轨迹；同时， $pbest$ 个体最优记录了每个粒子自身历史上达到的最佳适应度位置， $gbest$ 全局最优则代表了整个粒子群迄今为止所发现的最优解位置。通过这些信息的交互与传递，粒子能够逐步收敛至全局最优或近似最优的参数组合。

3.2.4. 适应度函数构建

为对控制系统的性能进行全面且细致的综合评价，本研究构建了一个适应度函数：

$$J = \alpha \cdot MSE + \beta \cdot Overshoot + \gamma \cdot Energy$$

该函数旨在通过量化指标来系统性地衡量和评估系统的各项关键性能表现。

4. 仿真结果及分析

4.1. 参数设置

本次仿真实验的具体参数配置如下：采样时间间隔设置为 0.1 秒；总的仿真运行时长设定为 20 秒；增益系数 K 的参数设定为 1，时间常数 T 的参数设定为 2，阻尼比 ζ 的参数设定为 0.7。MPC 控制器的预测时域 N_p 、控制时域 N_c 、以及控制权重 λ 通过粒子群优化算法进行整定，优化范围分别为 $N_p \in [3, 20]$ 、 $N_c \in [1, 10]$ 、 $\lambda \in [0.01, 1]$ 。

4.2. 结果分析

本研究对每组参数进行 20 次独立仿真，并取平均值作为最终结果，同时列出 MPC + PSO 20 次独立仿真的结果，见表 1：

Table 1. Statistical results of 20 independent simulations of MPC-PSO

表 1. MPC + PSO 20 次独立仿真的结果

Sequence	MSE	Overshoot	settling_time (s)	Energy
1	0.0415	22.38	1.55	30.25
2	0.0397	23.05	1.51	30.47
3	0.0407	21.80	1.53	30.36
4	0.0407	21.50	1.58	30.38
5	0.0413	20.42	1.47	30.20
6	0.0414	21.01	1.56	30.27
7	0.0409	21.03	1.51	30.15
8	0.0410	21.45	1.61	30.32
9	0.0406	20.78	1.48	30.23
10	0.0408	22.50	1.48	30.26
11	0.0409	21.15	1.51	30.20
12	0.0413	21.07	1.56	30.08
13	0.0412	22.65	1.54	30.32
14	0.0416	22.85	1.54	30.23
15	0.0409	20.75	1.48	30.24
16	0.0402	21.20	1.50	30.23

续表

17	0.0414	21.21	1.49	30.17
18	0.0402	22.69	1.51	30.39
19	0.0412	21.47	1.48	30.09
20	0.0414	21.96	1.53	30.37
average	0.0409	21.65	1.52	30.26
standard deviation	0.0005	0.79	0.04	0.10

Table 2. Performance evaluation results of the MPC-PSO hybrid optimization model**表 2.** MPC-PSO 融合优化模型性能结果

性能指标	Average	Standard Deviation
MSE	0.0409	0.0005
Overshoot	21.65	0.79
settling_time	1.52	0.04

表 2 给出了 MPC-PSO 融合优化模型在多次仿真下的统计结果。从表 2 中可以看出, 该系统的均方误差(MSE)为 0.0409, 超调量为 21.65%, 调节时间为 1.52 s, 说明该方法在跟踪精度与动态响应方面具有较优性能。从标准差角度分析, 各项指标波动较小, 其中 MSE 标准差为 0.0005, 调节时间标准差仅为 0.04 s, 能量指标标准差为 0.10, 说明该控制策略在多次运行中具有较高的一致性与稳定性。超调量的标准差为 0.79, 虽然略高于其他指标, 但整体仍处于较低水平, 说明系统动态响应虽存在一定波动, 但总体可控。

Table 3. Comparative performance of different control strategies**表 3.** 不同控制策略性能对比

控制策略	MSE	Overshoot	settling_time (s)
开环控制	0.0655	35.12	2.53
单一 MPC	0.0482	25.37	1.91
MPC + PSO	0.0409	21.65	1.52

表 3 对比了开环控制、单一 MPC 以及 MPC-PSO 三种控制策略的性能表现。从结果可以看出: 在跟踪精度方面, MPC-PSO 方法的 MSE 最低(0.0409), 相比单一 MPC 降低约 15.15%, 相比开环控制降低约 37.56%, 说明参数优化显著提升了系统精度; 在动态性能方面, MPC-PSO 的超调量为 21.65%, 明显优于单一 MPC (25.37%)和开环控制(35.12%); 调节时间缩短至 1.52 s, 相较单一 MPC 减少约 20.4%, 相较开环控制减少约 39.9%, 说明该方法具有更快的响应速度和更好的动态品质; 在控制能量方面, MPC-PSO 的能量消耗为 30.26, 高于单一 MPC (29.54)和开环控制(28.47), 表明该系统通过增加控制输入来换取更优的性能。

通过比较仿真结果可知, MPC-PSO 控制策略在反应速度、稳态误差和抗干扰能力方面均优于传统方法。但其性能提升的同时, 系统的能耗也增加了, 说明不同性能指标之间有取舍。具体来说, MPC-PSO 通过调整控制参数, 让系统快速接近期望值, 从而减少了调整时间和超调量。但这种“快速响应”需要较大的控制输入变化, 也就是控制器在短时间内加强调节力度, 导致能耗增加。另外, PSO 在优化时更

注重跟踪精度和动态性能,对控制输入变化率的限制相对较松,这也是能耗上升的原因之一,反映了“性能-能耗”之间的典型权衡,即更好的动态性能通常需要更高的能耗。




Figure 6. Performance comparison of different control strategies

图 6. 不同控制策略性能对比图

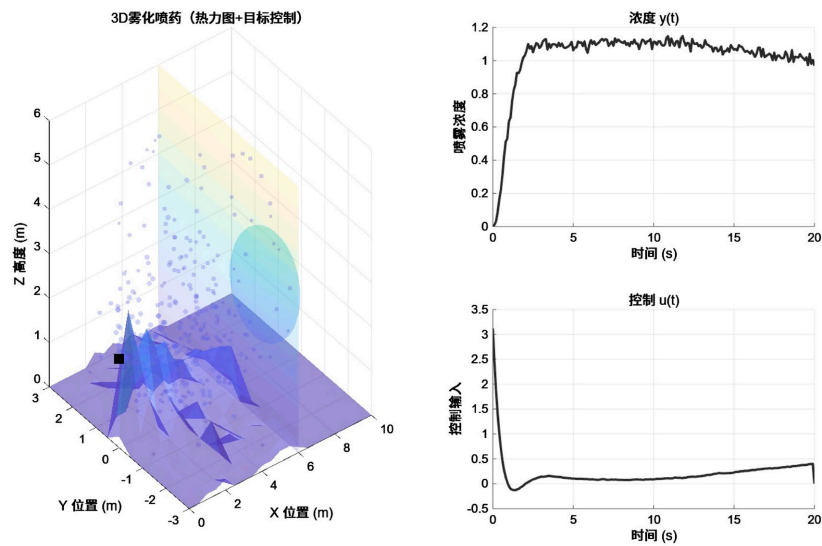


Figure 7. 3D spray heatmap with target tracking

图 7. 3D 雾化喷药热力图与目标控制

从图6可以看出, MPC + PSO 融合控制策略在各项指标上均表现最优: 其均方误差(MSE)最低, 为 0.0409, 显著优于单一 MPC 的 0.0485 和开环控制的 0.0655; 超调量最小, 为 21.65%, 较单一 MPC (25.37%) 和开环控制(35.12%)有明显改善; 调节时间最短, 仅需 1.52 秒, 响应速度远快于单一 MPC (1.91 秒)和开环控制(2.53 秒); 但是控制能量却最高, 为 30.26, 高于单一 MPC 的 29.54 和开环控制的 28.47。




Figure 8. Control signal and tracking error
图8. 控制信号与跟踪误差




Figure 9. System output and reference response curves
图9. 系统输出与目标响应曲线

图 7 展示了基于 MPC-PSO 融合优化模型的控制仿真，该系统模拟了喷雾过程中的喷头的位置、周围墙体大致布局、目标区域、环境风场影响(风场采用随机扰动模型模拟)、以及代表优化迭代过程中新旧种群的粒子状态，并引入了热力图来直观呈现喷雾密度与位置控制的动态效果。该过程实现了精准的目标区域控制，同时动态响应环境变化与系统约束，保证了喷雾作业的实现。

图 8 展示了系统在 0 至 20 秒内的部分仿真数据，反映了从初始状态到稳态的响应过程。初始时刻输出为 0，目标为 1，控制器迅速输出较大的控制信号，使输出快速上升；1 秒时输出已升至 0.4 左右，跟踪误差降至 0.9 左右；随后控制信号逐步减小，输出稳步逼近目标值；约 3 秒时输出达到 1，跟踪误差降至大约为 0，此后输出稳定保持在目标值，控制信号维持微小正值。整体响应速度快，存在一定超调，表明了 MPC + PSO 融合策略在动态响应与稳态精度方面的优越性。

图 9 中的蓝色实线为含噪声的输出信号，红色虚线为目标值(1.0)，绿色虚线为无扰动响应，灰色虚线为 10%误差带，紫色虚线标注调节时间。从图中可以看出，系统在约 1.5 秒内快速达到目标值，存在超调但迅速收敛，之后输出在误差带内保持稳定，说明控制系统具有较好的动态性能和抗干扰能力。

5. 结论

本文针对喷药控制系统的动态特性，提出了一种基于 MPC-PSO 的控制方法。通过引入粒子群优化算法对模型预测控制参数进行优化，实现了系统控制性能的提升。仿真结果表明，该方法在跟踪精度、响应速度及系统稳定性方面均优于传统控制策略，能够有效提高喷药系统的控制效果。分析结果也表明在性能提升的同时，系统控制能量存在一定程度的增加，表明控制性能与能耗之间的权衡关系。总体而言，本文提出的方法为喷药控制系统的智能化与精准化提供了一种可行的解决方案。未来研究可进一步结合实际实验数据，对算法进行优化，并在降低能耗的前提下提升系统综合性能，以增强其工程应用价值。

参考文献

- [1] 席裕庚, 李德伟, 林妹. 模型预测控制——现状与挑战[J]. 自动化学报, 2013, 39(3): 222-236.
- [2] Schwenzer, M., Ay, M., Bergs, T. and Abel, D. (2021) Review on Model Predictive Control: An Engineering Perspective. *The International Journal of Advanced Manufacturing Technology*, **117**, 1327-1349. <https://doi.org/10.1007/s00170-021-07682-3>
- [3] Kennedy, J. and Eberhart, R.C. (1995) Particle Swarm Optimization. *Proceedings of ICNN'95—International Conference on Neural Networks*, Perth, 27 November-1 December 1995, 1942-1948. <https://doi.org/10.1109/ICNN.1995.488968>
- [4] 李爱国, 覃征, 鲍复民, 等. 粒子群优化算法研究综述[J]. 计算机工程与应用, 2002, 38(21): 36-39.
- [5] Suzuki, R., Kawai, F., Ito, H., et al. (2007) Automatic Tuning of Model Predictive Control Using Particle Swarm Optimization. *2007 IEEE Swarm Intelligence Symposium*, Honolulu, 1-5 April 2007, 221-226. <https://doi.org/10.1109/SIS.2007.367941>
- [6] 李广龙, 翁发禄, 魏童俊, 杨晶晶, 许锦杰. 基于粒子群算法的主动悬架模型预测控制研究[J]. 传感器技术与应用, 2026, 14(1): 66-80.
- [7] Bwambale, E., Wanyama, J., Adongo, T.A., et al. (2025) A Review of Model Predictive Control in Precision Agriculture. *Smart Agricultural Technology*, **10**, Article ID: 100716. <https://doi.org/10.1016/j.atech.2024.100716>
- [8] Xu, N., Wang, L., Ning, X., et al. (2025) PSO-Optimized MPC for Trajectory Tracking of Articulated Tractors in Agricultural Environments. *Advances in Mechanical Engineering*, **17**. <https://doi.org/10.1177/16878132251391274>