

混合动力内燃机车能量管理策略优化

赵天宇

华能伊敏煤电公司铁路运输处 内蒙古 呼伦贝尔 021134

摘要：随着全球能源结构转型与环保法规的日益严格，混合动力内燃机车作为传统内燃机车与新能源技术的融合产物，其能量管理策略的优化成为提升系统效率、降低能耗与排放的关键。本文深入分析现有策略的局限性，提出基于多目标优化与智能算法的能量管理策略优化框架。为混合动力内燃机车的工程应用提供理论支撑与技术参考。

关键词：混合动力内燃机车；能量管理策略；多目标优化；智能算法；燃油经济性

1 引言

铁路运输在全球交通运输体系中占据重要地位，但同时也是能源消耗与碳排放的主要来源之一。面对日益严峻的能源危机和环保压力，铁路运输的低碳化转型已成为必然趋势。混合动力内燃机车通过集成内燃机、电动机、储能装置及能量管理系统，实现了动力源的灵活切换与能量流的动态优化，为铁路运输的节能减排提供了新的解决方案。然而，混合动力系统的复杂性使得能量管理策略的设计面临诸多挑战。一方面，需要兼顾燃油经济性、排放性能、动力性等多个目标，这些目标之间往往存在冲突，难以同时达到最优；另一方面，实际工况的不确定性以及系统各部件之间的动态耦合，使得传统基于规则的策略难以适应复杂多变的运行环境。因此，如何构建高效、智能的能量管理策略，成为混合动力内燃机车技术突破的核心问题。本文旨在系统分析混合动力内燃机车能量管理策略的优化方法，提出基于多目标优化与智能算法的混合策略框架，并通过仿真验证其有效性，为混合动力内燃机车的工程应用提供理论指导与技术路径。

2 现有能量管理策略分类与局限性分析

2.1 基于规则的策略

基于规则的策略通过预设逻辑门限来实现功率分配，其基本原理是根据车速、SOC、需求功率等参数的阈值来决定内燃机和电动机的工作状态。例如，恒温器策略规定当SOC低于下限时启动内燃机充电，高于上限时关闭内燃机，以维持储能装置的电量在合理范围内；功率跟踪策略则让内燃机全程跟踪需求功率，仅在SOC充足时由电动机辅助提供额外的动力。这种策略具有实现简单、实时性强的优点，不需要复杂的计算和模型，能够快速响应系统状态的变化。然而，其局限性也十分明显。规则参数的设定往往依赖工程经验，难以适应复杂多变的工况^[1]。不同的运行环境、线路条件和负载需求

会对系统的能量需求产生很大影响，而固定的规则参数无法根据实际情况进行灵活调整。此外，在多目标冲突的情况下，如燃油经济性和动力性之间存在矛盾时，基于规则的策略难以实现全局最优，可能会导致某些性能指标无法达到理想状态。

2.2 基于优化算法的策略

基于优化算法的策略通过数学建模来求解最优功率分配。全局优化算法如动态规划（DP）、遗传算法（GA）等，能够找到全局最优解，但需要预知工况且计算复杂度高。动态规划通过将问题分解为多个阶段，逐步求解每个阶段的最优解，最终得到全局最优解，但这种方法需要大量的计算资源和时间，难以在实际应用中实时运行。遗传算法则通过模拟生物进化过程，不断迭代优化解的质量，但同样面临着计算复杂度高的问题，且收敛速度较慢。瞬时优化算法如等效燃油消耗最小策略（ECMS），通过将电能消耗转化为等效燃油消耗来实现实时优化。该策略在每个时刻都计算内燃机和电动机的等效燃油消耗，并选择使总等效燃油消耗最小的功率分配方案。虽然瞬时优化算法能够在一定程度上实现实时优化，但其对工况预测的准确性依赖度高。如果工况预测不准确，可能会导致优化结果偏离实际最优解，影响系统的性能。

2.3 基于智能算法的策略

基于智能算法的策略通过机器学习或强化学习实现自适应优化。深度强化学习（DRL）通过智能体与环境的交互学习最优策略，智能体在不断尝试和探索中逐渐掌握在不同状态下采取何种行动能够获得最大的奖励。逆强化学习（IRL）则通过专家轨迹推导最优奖励函数，从专家的行为中学习到隐含的优化目标和策略。然而，智能算法也存在一些局限性。训练数据需求量大，智能算法需要大量的历史数据来训练模型，以使其能够准确地预测和决策。但在实际应用中，获取高质量、多样化

的训练数据往往比较困难。此外，模型的泛化能力有待提升，智能算法在训练数据上可能表现良好，但在面对新的、未见过的工况时，其性能可能会下降，无法很好地适应复杂多变的实际运行环境。

3 能量管理策略优化方法

3.1 多目标优化框架

混合动力内燃机车在实际运行过程中，其能量管理面临着多方面的性能要求，需要同时优化燃油经济性、排放性能以及系统可靠性等多个关键目标。然而，这些目标之间往往存在着复杂的相互制约关系。例如，若单纯追求燃油经济性的提升，可能会因调整发动机工作点或动力分配方式而导致排放增加；而过度强调低排放，又可能导致动力性能下降，或者为满足排放要求而增加额外的后处理设备，进而提高系统成本。

为了有效解决这一多目标优化难题，可以构建一个科学合理的多目标优化模型，将多个相互关联的目标函数进行综合优化。多目标优化问题的一般数学形式可表示为：

$$\min \{f_1(u), f_2(u), \dots, f_n(u)\}$$

其中， $f_i(u)$ 表示第*i*个目标函数，常见的目标函数包括燃油消耗量、 NO_x 排放量、颗粒物排放量等； u 为控制变量集合，涵盖了内燃机功率、电动机转矩、储能装置充放电功率等。

为了将复杂的多目标问题转化为便于求解的单目标问题，常用的方法有加权法和Pareto前沿法。

加权法：该方法的核心思想是为每个目标函数分配一个权重系数，这些权重系数反映了各个目标在优化过程中的相对重要性。通过将多个目标函数按照各自的权重进行加权求和，得到一个综合的目标函数，然后求解该综合目标函数的最小值^[2]。例如，设燃油消耗目标函数的权重为 w_1 ， NO_x 排放目标函数的权重为 w_2 ，则综合目标函数可表示为 $F(u) = w_1 f_1(u) + w_2 f_2(u)$ 。在实际应用中，权重的确定需要综合考虑多种因素，如环保要求、运营成本等，通常可以通过专家经验、层次分析法等方法来确定。

Pareto前沿法：此方法不将多个目标函数简单地进行加权求和，而是通过寻找一组非支配解来处理多目标优化问题。非支配解是指在所有目标函数上都不能被其他解同时优化的解，这些解构成了Pareto前沿。决策者可以根据实际需求，从Pareto前沿中选择最合适的解。例如，在追求燃油经济性和排放性能的平衡时，决策者可以根据当前的运营环境和政策要求，在Pareto前沿上选择一个既能满足一定燃油经济性要求，又能达到较好排放性能的解。

在求解多目标优化问题时，遗传算法和粒子群优化（PSO）算法是两种常用的智能优化算法。

遗传算法：遗传算法模拟了生物进化过程中的选择、交叉和变异操作。在优化过程中，首先随机生成一组初始解作为种群，然后根据目标函数值对种群中的个体进行选择，选择适应度较高的个体进入下一代种群；接着通过交叉操作将两个个体的部分基因进行交换，产生新的个体；最后通过变异操作对个体的基因进行随机改变，增加种群的多样性。经过不断地迭代，种群中的个体逐渐向最优解靠近，从而找到满足多目标优化要求的解。遗传算法具有较强的全局搜索能力，能够在复杂的解空间中寻找全局最优解，适用于混合动力内燃机车能量管理策略的多目标优化问题。

粒子群优化算法：该算法模拟了鸟群或鱼群的群体行为。在算法中，每个粒子代表问题的一个潜在解，粒子在解空间中根据自身的历最优化位置和群体的全局最优化位置来调整自己的飞行方向和速度。通过不断地迭代，粒子逐渐向最优解靠近^[3]。粒子群优化算法具有收敛速度快、参数设置简单等优点，在处理混合动力内燃机车能量管理策略的多目标优化问题时，能够快速找到较好的解。

3.2 基于智能算法的混合策略

尽管智能算法在混合动力内燃机车能量管理策略优化中取得了一定的成果，但仍然存在一些局限性，如奖励函数设计的主观性较强、算法的泛化能力有待提高等。为了克服这些局限性，可以提出基于深度强化学习与逆强化学习的混合策略。该混合策略主要分为逆强化学习阶段和深度强化学习阶段。

逆强化学习阶段：在这一阶段，主要任务是通过专家轨迹推导最优化奖励函数权重。专家轨迹通常是由经验丰富的驾驶员或专家在特定工况下操作机车所得到的数据，这些数据包含了丰富的隐含优化目标和策略信息。逆强化学习算法通过对专家轨迹进行深入分析，学习到专家在不同状态下采取行动所获得的奖励，进而推导出最优化奖励函数的权重。具体而言，逆强化学习算法会构建一个奖励函数模型，该模型的参数即为奖励函数的权重。通过不断地调整模型参数，使得根据该奖励函数计算出的专家行动的奖励值最大，从而得到最优化的奖励函数权重。这样可以有效解决奖励函数设计的主观性问题，使奖励函数更加符合实际需求。

深度强化学习阶段：基于逆强化学习阶段推导出的奖励函数，开始训练智能体。智能体在模拟环境中与系统进行交互，根据当前的状态信息选择相应的行动，并

获得相应的奖励。在训练过程中,智能体通过不断地学习和调整自己的策略,逐渐掌握最优的能量管理策略,实现自适应优化。深度强化学习算法通常采用神经网络来近似表示策略函数或价值函数,通过梯度下降等方法更新神经网络的参数,以提高智能体的性能^[4]。这种混合策略结合了逆强化学习的先验知识学习和深度强化学习的自适应学习能力,能够充分发挥两者的优势,提高智能算法的性能和泛化能力。例如,在面对不同的运行工况和任务需求时,智能体能够快速调整自己的策略,实现高效的能量管理。

3.3 工况预测与动态调整

为了进一步提高混合动力内燃机车能量管理策略的适应性和性能,可以结合历史数据与实时传感器信息,采用长短期记忆网络(LSTM)对未来工况进行预测。LSTM是一种特殊的循环神经网络,它通过引入门控机制,能够有效地处理序列数据,捕捉数据中的长期依赖关系。

工况预测:在工况预测过程中,首先收集大量的历史工况数据,包括机车的运行速度、加速度、负载情况、线路坡度等信息。将这些历史数据作为LSTM网络的输入,对网络进行训练。在训练过程中,LSTM网络通过不断地调整自身的参数,学习到工况的变化规律。当有新的实时传感器信息输入时,LSTM网络可以根据学习到的规律对未来一段时间内的工况进行预测。例如,预测机车在未来几分钟内的运行速度、负载变化等情况。

动态调整:根据LSTM网络预测的未来工况,动态调整能量管理策略参数。例如,如果预测到未来一段时间内机车将处于频繁启停的工况,可以提前调整储能装置的充放电策略,增加能量回收的力度。在机车制动时,将更多的制动能量存储到储能装置中;在机车启动或加速时,合理利用储能装置中的能量,减少内燃机的负荷,从而提高燃油经济性。此外,还可以根据预测的工况调整内燃机和电动机的功率分配,使系统在不同的工况下都能保持较高的效率和较低的排放。通过工况预测

与动态调整,能量管理策略能够更好地适应实际运行环境的变化,提升系统的整体性能。例如,在不同的线路条件和运营任务下,系统能够自动调整能量管理策略,实现最优的能量分配和利用。

结语

本文针对混合动力内燃机车的能量管理策略优化问题,提出了一种基于多目标优化与智能算法的混合策略框架。该策略在燃油经济性、排放性能及系统可靠性方面的显著提升。优化后的混合策略能够根据实时工况和系统状态,自适应地调整功率分配,实现内燃机工作点的高效区运行、储能装置的SOC平衡以及能量回收效率的最大化。未来研究可以聚焦于以下几个方面:一是轻量化设计,结合新材料与结构优化,降低系统质量,提高机车的能源利用效率;二是车联网技术,通过车-车/车-基础设施通信实现协同优化,使机车能够根据前方线路条件和交通状况提前调整能量管理策略;三是全生命周期评估,综合考虑经济性、环境性与社会性,构建综合评价体系,为混合动力内燃机车的设计和优化提供更全面的指导。混合动力内燃机车能量管理策略的优化是铁路运输低碳化转型的关键技术,其研究成果将为全球能源节约与环境保护提供重要支撑。随着技术的不断发展和创新,混合动力内燃机车将在铁路运输领域发挥越来越重要的作用。

参考文献

- [1] 郑伟光,李燕青,李骏,等.P2混合动力商用车能量管理策略研究[J/OL].机械设计与制造,1-7[2025-06-27].
- [2] 邓吉琛,王艳华,王耀勋,等.基于规则的混合动力汽车能量管理策略研究[J].中北大学学报(自然科学版),2025,46(03):326-332.
- [3] 赵小虎.并联式商用混合动力汽车能量管理控制策略研究[J].汽车测试报告,2025,(06):145-147.
- [4] 庞圣钊,赵已雨,程博,等.基于强化学习的混合动力运载工具能量管理策略综述[J].无人系统技术,2025,8(01):1-19.