

分类号: TP391

密 级: 公开

学校代码: 10363

学 号: 2220320133



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题目 数据驱动的无人机故障诊断
与容错控制研究

论 文 作 者 任以然

校 内 导 师 郭黎

校 外 导 师 袁学超

专业学位类别 电子信息

研究方向(领域) 智能故障诊断

论文提交日期: 2025 年 5 月 19 日

分类号：TP391

单位代码：10363

密 级：公开

学 号：2220320133

题 目 数据驱动的无人机故障诊断与容错控制研究

题 目 Research on Data-Driven Fault Diagnosis and Fault-Tolerant Control for Unmanned Aerial Vehicle

论文作者： 任以然

校内导师： 郭黎（教授）

校外导师： 袁学超

专 业： 电子信息

研究方向： 智能故障诊断

论文答辩日期： 2025 年 5 月 6 日

安徽工程大学学位论文原创性声明

本人郑重声明：我恪守学术道德，崇尚严谨学风。所呈交的学位论文，是本人在导师的指导下，独立进行研究工作所取得的成果。除文中已明确注明和引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写过的作品及成果的内容。论文为本人亲自撰写，我对所写的内容负责，并完全意识到本声明的法律后果由本人承担。

学位论文作者签名：任以然

日期：2025年5月19日

安徽工程大学学位论文版权使用授权书

学位论文作者完全了解学校有关保留、使用学位论文的规定，同意学校保留并向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅或借阅。本人授权安徽工程大学可以将本学位论文的全部内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存和汇编本学位论文。

保密 ☐，在 _____ 年解密后适用本版权书。

本学位论文属于

不保密 ☒。

学位论文作者签名：

任以然

指导教师签名：

邵子

日期： 2025 年 5 月 19 日

日期： 2025 年 5 月 19 日

数据驱动的无人机故障诊断与容错控制研究

摘 要

随着技术的进步和产业政策的不推动,各类无人机被广泛地应用于多个领域,显著推动了社会的发展。然而,无人机在飞行过程中容易受到自身动态特性和外部复杂环境的影响而出现执行器故障或传感器故障。如果无人机发生故障后没有得到及时诊断或有效的容错控制,很有可能造成经济损失甚至人员伤亡。因此,为提高无人机的安全性和稳定性,本文以目前应用广泛的四旋翼无人机为研究对象,针对其飞行过程中可能发生的传感器故障和执行器故障,提出了一种基于数据驱动的故障诊断与容错控制方案。具体研究内容如下:

(1) 针对传统四旋翼无人机故障诊断方法中存在难以精确建模、人工特征提取困难和需要专家先验知识等问题,本文提出了一种轻量级融合卷积神经网络(Convolutional Neural Network, CNN)和Transformer的四旋翼无人机故障诊断方法。该方法通过在轻量化的CNN结构中嵌入高效注意力机制,能够有效挖掘隐藏在飞行数据中的局部关键特征。同时,为克服基于Transformer模型复杂度较高的问题,提出了一种轻量级注意力机制用于自适应学习不同通道特征表示的重要性,从而在更好地捕捉全局关键特征的同时,有效降低了模型的复杂度。最后,与其他故障诊断模型进行了对比实验,实验结果验证了本文所提出的故障诊断方法的优越性。

(2) 针对传统容错控制方法依赖精确的数学模型以及需要繁琐

参数整定的缺陷，本文提出了一种结合软演员-评论家（Soft Actor-Critic, SAC）强化学习算法和 PID 控制器的四旋翼无人机容错控制方法。该方法充分利用了 PID 控制器基础控制能力强和强化学习的自学习特性，能够减少强化学习中无效的探索，同时降低了对模型先验知识的要求。强化学习控制器作为补偿控制器，在接收到故障信息后，能够实现对 PID 控制器输出控制信号的有效补偿，显著增强系统的容错控制能力。在执行器故障和传感器故障情形下，通过仿真实验验证了所提容错控制方法的有效性。

（3）本研究基于 RflySim 搭建了一个包含软件在环仿真和硬件在环仿真的四旋翼无人机故障诊断与容错控制仿真平台。在该仿真平台上构建了故障数据集以及基于强化学习的容错控制框架，并针对执行器故障和传感器故障开展了故障诊断与容错控制实验，实验结果验证了本文所提方法的有效性。

关键词：四旋翼无人机，故障诊断，容错控制，Transformer，强化学习

RESEARCH ON DATA-DRIVEN FAULT DIAGNOSIS AND FAULT-TOLERANT CONTROL FOR UNMANNED AERIAL VEHICLE

ABSTRACT

With the development of technology and the promotion of government policies, various types of unmanned aerial vehicles (UAVs) have been widely applied in a wide range of domains, which significantly contribute to the development of society. However, UAVs are prone to be affected by their own dynamic characteristics and the complex external environment during flight, which may result in actuator or sensor faults. If faults occur in UAVs without timely diagnosis and proper handling, they may cause economic losses and even human casualties. Therefore, in order to improve the safety and stability of UAVs, this thesis takes the widely used quadrotor as the research object, and proposes a data-driven fault diagnosis and fault-tolerant control method to address potential sensor and actuator faults that may occur in UAVs during flight. The research contents are described as follows:

(1) To address the challenges in traditional quadrotor fault diagnosis methods, such as difficulties in precise modeling, complex manual feature

extraction, and reliance on expert prior knowledge, this thesis proposes a lightweight fault diagnosis method that integrates Convolutional Neural Networks (CNNs) and Transformer. This method embeds an efficient attention mechanism into a lightweight CNN structure, effectively extracting local critical features hidden in the flight data. Additionally, to mitigate the high computational complexity of Transformer-based models, a lightweight attention mechanism is developed to adaptively learn the importance of different channel representations, thereby capturing global key features more effectively while significantly alleviating the issue of model complexity. Finally, comparative experiments with other fault diagnosis models were conducted, and the experimental results demonstrate the superiority of the proposed fault diagnosis method.

(2) To overcome the limitations of traditional fault-tolerant control method, such as relying on an accurate mathematical model and the need for manual parameter tuning, this thesis proposes a quadrotor fault-tolerant control method that combines Soft Actor-Critic (SAC) reinforcement learning algorithm with a PID controller. This method leverages the strengths of the PID controller and the self-learning characteristics of reinforcement learning, thereby avoiding unnecessary exploration in reinforcement learning while reducing dependence on the knowledge of the quadrotor model. The reinforcement learning algorithms acts as a compensation controller, effectively compensating the motor control

signals output by the PID controller when receiving fault information, thus significantly enhancing the system's fault-tolerant control capability. Simulation experiments under actuator and sensor fault scenarios validate the effectiveness of the proposed control method.

(3) The thesis develops a quadrotor fault diagnosis and fault-tolerant control simulation platform based on RflySim, containing both software-in-the-loop and hardware-in-the-loop simulations. A fault dataset and a reinforcement learning-based fault-tolerant control framework were constructed on this platform. The proposed fault diagnosis and fault-tolerant control method were conducted for actuator and sensor failures, and the experimental results validated the effectiveness of the proposed method.

KEY WORDS: quadrotor unmanned aerial vehicle, fault diagnosis, fault-tolerant control, Transformer, reinforcement learning

目录

摘 要.....	I
ABSTRACT.....	III
第 1 章 绪论.....	1
1.1 研究背景及意义.....	1
1.2 国内外研究现状.....	3
1.2.1 四旋翼无人机故障诊断研究现状.....	3
1.2.2 四旋翼无人机容错控制研究现状.....	5
1.3 研究内容与章节安排.....	7
第 2 章 相关理论与算法基础.....	9
2.1 引言.....	9
2.2 卷积神经网络.....	9
2.3 Transformer 神经网络.....	13
2.4 强化学习基础.....	17
2.5 仿真平台介绍.....	20
2.5.1 平台介绍.....	20
2.5.2 故障注入模型.....	21
2.6 本章小结.....	23
第 3 章 基于深度学习的四旋翼无人机故障诊断方法.....	24
3.1 引言.....	24
3.2 基于 CNN-Transformer 模型的故障诊断方法.....	24
3.2.1 选择分块模块.....	25
3.2.2 选择通道模块.....	28
3.3 实验设置及结果分析.....	30
3.3.1 数据采集.....	30
3.3.2 数据处理.....	32
3.3.3 评价指标.....	33

3.3.4 结果分析.....	34
3.4 本章小结.....	41
第 4 章 基于强化学习的四旋翼无人机容错控制方法.....	42
4.1 引言.....	42
4.2 基于 SAC 算法的四旋翼无人机容错控制方法.....	42
4.2.1 四旋翼无人机飞行控制框架.....	42
4.2.2 SAC 强化学习算法.....	44
4.2.3 容错控制方法设计.....	46
4.3 实验设置及结果分析.....	48
4.3.1 实验参数设置.....	48
4.3.2 实验结果分析.....	49
4.4 本章小结.....	55
第 5 章 总结与展望.....	56
5.1 本文总结.....	56
5.2 未来展望.....	57
参考文献.....	58
攻读学位期间发表的学术成果.....	66
致谢.....	67

第 1 章 绪论

1.1 研究背景及意义

近年来，随着工业制造水平的提升、信息技术的进步，以及低空经济产业政策的不断推动，无人机（Unmanned Aerial Vehicles, UAVs）在全球范围内受到广泛的关注和应用^[1]。当前，许多无人机具有智能化程度高、操作便捷和适应各种复杂环境等特性，已经渗透到社会经济领域的诸多行业，并在人们的日常生活中扮演着重要的角色。在各类无人机中，四旋翼无人机（Quadrotor Unmanned Aerial Vehicles, QUAVs）凭借结构简单、操作简便和成本低廉等显著优势，尤其受到人们的青睐，被广泛地应用于低空经济的各个领域，在不同场景下执行各类任务时均发挥着重要作用^[2]。



(a) 航空摄影



(b) 智慧农业



(c) 低空物流



(d) 电力巡检

图 1-1 四旋翼无人机的应用场景

图 1-1 展示了四旋翼无人机在不同领域中执行任务的场景。在航拍领域中，四旋翼无人机以其小巧轻便、高机动性和运行稳定等特性，成为个人和专业影视公司在低空航拍的首选工具。在智慧农业领域中，四旋翼无人机可用于农药喷洒、

农田测绘和撒播种子等任务,不仅能够显著提升作业效率,还能够减轻人力负担。在低空物流领域中,四旋翼无人机可用于短途运输任务,适用于最后一公里配送,其在外卖和快递配送领域备受关注。在电力巡检领域中,四旋翼无人机不仅能够轻松到达人工巡检难以到达的区域,提升巡检效率并降低人工作业安全风险,还能够通过其装备的各类高精度传感器及时发现潜在的隐患点,从而提升对电力设施的监控强度。在未来,四旋翼无人机的应用领域还将会不断拓展和深化。

随着四旋翼无人机应用领域的持续扩展,其飞行范围已从城郊或野外等人口稀疏区域,逐渐延伸至人口密集且环境复杂的城市中心区域。特别是随着城区中短途物流运输的四旋翼无人机的应用,一旦这类无人机出现故障却未能得到及时诊断和容错控制,不仅可能导致无法完成既定的飞行任务,更有可能造成财产损失甚至人员伤亡。因此,确保四旋翼无人机的飞行安全受到了来自各界的广泛关注。四旋翼无人机是典型的欠驱动、强耦合、非线性系统^[3],主要由执行器、传感器和其他机身组件构成,具有四个控制输入和六个自由度的输出,通过调节四个电机的转速进而控制升力,从而实现对各种飞行姿态的控制^[4]。四旋翼无人机的执行器在长期高负荷运转以及外界因素的影响下容易发生故障,而一个执行器发生故障就有可能导致系统失去稳定能力^[5]。同时,四旋翼无人机的控制系统高度依赖于机上传感器的各种数据,以实现稳定飞行^[6]。在复杂的外部环境干扰下,机载传感器发生故障的可能性也不断提高。更重要的是,一般的四旋翼无人机受限于自身负载能力、有限的机上空间和成本等因素,通常不采用硬件冗余的方式(例如安装备份传感器)来提升飞行的安全性^[7]。因此,有效的故障诊断与容错控制方法对于确保四旋翼无人机系统稳定性、安全性与可靠性具有重要的意义。

传统的四旋翼无人机故障诊断与容错控制方案往往依赖于精确的数学模型、复杂的特征工程或者专家的先验知识,在四旋翼无人机智能化发展的浪潮中显露出了局限性。提高无人机智能化健康管理及故障处置能力是无人机系统未来的发展趋势。近年来,随着人工智能技术、大数据和硬件技术的发展,如何从四旋翼无人机飞行期间产生的海量数据中自动有效地提取特征从而进行故障诊断,以及进一步提升四旋翼无人机的智能容错控制水平,已经成为研究热点。这其中,数据驱动的方案摆脱了对精确数学模型和先验知识的要求,能够直接从数据中学习,因而受到了学者的广泛关注和应用。因此,本文针对四旋翼无人机常见的执行器

故障和传感器故障，提出一种数据驱动的智能故障诊断与容错控制方法，具有重要的理论研究意义和工程应用前景。

1.2 国内外研究现状

1.2.1 四旋翼无人机故障诊断研究现状

自四旋翼无人机被广泛应用以来，其在飞行过程中的可靠性、安全性和稳定性就一直备受工业界和学术界的关注。针对四旋翼无人机的故障诊断问题，来自国内外的学者提出了很多的解决方法，这些方案大致可以分为三类，即基于模型的故障诊断方法、基于信号分析的故障诊断方法和基于数据驱动的故障诊断方法[8]。

基于模型的四旋翼无人机故障诊断方法是一种传统的故障诊断方法，提出和应用的时间较早，也是目前广泛使用故障诊断方法之一，已经在学术界和工业界中取得了大量的成果^[9]。该方案的核心在于建立一个能够准确反映实际飞行状态的精确数学模型，通过分析和对比该模型的输出与实际运行状态之间的偏差来进行故障诊断工作^[10]。如果偏差在允许的阈值范围内，则认为系统运行稳定；如果偏差在允许的阈值范围之外，则说明系统出现了异常。基于模型的方法主要有状态观测器方法和滤波器方法^[11]。杨苏桥等人^[12]针对飞行器多传感器融合导航故障中的 GPS 故障问题，提出了一种基于扩展卡尔曼滤波的故障诊断方法。黄庆南等人^[13]提出一种基于中间观测器的故障诊断方法。该方法能同时对四旋翼无人机的系统状态、执行器故障、传感器故障和扰动进行准确估计。Falcón 等人^[14]针对存在外部干扰情况下的四旋翼无人机执行器故障诊断问题，提出了一种基于有限时间滑膜观测器方案。该方案能够准确估计系统状态和残差信号。Ren^[15]设计了非线性鲁棒 H_∞ 观测器，可以同时估计系统的状态和执行器故障信息。戴凌宇等人^[16]针对四旋翼无人机的执行器故障问题，提出了一种多阶段联合故障观测器，实现对故障系数和系统原始状态量的估计。基于模型的方法在无人机故障诊断领域取得了大量的成果，但是严重依赖精确的数学模型。然而，现实中很难建立一个精确的数学模型，这会严重影响其故障诊断结果^[17]。

基于信号分析的故障诊断方法不同于基于模型的方法，其利用信号处理算法

或者统计学技术对系统的输入输出或传感器数据进行综合处理,通过分析信号中存在的键时频域故障特征来进行故障诊断^[18]。李润泽等人^[19]结合主成分分析技术开展四旋翼无人机集群的故障检测与诊断工作。Yaman 等人^[20]使用梅尔频率倒谱系数进行无人机故障特征的提取工作。Zhang 等人^[21]使用小波包分解从无人机机体振动信号中提取故障特征,然后进行故障的检测与识别。舒畅等人^[22]使用小波特征提取方法开展无人机传感器的故障诊断。基于信号分析的故障诊断方法不仅依赖于专家经验进行复杂特征提取,通常还需要额外的传感器采集数据进行分析,这对于小型四旋翼无人机无疑是个负担。

随着大数据、人工智能和硬件设备技术的迅猛发展,无人机在飞行过程中产生的海量飞行参数数据已经可以被本地或者云端进行存储和分析。这些数据忠实地反映了无人机的飞行状态,而如何从这些数据有效提取特征信息已经成为研究热点^[23]。基于数据驱动的故障诊断方法,尤其是采用深度学习的方式,优势之一就是能够从大量数据中自动挖掘出有效的故障特征,无需依赖系统模型或者复杂的特征工程,从而构建出一个从输入数据到故障类别的复杂映射,实现端到端的智能故障诊断^[24]。卷积神经网络由于其出色的局部特征提取能力,是故障诊断领域中常用的深度学习故障诊断模型^[25],同样也被引入四旋翼无人机故障诊断领域。Yang 等人^[26]提出一种基于深度残差收缩网络的端到端故障诊断模型。该模型被用于四旋翼无人机的早期螺旋桨微小故障诊断,实验结果表明该方法的有效性。Chen 等人^[27]考虑到一些四旋翼无人机故障诊断方法需要额外安装传感器的缺陷,其直接使用电机电流数据,提出了一种结合宽度学习(Broad Learning System, BLS)和 CNN 的电机故障诊断方法。Steinhoff 等人^[28]针对四旋翼无人机螺旋桨破损问题,提出一种基于声学的故障诊断方案。该方案通过采集不同破损程度螺旋桨在飞行时的声学信息,然后将这些声学信号转为图像信息,最后送入 CNN 进行故障诊断。Huang 等人^[29]通过短时傅里叶变换将传感器故障下的飞行参数时序数据转化为时频图,通过部署 CNN 实现对四旋翼无人机的精准故障诊断。无人机的飞行参数是多变量非线性时间序列数据,具有较复杂的非线性关系,而典型的 CNN 并不具备提取时序特性信息的能力。因此有学者通过部署或结合用于提取时间序列特征的网络模型来提高故障诊断模型的准确率。循环神经网络(Recurrent Neural Network, RNN)是早期用于提取时间序列特征的模型,但是

由于 RNN 存在梯度消失或梯度爆炸问题, 导致网络难以训练^[30], 因此目前主要是 RNN 的变体长短期记忆神经网络 (Long Short-Term Memory, LSTM) 和门控循环单元 (Gated Recurrent Unit, GRU) 被广泛用于提取时间序列中隐藏的时序特征。张雅婷等人^[31]针对四旋翼无人机飞行工况复杂和故障数据稀少的问题, 提出了一种基于 CNN 和 LSTM 的孪生混合网络故障诊断模型。该模型利用了 LSTM 对时域数据信号特征提取能力, 实现了对四旋翼无人机结构损伤性故障的诊断, 实验结果表明该故障诊断方法的有效性。Sadhu 等人^[32]结合 CNN 和 LSTM 实现了高效的四旋翼无人机故障检测与诊断, 并在真机实验中验证了所提方法的有效性。然而, LSTM 和 GRU 存在无法并行计算以及对长时间序列特征提取能力不足的缺陷, 这限制了其对时序数据的处理能力^[33]。近年来, Transformer^[34]及其各类变体以其强大的长距离建模能力和训练过程可并行化的优势, 在自然语言处理、计算机视觉以及智能故障诊断等领域取得了非凡成就^[35]。不过, 当前基于 Transformer 的四旋翼无人机故障诊断研究并不多。Ahmad 等人^[36]结合 Transformer 开展了无人机传感器的故障预测和诊断, 其实验结果证明 Transformer 对于处理飞行数据这类多变量时间序列的有效性。Wang 等人^[37]结合 Transformer 中的自注意力机制和 CNN 对四旋翼无人机的螺旋桨缺陷进行故障诊断。该方法通过注意力机制捕捉在时间维度的长距离依赖关系, CNN 则用来进一步的特征提取, 并在多种飞行状态下证明了方法的有效性。然而, 基于 Transformer 的智能故障诊断模型往往存在参数量和计算量大的问题, 这个问题限制了这类方法在故障诊断领域中的应用^[38], 因此一个有效的基于 Transformer 的轻量级故障诊断方法还需要进一步研究。

综上所述, 当前四旋翼无人机的故障诊断主要依赖于专家经验、信号分析以及精确的数学模型。这些方法在应对进一步提高无人机智能化水平的挑战中凸显了一定的局限性。伴随着大数据、人工智能技术和硬件算力的发展, 基于数据驱动的智能故障诊断方法能够自动从海量的数据中提取关键故障特征, 从而实现端到端的诊断方法, 具有广阔的发展前景和研究价值。

1.2.2 四旋翼无人机容错控制研究现状

四旋翼无人机作为典型的非线性、欠驱动系统, 在外界复杂环境下发生故障

时,如何高效地开展容错控制具有重要的意义。容错控制系统的目标就是当四旋翼无人机发生故障时,控制系统仍然能够让四旋翼无人机保持状态稳定或者是处于一个可接受的性能损失范围之内,从而保证无人机在故障情况下仍然能完成既定任务或者确保飞行安全。当前主流的容错控制方法通常可分为主动容错控制(Active Fault Tolerant Control, AFTC)和被动容错控制(Passive Fault Tolerant Control, PFTC)这两类^[39]。

主动容错控制首先需要了解四旋翼无人机的故障信息,然后针对不同故障类型更改相应的控制策略,具有更好的容错控制性能。而被动容错控制则不需要知道故障信息,其核心在于提升控制器的鲁棒性,这样即使发生了故障也能确保飞行安全。Ke 等人^[40]提出一种可以实现单、双和三电机完全失效的被动容错控制器,并通过仿真和真机飞行验证了控制器的可靠性。王君等人^[41]提出了一种自适应非奇异快速积分终端滑模控制器,用来解决四旋翼无人机的执行器故障问题。张思洁等人^[42]针对四旋翼无人机的执行器故障,设计了一种基于鲁棒全局快速终端滑模控制算法的有限时间容错控制器,其仿真实验证明了容错控制器的有效性。周丹等人^[43]针对无人机存在的传感器偏置故障,提出了一种反步法和滑模控制的容错控制方法。任朝晖等人^[44]提出一种基于模糊增益滑模的容错控制方法,该方案能确保执行器发生故障后仍能够实现精确的轨迹跟踪。Nan 等人^[45]针对单电机完全失效的故障,提出了一种基于非线性模型预测方法(Nonlinear Model predictive control, NMPC)的容错控制器。当前,绝大多数四旋翼无人机容错控制方案是基于模型的方法或者是经过反复参数调整后的比例-积分-微分(Proportional Integral Derivative, PID)控制器。这些容错控制方案虽然取得了巨大的成功,但是存在过度依赖精确的数学模型和专家先验知识的缺陷,已经难以满足未来对无人机智能化水平不断提升的需求。

随着人工智能和硬件算力水平的大幅提升,近年来基于学习的控制方法得到广泛关注,尤其是基于强化学习(Reinforcement Learning, RL)的智能控制方法取得了一定的进展^[46]。在强化学习框架中,通常无需了解无人机和环境的精确数学模型。无人机通过与环境不断进行试错交互获取大量数据,然后从这些反馈数据中学习到满足指标要求的一个最优控制策略^[47]。在一些任务中,例如四旋翼无人机飞行竞速,基于强化学习的方案往往能取得非常好的效果^[48]。因此,强化学

习也被一些研究人员引入了容错控制领域。Jiang 等人^[49]提出一种将强化学习和模型预测方法（Model predictive control, MPC）相结合的主动容错控制方法。该方法通过补偿不同执行器故障下的输入控制信号来确保四旋翼无人机的稳定。徐鑫峰等人^[50]在零和博弈的框架下结合强化学习算法,实现了四旋翼无人机在恶意欺骗攻击下的容错控制。Liu 等人^[51]使用强化学习作为辅助控制器,通过补偿电机控制量实现了四旋翼无人机的执行器容错控制。Sohège 等人^[52]结合强化学习和 PID 控制实现了一个混合容错控制器。该容错控制器通过强化学习调整 PID 控制器的参数,能够实现无人机在有风干扰和噪声干扰情况下的容错控制任务。Sharma^[53]等人基于软演员-评论家强化学习算法实现了一个免模型的容错控制方法。该方法通过控制输出脉冲宽度调制（Pulse Width Modulation, PWM）值的变化量,在无人机单执行器完全失效的情况下,实现了在悬停、轨迹跟踪和降落等情况的容错控制。Dooraki 等人^[54]通过强化学习实现了一个端到端的容错控制方案。该方案中,基于生物启发的强化学习策略网络直接输出角速度送给四旋翼无人机模型,并在仿真中完成单、双电机完全失效的容错控制。Wang 等人^[55]同样使用强化学习设计了一个能够实现执行器出现部分效率损失故障下的端到端容错控制器。实验证明,该方案相比传统 PID 控制器在发生故障下的表现更好。然而,实现一个完全端到端的强化学习容错控制器不仅需要漫长的训练时间,而且泛化性能较弱。

综上所述,容错控制对于四旋翼无人机的飞行安全非常重要,有效的容错控制不仅能够确保四旋翼无人机的自身安全,还能显著降低因故障导致的财产损失和人员伤亡风险。传统的容错控制方法依赖于精确的数学模型或繁琐的调参过程,因而在智能化方面面临严峻挑战。而基于强化学习的容错控制方法能够从大量飞行数据中学习到一个最优策略,有效克服了传统方法的局限性。因此,为进一步提高四旋翼无人机的安全性和智能化水平,开展基于强化学习的容错控制研究具有重要的研究意义。

1.3 研究内容与章节安排

本课题针对四旋翼无人机飞行过程中常发生的执行器故障和传感器故障,开展基于数据驱动的故障诊断与容错控制研究,克服了传统方案中依赖专家先验知

识、复杂特征工程和精准数学模型的缺陷。首先，设计了一个基于 CNN 和 Transformer 的故障诊断模型，能够实现轻量化的同时有效提取局部和全局关键故障特征。其次，设计了一个基于强化学习的容错控制方法。该方法融合了 SAC 强化学习和 PID 控制器，用于增强四旋翼无人机的容错控制能力。最后，搭建了包含软件在环仿真和硬件在环仿真的无人机故障诊断与容错控制实验平台，在该平台上通过仿真实验验证了本文所提方法的有效性。具体研究内容如下：

第一章为绪论部分，主要阐述了本课题的研究背景及意义，介绍了四旋翼无人机故障诊断与容错控制的国内外研究现状，说明了基于数据驱动方法的广阔前景。最后给出了本文的研究内容和章节安排。

第二章为相关理论和算法基础，主要介绍了本文所用深度神经网络的基本理论，并对强化学习的基本概念做了说明。最后介绍了本文所使用的高物理准确度的四旋翼无人机仿真平台及其故障注入功能的使用。

第三章为基于深度学习的四旋翼无人机故障诊断方法。首先，提出了一种融合卷积神经网络和 Transformer 的故障诊断模型，并详细介绍了该模型在轻量化、局部特征提取能力和全局特征提取能力的设计。其次，说明了在仿真实验平台上所进行的故障数据集构建工作。最后，通过该数据集，在与其他故障诊断模型的对比实验中验证了本文故障诊断模型的性能。

第四章为基于强化学习的四旋翼无人机容错控制方法。首先，提出了一种结合 PID 控制和强化学习的容错控制方法。该容错控制方法通过软演员-评论家强化学习算法对 PID 控制器的输出量进行有效补偿，增强了四旋翼无人机的容错控制能力。其次，介绍了基于强化学习的四旋翼无人机容错控制框架。最后，在具有执行器故障和传感器故障的仿真实验环境下，验证了本文所提出的容错控制方法的有效性。

第五章为总结和展望，对本文所开展的基于数据驱动的四旋翼无人机故障诊断与容错控制的工作进行了全面的总结，说明了本文所提方法的不足之处，并对未来的工作进行了展望。

第2章 相关理论与算法基础

2.1 引言

近年来,人工智能技术和计算硬件设备的迅猛发展为四旋翼无人机故障诊断与容错控制领域提供了新的问题解决思路,而深度学习和强化学习则在该领域中展现出了巨大的应用潜力。本章将介绍 CNN、Transformer 以及强化学习的基本原理与流程,同时给出本文所使用的仿真实验平台说明,为后续的研究提供理论和实验基础。

2.2 卷积神经网络

卷积神经网络是一种经典的深度学习模型,特别适合处理具有明显空间结构的数据,因此起初被用于计算机视觉领域。卷积神经网络具有局部连接、参数共享、平移不变性等特点,通过卷积操作不仅能够有效提取局部特征,同时还显著降低了模型的复杂度。由于卷积神经网络的强大局部特征提取能力,其在智能故障诊断等领域中也发挥着重要的作用,各类基于 CNN 的故障诊断模型层出不穷^[56]。如图 2-1 所示,一个用于分类任务的现代卷积神经网络的基础结构主要包括多个交替的卷积层、批归一化层、激活层和池化层。最后一个卷积模块输出的特征信息数据会被展平,然后送入全连接层(Fully Connected Network, FC)进行分类。下面分别对卷积神经网络中各组成部分作介绍。




图 2-1 卷积神经网络结构

(1) 卷积层

卷积层的核心是卷积运算,其通过一定尺寸的卷积核实现对输入数据的局部

特征提取。卷积核可以看作成特征提取器，不同的卷积核相当于针对不同特征的提取器。同时，每一个卷积核的参数都是通过训练获取，不需要手动设置卷积核的参数。卷积核会在输入数据上按照设定的移动步长（Stride）进行滑动操作，每一次滑动都可以看成一次特征提取操作。具体来说，卷积核的每一个参数会与数据窗口内的元素进行逐元素相乘再相加，得到相应的特征图（Feature map）。如果输出特征图的对应位置数值较高，则说明在该位置上的输入数据出现的特征与卷积核的特征相符，这样就实现了特征提取。随后，卷积核会继续在输入数据按照设定的步长进行滑动，直至所有数据都被卷积完。一个简化的、不考虑偏置量的卷积操作如图 2-2 所示。从图 2-2 中也可以发现，卷积操作会导致输出的特征图尺寸相比输入发生变化。为了解决这一问题，可以通过填充（Padding）或者调整步长来控制输出特征图的尺寸。单层卷积网络由于较小的感受野，导致整个网络难以提取高层次的特征信息。因此，通常需要叠加多个卷积模块形成深度网络结构来逐步扩大网络的感受野，从而实现对输入数据更高层级的特征抽象。




图 2-2 卷积过程示意图

（2）批归一化层

批归一化（Batch Normalization, BatchNorm）技术于 2015 年提出^[57]，因此早期的卷积神经网络并没有采用，但是一个现代卷积神经网络通常会加入批归一化层。批归一化会计算每个批次的均值和方差，然后对整个批次的数据进行归一化，最后使用可学习的缩放因子和偏置参数调整批次数据的分布，能够加速网络训练、缓解梯度流动问题以及提升模型的泛化性能，其计算过程如下所示：

$$BatchNorm = \gamma \frac{x - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} + \beta \quad (2-1)$$

$$\mu_B = \frac{1}{m} \sum_{i=1}^m x_i \quad (2-2)$$

$$\sigma_B^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2 \quad (2-3)$$

式中， x 代表输入特征数值； μ_B 代表当前批次的均值； σ_B^2 代表当前批次的方差； γ 和 β 是可学习的缩放和平移参数； ε 用于防止除数为零。

(3) 激活函数层

激活函数是构成各类神经网络的一个重要组成部分，通过对输入信号开展非线性变换，不仅能够增强神经网络的非线性建模能力，同时还能够缓解网络训练过程中可能出现的梯度消失和梯度爆炸问题^[58]。神经网络常用的激活函数包括 Sigmoid 函数、线性整流函数（Rectified Linear Unit, ReLU）和高斯误差线性单元函数（Gaussian Error Liner Unit, GELU）。下面简单介绍这三个激活函数。

Sigmoid 函数是一个在早期神经网络中被广泛使用的一种激活函数，其图像如图 2-3 所示。从图 2-3 可以看出 Sigmoid 是一个连续、光滑的函数，其导数简单且方便计算，可以将任何输入值映射到 0 到 1 的区间中。但是 Sigmoid 函数在输入值较大或者较小时，其导数变得很小，从而导致在训练过程中梯度会快速衰减。

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (2-4)$$




图 2-3 Sigmoid 激活函数

ReLU 函数是当前在各类神经网络中大规模使用的激活函数之一，其数学表达式可见公式（2-5），图像见图 2-4。从图 2-4 中可以看出，ReLU 函数仅在输入值为正数时会被激活且为恒等映射，此时导数为 1；输入值为负时会直接将数值

置为 0，导数也为 0。ReLU 的这种特性为神经网络引入了稀疏性，使得其空间和时间复杂度较小，同时还能够避免在神经网络训练过程中出现类似 Sigmoid 函数的梯度流动问题，因此成为很多深度神经网络的首选激活函数。

$$\text{ReLU}(x) = \max(0, x) \quad (2-5)$$




图 2-4 ReLU 激活函数

GELU 激活函数最早在 2016 年被提出^[59]，是一个平滑的非线性激活函数。GELU 激活函数的近似表达式如公式（2-6）所示，其图像见图 2-5。

$$\text{GELU}(x) \approx 0.5x(1 + \tanh(\sqrt{2/\pi}(x + 0.044715x^3))) \quad (2-6)$$

从其数学表达式和图像可以看出当输入值为正时，GELU 函数为恒等映射，而当输入值为负时则保留小幅输出，从而避免出现 ReLU 函数将负输入值直接置 0 的问题。这种特性使得 GELU 在训练深度神经网络时可以更容易地传播梯度、加速模型的收敛速度。GELU 函数在当前各类基于 Transformer 的深度学习模型中被广泛使用。




图 2-5 GELU 激活函数

(4) 池化层

池化是卷积神经网络常用的下采样手段。通过池化层，不仅可以有效降低特征图尺寸，还能提高网络的鲁棒性。常用的池化操作包括最大池化和平均池化。最大池化是在池化窗口内取最大值，而平均池化则是在池化窗口内取平均值。如图 2-6 所示，一个 4×4 通道为 1 的特征图在经过步幅为 2、池化窗口为 2×2 的最大池化和平均池化操作后就可以分别得到大小为 2×2 通道为 1 的特征图。




图 2-6 最大池化和平均池化操作示意图

(5) 全连接层

如图 2-7 所示，一个典型的全连接层包含输入层、若干隐藏层和输出层。一般来说，在卷积神经网络中，特征数据在经过最后一个卷积模块之后会被展平为向量，然后送入全连接层以进一步提取特征。全连接层中的每一个神经元都会与前一层的所有神经元相连接，从而实现全局特征整合和学习高级特征。在分类任务中，全连接层会输出类别得分。




图 2-7 全连接层示意图

2.3 Transformer 神经网络

Transformer 模型由 2017 年被提出，最初应用于自然语言处理领域的序列到

序列任务，并在机器翻译的任务中取得了前所未有的成功^[60]。Transformer 是一个完全基于自注意力机制来捕捉输入和输出序列之间全局依赖关系的模型，解决了 RNN 及其变体长距离建模能力不足和无法并行计算的问题。自注意力机制的成功应用，不仅使得模型能够有效处理序列数据中长距离依赖问题，并且实现了对时序数据的并行计算。如图 2-8 所示，一个典型的 Transformer 为编码器-解码器结构。在实际应用中，Transformer 通常会叠加多个相同的编码器或者解码器以增加网络深度和增加模型表示能力，而每一个编码器和解码器都是由若干个相同的层叠加而成。由于本文的主要目的是利用 Transformer 提取故障特征进行故障诊断的工作，而不是生成新的故障序列或者其他任务，因此本文将主要介绍解码器的结构和原理。Transformer 编码器主要包含多头注意力机制（Multi-Head Self-Attention）、前馈神经网络（Feed-Forward Neural Network, FFN）、残差连接（Residual Connect）和层归一化（Layer Normalization, LayerNorm）。




图 2-8 Transformer 总体结构图

(1) 嵌入层和位置编码

嵌入层（Embedding）的目的是将每一个输入序列映射为固定维度的嵌入向量，从而对输入序列进行编码。同时，由于 Transformer 完全摒弃了卷积和循环神经网络结构，这导致 Transformer 无法知晓输入序列中的位置关系。为了解决这一问题，Transformer 会在经过嵌入层处理后的数据中加入位置编码（Positional Encoding, PE），从而建模序列之间的相对位置或者绝对位置关系，其采用的正余弦位置编码计算公式如下所示：

$$PE_{(pos, 2i)} = \sin(pos / 10000^{2i/d_{model}}) \quad (2-7)$$

$$PE_{(pos, 2i+1)} = \cos(pos / 10000^{2i/d_{model}}) \quad (2-8)$$

式中， pos 是序列在序列集合中位置； i 是嵌入向量中的维度索引； d_{model} 是嵌入向量的维度。由于位置编码的维度和嵌入维度会设置成相同的维度，因此位置编码向量和嵌入向量会直接相加，从而让模型捕捉到序列间的位置关系。

（2）多头注意力机制

Transformer 的成功不仅归结于其出色的架构设计，很大程度上也归功于其多头自注意力机制的成功实现。自注意力机制可以帮助模型从一开始就能有效地捕捉输入序列中的全局依赖关系，其基本结构如图 2-9 所示。




图 2-9 多头注意力机制结构图

首先嵌入向量矩阵 $X \in \mathbb{R}^{n \times d_{model}}$ ，其中 n 为嵌入向量的个数，会经过三个不同的线性变换生成查询（Query）矩阵 Q 、键（Key）矩阵 K 和值（Value）矩阵 V 。随后， Q 和 K 的转置会进行点积运算，点积运算的结果会经过 Softmax 函数进行归一化，从而得到注意力得分矩阵。注意力得分矩阵会与 V 做乘法得到特征的

加权映射。以上过程可以用如下的计算公式表示：

$$Q = XW_Q \quad (2-9)$$

$$K = XW_K \quad (2-10)$$

$$V = XW_V \quad (2-11)$$

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (2-12)$$

式中， $W_Q \in \mathbb{R}^{d_{model} \times d_q}$ 、 $W_K \in \mathbb{R}^{d_{model} \times d_k}$ 和 $W_V \in \mathbb{R}^{d_{model} \times d_v}$ 均为可学习的线性映射矩阵； $1/\sqrt{d_k}$ 是一个缩放因子，用来将点积的结果进行缩放，从而缓解 Softmax 函数带来的梯度消失问题； d_q 、 d_v 和 d_k 分别代表 Q 、 V 和 K 的维度。由于 Q 和 K 的转置需要进行矩阵乘法运算，所以 $d_q = d_k$ 。

Transformer 会并行计算多个注意力头，通过不同的线性投影捕捉输入数据在不同子空间的长距离依赖关系，最后将各个头的输出拼接在一起，再通过线性变换映射到目标维度。以上过程可用如下计算公式说明：

$$head_i = Attention(QW_i^Q, KW_i^K, VW_i^V) \quad (2-13)$$

$$MultiHead(Q, K, V) = Concat(head_1, \dots, head_h)W^O \quad (2-14)$$

式中， $W_i^Q \in \mathbb{R}^{d_{model} \times d_k}$ 、 $W_i^K \in \mathbb{R}^{d_{model} \times d_k}$ 、 $W_i^V \in \mathbb{R}^{d_{model} \times d_v}$ 和 $W^O \in \mathbb{R}^{d_{model} \times hd_v}$ 都是可学习的线性变换参数； h 是多头注意力机制中的头数，其中 $d_k = d_v = d_{model} / h$ 。

（3）前馈神经网络

前馈神经网络的结构见图 2-10，主要包含两个线性变换层和一个 ReLU 激活函数层。第一个线性变换将输入映射到一个高维空间，并通过 ReLU 函数增强模型的非线性表达能力。第二个线性变换将数据特征映射回原始维度，从而确保总体输入和输出的维度相同。以上过程在数学上可用公式（2-15）表示。前馈神经网络的主要功能是对每个位置的表示进行独立的非线性变换，通过维度拓展增加参数进而支持模型学习复杂的特征，进一步增强模型的特征表达能力。

$$FFN(x) = max(0, xW_1 + b_1)W_2 + b_2 \quad (2-15)$$

式中， $W_1 \in \mathbb{R}^{d_{model} \times d_{ff}}$ 和 $W_2 \in \mathbb{R}^{d_{ff} \times d_{model}}$ 代表线性映射中的权重矩阵； $b_1 \in \mathbb{R}^{d_{ff}}$ 和

$b_2 \in \mathbb{R}^{d_{model}}$ 代表线性映射中的偏置项； d_{ff} 代表隐藏层的维度； $\max(.)$ 代表 ReLU 激活函数。




图 2-10 前馈神经网络结构图

（4）残差连接和层归一化

在 Transformer 模型架构中，每个子层都伴随着一个残差连接，残差连接的结果会经过层归一化操作，然后才会送入下一层网络结构。残差连接的核心思想是将输入直接加到网络层的输出上，从而缓解网络训练过程中出现的梯度消失问题，并能够促进深度网络的训练，防止神经网络退化。Transformer 也借鉴了该思路，并将其应用于模型中。层归一化对每个特征维度进行标准化，通过计算每个样本的均值和方差，用来稳定特征分布。使用层归一化技术，可以稳定网络的训练过程，增强模型泛化能力，加速模型收敛。

2.4 强化学习基础




图 2-11 强化学习基本原理

强化学习（Reinforcement learning, RL）是机器学习领域下的一个分支，其主

要用于解决序贯决策任务，通过不断与环境进行试错交互，从而学习到一个可以最大化期望累计奖励的最优策略^[61]。强化学习的基本原理如图 2-11 所示，其主要要素由做决策的智能体（Agent）、环境状态（State）、动作（Action）和奖励（Reward）组成。在强化学习中，智能体在每个时刻 t 会处于某种环境状态 s_t 下，这个环境状态对智能体来说可能是完全可观测的或者部分可观测的，然后智能体会观察这个环境状态并根据相应的策略输出一个动作 a_t 作用到环境当中。环境可能会因为智能体的动作发生一些改变，会将按照设定好的奖励机制给予即时奖励 r_{t+1} 以及将动作执行后的下一轮状态 s_{t+1} 反馈给智能体。强化学习通过不断地重复以上过程，智能体会不断地在交互过程中优化策略从而最大化累计奖励的期望。强化学习的相关问题通常可以被数学表达为一个马尔可夫决策过程（Markov Decision Process, MDP）。MDP 由五个元素组成的元组 (S, A, P, r, γ) 表示，其中 S 表示所有可能状态的集合； A 表示所有可能动作的集合； P 表示状态转移概率，表示智能体在当前状态 s_t 下采取动作 a_t 转移到状态 s_{t+1} 的概率，其满足马尔可夫性，即下一个时刻的状态只取决于当前状态，而与过去的历史无关； r 是奖励，代表着环境给予的实时反馈； $\gamma \in [0, 1)$ 代表折扣因子。

在强化学习中，一个智能体的最终目标学习到一个能够最大化期望累计奖励的策略。策略可以公式（2-16）表示：

$$\pi(a|s) = p(A_t = a | S_t = s) \quad (2-16)$$

式中， $\pi(\cdot)$ 表示策略； $\pi(a|s)$ 表示在状态 s 下采取动作 a 的概率； A_t 为 t 时刻在状态 s 下的动作空间集合； S_t 为 t 时刻的状态空间集合。

策略需要考虑当前状态下不断与环境进行交互后的奖励之和。奖励之和被称为回报（Return），通常可用公式（2-17）表示：

$$G_t = r_t + \gamma r_{t+1} + \gamma^2 r_{t+2} + \dots \quad (2-17)$$

式中， G_t 即折扣回报； γ 用来平衡短期和长期的奖励，同时防止在一些任务中奖励值之和变成无穷大而影响算法收敛。 γ 越接近 0 代表更重视短期奖励，越接近 1 代表更关注长期奖励。

为了评估一个策略的好坏，可以使用价值函数来评估智能体处于某一个状态或在某一个状态采取某个动作之后的长期回报。价值函数主要包括状态价值函数

和动作价值函数。基于策略 π 的状态价值函数可以用 $V^\pi(s)$ 表示，其表示智能体在状态 s 所能得到的期望回报；基于策略 π 的动作价值函数可以用 $Q^\pi(s, a)$ 表示，其表示智能体在状态 s ，采取动作 a 之后的期望回报。状态价值函数和动作价值函数可以用下面公式表达：

$$V^\pi(s) = E_\pi[G_t | S_t = s] \quad (2-18)$$

$$Q^\pi(s, a) = E_\pi[G_t | S_t = s, A_t = a] \quad (2-19)$$

状态价值函数和动作价值函数同时还满足贝尔曼方程。贝尔曼方程描述了不同价值函数之间的迭代关系，而状态价值函数和动作价值函数对应的贝尔曼方程可用如下公式表示：

$$V^\pi(s) = \sum_a \pi(a | s) \left[\sum_r p(r | s, a) r + \gamma \sum_{s'} p(s' | s, a) V^\pi(s') \right] \quad (2-20)$$

$$Q^\pi(s, a) = \sum_r p(r | s, a) r + \gamma \sum_{s'} p(s' | s, a) V^\pi(s') \quad (2-21)$$

式中， s' 为下一状态。从公式（2-20）和公式（2-21）还可以看出动作价值函数和状态价值函数之间存在如下的联系：

$$V^\pi(s) = \sum_a \pi(a | s) Q^\pi(s, a) \quad (2-22)$$

有了价值之后就可以做策略评估和提升。一个最优策略 π^* 能够让价值函数最大化，会在每个状态下选择动作价值最高的那个动作。最优状态价值函数、最优动作价值函数和最优策略可用如下公式表达：

$$V^*(s) = \max_\pi V^\pi(s), \forall s \in S \quad (2-23)$$

$$Q^*(s, a) = \max_\pi Q^\pi(s, a), \forall s \in S, a \in A \quad (2-24)$$

$$\pi^*(a | s) = \arg \max_a Q^*(s, a), \forall s \in S, a \in A \quad (2-25)$$

按照学习方式分类，强化学习主要可以分为基于价值（Value-based）的方法、基于策略（Policy-based）的方法和基于演员-评论家（Actor-Critic）的方法^[62]。基于价值的方法通过估计状态或者状态-动作对的价值，来选择一个价值更高的动作作为输出。基于策略的方法则直接优化策略，通过策略梯度方法来最大化目标函数。基于演员-评论家的方法则结合了基于价值的方法和基于策略的方法的各自优势。该方法在训练过程中，演员负责根据当前状态输出动作，而评论家则输

出当前策略下对应的价值用于帮助提升策略。在完成训练后，只使用演员输出动作。演员-评论家的方法在很多强化学习任务中表现出优异的性能，因而在目前非常流行。

2.5 仿真平台介绍

2.5.1 平台介绍

基于数据驱动的四旋翼无人机故障诊断与容错控制方法依赖于大量的测试以获取足够的训练数据，而直接在真实四旋翼无人机开展故障实验不仅成本高昂，更有可能对操作人员带来潜在的安全威胁。因此，通用做法是在真机故障飞行实验之前，使用仿真平台进行数据的采集和算法的验证，以便提前发现可能存在的缺陷。一个功能强大且物理特性仿真还原度高的四旋翼无人机仿真平台不仅可以有效缩小仿真与真实飞行的差距，还可以减少试错成本。表 2-1 列出了 Gazebo^[63]，AirSim^[64]和 RflySim^[65]这三个优秀的四旋翼无人机仿真平台的主要特性。从表 2-1 可以看出相较于另外两个仿真平台，RflySim 仿真平台具有显著的优势，尤其是其具有物理特性准确度高、故障模块功能全和部署难度低等特性。这些特性降低了针对四旋翼无人机开展故障诊断与容错控制实验的难度。因此，本文采用 RflySim 作为四旋翼无人机故障诊断与容错控制的仿真平台。

表 2-1 仿真平台特性

特性	Gazebo	AirSim	RflySim
主要模型	机器人、四旋翼	汽车、四旋翼	多旋翼、固定翼
场景逼真度	中	高	高
硬件在环仿真	不支持	支持	支持
故障注入功能	否	否	支持
物理特性准确度	低	中	高
支持 Windows 环境	否	否	支持

RflySim 是基于模型设计理念而开发出的高保真无人系统飞行仿真平台，提供一系列用于开展无人系统健康评估与故障诊断研究的工具，支持不同类型故障的实时注入，以及实时获取无人机在各种故障状态下的飞行数据。同时，RflySim 不仅支持内部 Simulink 控制器的输入，同时还提供外部控制器的输入接口。利用

RflySim, 可以实现从数据采集、数据处理、故障注入、故障诊断以及容错控制的全流程部署, 实现从软件在环仿真 (Software-In-the-Loop, SIL) 到硬件在环仿真 (Hardware-In-the-Loop, HIL) 的一键运行。

2.5.2 故障注入模型

RflySim 提供的四旋翼无人机模型中的主要模块如图 2-12 所示, 主要包含输入模块、电机模块、刚体运动状态模块、力和力矩模块、传感器模块、输出模块以及故障注入模块。





图 2-12 简化的四旋翼无人机模型


输入模块主要包含电机的控制信号和外部的控制信号。电机模块的输入为脉冲宽度调制 (Pulse Width Modulation, PWM) 值, 输出为电机转速。力和力矩模块用于计算无人机所受到的外部力和力矩。刚体运动状态模块输入为机体所受的力和力矩, 输出机体坐标系下的速度、加速度, 以及地球坐标系下的速度、位置和欧拉角等状态信息。传感器模块主要包含环境模型、传感器模型和 GPS 模型。环境模型模拟了外部环境变量在四旋翼无人机在飞行过程中所产生的影响。传感器模块对磁力计、惯性导航单元进行了建模, 同时对传感器的输出加入了噪声。GPS 模型用于计算 GPS 数据。输出模块将数据进行打包, 发送给飞控或者其他模块。故障注入模块主要用于注入四旋翼无人机的各类故障, 例如执行器故障或者传感器故障。

图 2-13 中展示了可以用于注入传感器故障或执行器故障的简化模型。在 RflySim 中, 每一类故障都有唯一的故障编号 A、故障参数提取模块 D 和两个故

障参数向量 B 和 C。当 A 中的数值与 B 中的值相同时，会提取故障参数 C 中的数值。E 模块会根据故障参数向量 B 和 C 的值生成自定义的噪声信号。传感器故障产生的噪声信号会和原始传感器信号相加后输出。



(a) 传感器故障注入模块



(b) 执行器故障注入模块

图 2-13 RflySim 中简化的故障注入模型

四旋翼无人机的传感器在实际飞行过程中不可避免地会受到噪声干扰。在本文中，RflySim 给惯性测量单元（Inertial Measurement Unit, IMU）和 GPS 注入的噪声是均匀分布的噪声信号。具体来说：对于陀螺仪，三轴的噪声采样范围分别为 $[-0.05, 0.05, 0.05]$ 至 $[0.05, 0.05, 0.05]$ ；对于加速度传感器，三轴的噪声采样范围分别为 $[-0.5, 0.5, 1.0]$ 至 $[0.5, 0.5, 1.0]$ ；对于 GPS 传感器来说，北地东地球坐标系坐标噪声的采样范围分别为 $[-0.5, 0.5, 1.0]$ 至 $[0.5, 0.5, 1.0]$ 。传感器噪声是在上述噪声的基础上乘以一个噪声增益系数而得到的值。噪声增益系数越大，代表模拟的噪声强度就越高。

对于执行器故障考虑的是执行器效率损失故障。执行器效率损失故障表示执行器在运行过程中，由于一些原因（例如电机老化、螺旋桨破损）无法以预期效率工作的故障。在 RflySim 仿真平台中，该故障可用公式（2-26）表示：

$$a_i(t) = \tau_i a_i(t), i = 1, 2, 3, 4 \quad (2-26)$$

式中， τ_i 代表执行器的健康系数。

当 $\tau_i = 1$ 时, 表示四个电机都没有发生执行器效率损失故障; 当 $0 < \tau_i < 1$ 时说明无人机的第 i 个执行器出现了效率损失故障; $\tau_i = 0$ 时说明无人机的第 i 个执行器处于完全失效的状态; $a_i(t)$ 表示在当前时刻的第 i 个电机的控制量。

2.6 本章小结

本章主要阐述了本文所涉及的深度学习模型及其原理, 详细说明了 CNN、Transformer 和强化学习的核心概念, 为后续构建基于数据驱动的四旋翼无人机故障诊断与容错控制方法提供了理论基础; 其次还介绍了本文所使用的高保真四旋翼无人机仿真平台及其故障注入模型, 为后续的仿真实验打下了实践基础。

第3章 基于深度学习的四旋翼无人机故障诊断方法

3.1 引言

传统的故障诊断方法依赖专家的先验知识、精确的数学模型或者复杂的特征工程,已经无法有效应对现代四旋翼无人机对于智能化水平需求不断提高的现状。在各类数据驱动的方法中,基于深度学习的故障诊断方法能够自动挖掘潜藏在海量数据中故障特征,因此在智能故障诊断领域中得到日益广泛的应用。近年来,Transformer 及其各类变体以其强大的全局特征提取能力,在自然语言处理、图像识别以及智能故障诊断领域取得了巨大的成功。然而,一些研究表明由于缺少类似 CNN 中的归纳偏置能力,基于 Transformer 的方案在小规模数据集上可能无法取得满意的成果^[66]。因此,一些学者提出了融合 CNN 和 Transformer (CNN-Transformer) 的方案,并在智能故障诊断领域取得了显著进展^[67]。CNN-Transformer 模型能够结合各自模型的优势,展现出了强大的局部和全局特征提取能力。不过,Transformer 中多头注意力机制会给模型带来巨大的参数量和运算量,这无疑限制了其在故障诊断领域的应用。为了应对以上挑战,同时将 CNN-Transformer 模型的优势引入四旋翼无人机故障诊断领域,本文提出了一种轻量级基于 CNN-Transformer 神经网络模型的四旋翼无人机故障诊断方法:SPCFormer。在 SPCFormer 中,通过在轻量化的 CNN 结构中插入轻量高效注意力机制,实现了对局部关键特征地提取。同时,提出了一种轻量级注意力机制用于替代 Transformer 中自注意力机制,从而在有效提取全局故障特征的同时,降低了模型的复杂度。本章将具体介绍本文所提出的故障诊断模型 SPCFormer 的整体结构和故障诊断流程,最后给出实验结果验证 SPCFormer 的优越性。

3.2 基于 CNN-Transformer 模型的故障诊断方法

SPCFormer 的总体架构如图 3-1 所示,主要包含四个组成部件,分别是输入层、选择补丁模块 (Selective Patches Module, SPM)、选择通道模块 (Selective Channels Module, SCM) 和一个使用全连接网络的分类器。输入层用于将原始飞行数据进行标准化,从而方便网络训练,同时会对标准化后的数据进行分块嵌入

(Patch Embedding)。随后，数据会通过本文所提出的选择分块模块和选择通道模块进行处理，用于实现高效的局部和全局特征提取，同时降低模型的参数量和计算量。最后，通过一个线性映射将特征数据映射为类别得分，从而得到诊断结果。下面将重点介绍选择分块模块和选择通道模块的设计和流程。




图 3-1 SPCFormer 结构图

3.2.1 选择分块模块

(1) ConvMixer 网络

为了探究视觉 Transformer (Vision Transformer, ViT)^[68]在图像分类领域中取得巨大成功的原因，是其继承了 Transformer 的架构优势，还是因为使用了分块表示 (Patch-based representation) 的数据处理方式，文献[69]提出了一种结合分块嵌入和轻量级卷积结构的 ConvMixer 模型。ConvMixer 模型的网络结构如图 3-2 所示，主要由 Patch 嵌入层和若干堆叠在一起的 ConvMixer 层构成。Patch 嵌入层借鉴了 ViT 中将输入数据分块的思想，利用 CNN 将输入图片分割成若干固定大小的 patch，实现了对输入数据基于 patch 的特征嵌入。ConvMixer 层则使用深度可分离卷积将标准卷积分解成深度卷积和逐点卷积，通过这种操作不仅使得计算量和参数量大大减少，还能够提升模型对复杂数据特征的学习能力^[70]。在 ConvMixer 层中，深度卷积用于混合空间位置信息，逐点卷积用于混合通道位置信息，残差连接用于稳定特征信息和梯度的流动。经过 Patch 嵌入层、深度卷积和逐点卷积之后的特征数据会都被送入 GELU 和 BatchNorm，用于增强网络的非线性表达能力以及稳定训练过程。ConvMixer 网络通过简单的卷积网络结构代替 ViT 编码器，即使在没有特别进行参数优化的情况下，也能在一些任务中取得比 ViT 及其变体更好的成绩。这无疑证明了分块表示对输入数据进行处理的重要性。本文保留了 ConvMixer 网络中的 Patch 嵌入层，并对 ConvMixer 层做了一定

调整。




图 3-2 ConvMixer 网络结构图

(2) ECA-Net 模块

ECA-Net（Efficient Channel Attention Network）是一种轻量级的高效通道注意力机制，通过一维卷积代替全连接层实现了高效局部跨通道交互机制，在有效降低参数量的同时带来了更好的性能表现^[71]。如图 3-3 所示，对于输入特征图 $X \in \mathbb{R}^{H \times W \times C}$ ，其中 H 是高度维度， W 是通道维度， C 是通道维度，ECA-Net 会利用全局平均池化（Global Average Pooling, GAP）提取各通道的全局特征信息，其数学表达式如下所示：

$$y = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X_{i,j} \quad (3-1)$$

式中， $y \in \mathbb{R}^{1 \times 1 \times C}$ 代表各通道的全局特征。




图 3-3 ECA-Net 网络结构图

SE-Net 中的激励操作会使用两个全连接网络先降维后升维来学习通道之间的重要性，这可能会在提高网络参数量的同时降低模型的性能。为了解决这个问题，ECA-Net 通过一维卷积来代替全连接层，其可用公式（3-2）来说明：

$$w = \delta(CID_k(y)) \quad (3-2)$$

式中， CID 代表一维卷积； w 为各个通道的权重； δ 为 Sigmoid 激活函数； k 是自适应一维卷积核的大小，其值决定了各通道与其相邻通道的交互范围，可以用下数学公式计算：

$$k = \psi(c) = \left\lfloor \frac{\log_2(c)}{\gamma} + \frac{b}{\gamma} \right\rfloor \quad (3-3)$$

式中， γ 和 b 为可学习的参数； c 为通道维度。

最后，原始的输入数据会和通道权重向量做按元素乘积从而获得具有通道注意力的特征。在本文中，ECA-Net 主要用于给每个通道的不同 patch 分配各自的权重。

(3) 选择分块模块

四旋翼无人机飞行数据是典型的多变量时间序列，而基于 patch 的特征表示方法已经被证明是一个有效处理时间序列的技术^[72]。因此，本文结合 ConvMixer 模型和 ECA-Net 注意力机制，提出选择分块模块用于获取每个通道的特征表示。输入的多变量时间序列数据段可以表示为 $x \in \mathbb{R}^{M \times L}$ ，其中 M 是飞行数据的变量数， L 是一个数据段的时间步长。在本文中，每一个变量序列都将视为一个通道数据。图 3-4 展示了选择分块模块结构图。输入数据段的每一个通道都会沿着时间轴同时进行独立地分块处理，分块结果可以表示为 $x^{(i)} \in \mathbb{R}^{P \times N}$ ，其中 P 为 patch 的长度， N 是 patch 的数量， i 表示通道的序号。接下来，这些 patch 会被送入选择分块模块进行处理。选择分块模块首先使用一个卷积核大小为 3、步长为 1 的深度卷积对每一个通道的 patch 进行处理，用于提取每一个 patch 中局部细粒度特征。在深度卷积层之后，ECA-Net 用于筛选每个通道中最重要的 patch，同时抑制无用 patch 的特征信息。ECA-Net 的输出会被送入逐点卷积层。逐点卷积层通过卷积核大小和步长均为 1 的卷积操作，实现了在每个通道中不同 patch 之间的信息交换和整合。这样不仅有利于模型获取每一个通道上的关键局部特征信息，同时减少模型对序列中不必要信息的关注。经过逐点卷积后的输出会通过残差连接与选择分块模块的输入相加，从而增强特征表示的同时还改善了特征信息与梯度的流动。需要注意的是，在选择分块模块中，数据在经过深度卷积或逐点卷积后，会被送入 GELU 激活函数和批归一化层进一步处理，用于增加网络的非线性学习能力和稳定训练过程。这些通道特征表示会沿着通道维度方向进行拼接。选择分

块模块的输出是与输入形状相同的通道特征表示的集合。




图 3-4 选择分块模块结构图

3.2.2 选择通道模块

多头注意力机制让基于 Transformer 的故障诊断方案存在学习参数过多和计算量过大的问题，这限制了 Transformer 在故障诊断领域的应用。受文献[73]和文献[74]的启发，本文提出了选择通道模块，通过嵌入选择通道注意力机制（Selective Channel Attention, SCA）并结合卷积操作，实现了高效全局特征信息提取的同时显著降低了复杂度和参数量。图 3-5 展示了选择通道模块的结构图。




图 3-5 选择通道模块结构图

在将所有通道表示送入选择通道模块前，类似于 ViT，一个可学习的分类向量 Class Token（记为 CLS）会被加入输入通道特征表示集合的起始位置，用于表示来自不同通道的全局特征信息。CLS 分类向量最后会被单独提取出来，然后送入分类器用于输出诊断结果。选择通道模块的输入可用如下公式表示：

$$Z = [z_{class}, z_1, z_2, \dots, z_d], d = 1, \dots, c \quad (3-4)$$

式中， $Z_{class} \in \mathbb{R}^{1 \times d_m}$ 为 CLS； d_m 代表了 token 的维度； d 代表了通道特征的维度。

随后，CLS 和每一个通道特征表示会被整体嵌入作为 token，从而更好地学习不同通道表示之间的相关性，而不是不同时间步的相关性。选择通道注意力机制在聚合全局特征起到了关键作用。在选择通道注意力机制中，CLS 会计算其对应的查询向量、键向量和值向量，其他通道特征表示只会计算对应的键向量和值向量。因此只有 CLS 会对所有 tokens 计算注意力分数。下面将详细介绍上述流程。

首先，选择通道模块会通过 CNN 获取分别 CLS 的查询向量 $Q_C \in \mathbb{R}^{1 \times d_m}$ 、键向量 $K_C \in \mathbb{R}^{1 \times d_m}$ 和值向量 $V_C \in \mathbb{R}^{1 \times d_m}$ 。同样，通过 CNN 获取其他通道表示的键向量和值向量，并分别按照通道维度方向拼接在一起获得其他通道表示的键矩阵 $K_F \in \mathbb{R}^{c \times d_m}$ 和值矩阵 $V_F \in \mathbb{R}^{c \times d_m}$ 。其次，使用核大小为 1×1 的 CNN 代替全连接层进行特征映射。随后， K_F 和 K_C 会沿着通道维度方向进行拼接形成 $K \in \mathbb{R}^{(1+c) \times d_m}$ ， V_C 和 V_F 同样也会沿着通道维度进行拼接形成 $V \in \mathbb{R}^{(1+c) \times d_m}$ 。以上过程可以用以下的公式说明：

$$Q_C, K_C, V_C = \text{Conv}(z_{\text{class}}) \quad (3-5)$$

$$K_F, V_F = \text{Conv}([z_1, z_2, \dots, z_d]) \quad (3-6)$$

$$K = \text{Concat}(K_C, K_F) \quad (3-7)$$

$$V = \text{Concat}(V_C, V_F) \quad (3-8)$$

式中，Conv 表示卷积操作。随后， Q_C 会和 K 的转置进行乘法运算从而获取各通道的注意力得分。注意力得分向量会和 V 相乘得到全局通道特征表示，从而自适应的调整网络中的每个通道表示的贡献值。以上过程可用如下计算公式表达：

$$G = \text{SoftMax}\left(\frac{Q_C K^T}{\sqrt{d_m}}\right)V \quad (3-9)$$

式中， $1/\sqrt{d_m}$ 是一个缩放因子； G 被视为汇聚了所有通道重要的特征信息的表示，会和 V_F 进行拼接然后送入卷积映射层。这个过程可用如下公式表示：

$$C = [G, V_F] \quad (3-10)$$

式中 $C \in \mathbb{R}^{(1+c) \times d_m}$ 是 SCA 的输出。

需要指出的是，在本文中 d_m 和 d_k 的值是相等的。本文使用了和文献[74]相同结构的卷积映射来实现所有通道之间的跨通道信息交换与整合。通过部署了两个

卷积核大小和步长均为 1 的一维卷积网络，用以取代 Transformer 中的逐位置前馈网络，从而进一步降低参数量和计算量。同大多数深度学习模型一样，本文中会堆叠若干个 SCM，最后一个经过 SCM 的 CLS 将会被提取并被送入由一个简单的全连接层构成的分类器得出故障结果

3.3 实验设置及结果分析

所有实验均在同一台主机上完成，配置为 Intel i7-12700H CPU, RTX 3060 GPU, PyTorch 版本为 2.2.1。

3.3.1 数据采集


为了验证本章所提出的 SPCFormer 的有效性，本文在基于 RflySim 仿真平台的基础上，开展了软件在环仿真和硬件在环仿真的数据采集工作。在本章研究中，执行器故障和传感器故障在三种不同的飞行状态下（悬停、盘旋和速度控制）触发。数据采集频率设置为 100Hz。对于执行器故障，考虑了单电机的 100%效率损失、40%效率损失以及 70%效率损失的情况，以上三种情况分别记为类别 1、类别 2 和类别 3。传感器故障是对加速度计、GPS 和陀螺仪三个轴施加具有相同故障参数向量的噪声增益干扰，噪声的类型与参数可见小节 2.4.2，分别记为类别 4、类别 5 和类别 6。此外，正常运行状态记为类别 0。因此，在本文中共有六种故障类型和一种正常运行状态，具体可见表 3-1。

表 3-1 故障数据集


故障位置	故障类别	数据分布			标签
		训练集	验证集	测试集	
无	无故障	840	180	180	0
单电机	100%效率损失	630	135	135	1
单电机	40%效率损失	630	135	135	2
单电机	70%效率损失	630	135	135	3
加速度计	噪声	840	180	180	4
GPS	噪声	840	180	180	5
陀螺仪	噪声	840	180	180	6

图 3-6 展示了正常飞行状况和发生电机失控故障状态下飞行参数的变化情

况。图 3-6 中 v_x 、 v_y 和 v_z 代表无人机的速度； a_x 、 a_y 、 a_z 以及 w_x 、 w_y 、 w_z 分别代表四旋翼无人机在 XYZ 轴上的加速度和角速度信息； ϕ 、 θ 和 ψ 分别代表俯仰角、滚转角和偏航角。一个性能良好的故障诊断模型应该捕捉到这些飞行参数的变化。



(a) 无故障下的飞行参数变化



(b) 电机失效下的飞行参数变化

图 3-6 正常及故障时飞行参数变化图

3.3.2 数据处理

在神经网络训练过程中，增加样本数量可以让神经网络学习到更多的数据特征，能够减少过拟合风险，还能让模型的泛化能力更强。考虑到四旋翼无人机飞行参数数据序列是多变量的时间序列，因此本文使用滑动窗口技术用于从原始飞行数据中生成子序列。如图 3-7 所示，该方法将多变量的时间序列数据划分为多个相同长度的子序列，每个子序列都被视为一个新的训练样本。滑动窗口的大小 w 和滑动步长 s 决定了窗口的大小和数量。随着滑动窗口在四旋翼无人机飞行数据时间序列数据上移动，能够生成多个子序列，从而增加样本数量。




图 3-7 数据采集与处理

四旋翼无人机飞行参数包含速度、角速度、欧拉角等数据。由于这些数据具有不同的物理属性和量纲，直接使用原始飞行数据进行神经网络训练会导致模型训练效率低下。因此，需要使用归一化技术将原始飞行数据不同变量数据特征转换为相同的尺度，确保所有输入数据处于相同的数量级。本文中每个数据样本的每一个通道都会进行独立的 Z-Score 标准化（Z-Score Normalization），其数学计算式如下所示：

$$x' = \frac{x - \mu}{\sigma} \quad (3-11)$$

式中， μ 是样本数据的均值； σ 是样本数据的标准差； x 是原始样本； x' 是经过标准化处理的样本。

经过数据预处理之后，每个故障样本都被表示为一个包含多通道时间序列数据的数据段，为后续的故障诊断模型提供了高质量的数据输入。本文在 SIL 和 HIL 仿真实验中分别收集了 7140 个样本。如表 3-1 中所示，这些样本会按照按照 70%、15% 和 15% 的比例划分为训练集、验证集、测试集。训练集用于训练模型，而在验证集上损失最低的模型会被选为最佳模型在测试集上进行测试。

3.3.3 评价指标

为了充分体现本文所提出的四旋翼无人机故障诊断模型的有效性，本章选择准确率（Accuracy）、精确率（Precision）、召回率（Recall）和 F1 分数（F1-Score）衡量模型的故障诊断性能。参数量（Parameters, Params）和浮点数计算量（Floating Point Operations, FLOPs）则用来评估模型的轻量化水平。下面通过表 3-2 混淆矩阵来说明准确率、精确率、召回率和 F1 分数这四个指标。

表 3-2 混淆矩阵内容

混淆矩阵		真实值	
		Positive	Negative
预测值	Positive	TP	FP
	Negative	FN	TN

如表 3-2 所示，真正例（True Positive, TP）表示真实类别为正类且模型预测也为正类；假负例（False Negative, FN）表示真实类别为正类但模型预测为负类；假正例（False Positive, FP）表示真实类别为负类但模型预测类别为正类；真负例（True Negative, TN）表示真实类别为负类且模型预测也为负类。

准确率指的是所有预测正确的样本占总样本数的比例，反映了模型的整体诊断性能，其计算公式如下所示：

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3-12)$$

精确率指的是被预测为正类的样本中，实际为正类的样本所占的比例。用于衡量模型诊断结果的可靠性，精确率高的模型能够更准确地识别出真正的故障样本，其计算公式如下所示：

$$Precision = \frac{TP}{TP + FP} \quad (3-13)$$

召回率指的是预测为正类的样本占实际正类的比例，反映了模型对正类的诊断能力，其计算公式如下所示：

$$Recall = \frac{TP}{TP + FN} \quad (3-14)$$

F1 分数指的是精确率和召回率的调和平均值。F1 分数越高说明模型能够精确识别故障类别的能力越强，其计算公式如下所示：

$$F1-score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3-15)$$

需要指出的是上述评价指标适用于二分类任务，而本文的故障诊断是一个多分类任务。在多分类任务中，准确率、精确率和召回率需要针对每个类别单独计算，然后通过不同的方式汇总，主要包括宏平均（Macro Average）、微平均（Micro Average）和加权平均（Weighted Average）。本文使用的宏平均计算方式。宏平均会对每个类别单独计算指标数值后取平均，其计算公式如下所示：

$$Macro-average = \frac{1}{N} \sum_{i=1}^N Metric_i \quad (3-16)$$

式中， N 是类别的总数； $Metric_i$ 是第 i 个类别的评价指标。

Params 指的是模型在训练过程中参与训练的参数总数，可以用来衡量模型的空间复杂度；FLOPs 指的是模型从输入接受一个样本到输出结果的过程中所需要执行的浮点运算操作次数，可以用来衡量模型的计算复杂度。

3.3.4 结果分析

在本文的实验中，网络模型的训练采用 AdamW 优化器，优化器的学习率设置为 0.001，损失函数采用交叉熵损失函数（Cross-entropy），训练周期为 150 轮，批次大小为 64，Dropout 层的丢弃概率为 0.2。SPCFormer 的训练详细参数见表 3-3。

表 3-3 SPCFormer 实验参数设置

参数	值
批次大小	64
训练周期数目	150
优化器	AdamW
损失函数	交叉熵损失
Dropout	0.2
学习率	0.001
SPM 数目	3
SCM 数目	3
多头数目	1

为了验证本论文所提方法的优越性，本文选择与其他五种基于深度学习的故障诊断模型开展对比实验。这些模型分别是：基于 CNN 方法的 MDPS^[75]；基于

CNN-LSTM 方法的 MCNN-LSTM^[76]; 基于 CNN-Attention-GRU 方法的 DCA-BiGRU^[77]; 两个基于 CNN-Transformer 方法: MCSwin-T^[78]和 Convformer-NSE^[79]。CNN 是最常见的用于故障诊断的深度学习模型。基于 LSTM 和 GRU 的故障诊断模型相较于 CNN 可以额外提取时序特性信息。另外两个基于 CNN-Transformer 的故障诊断模型分别采用卷积和分块的方法, 从另一个角度验证本文方法的有效性。本章 3.3.3 节中介绍的评价指标用于评价各模型的故障诊断性能和轻量化水平。

表 3-4 准确率和复杂度实验结果

模型	SIL	HIL	复杂度(M)	
	Accuracy (%)	Accuracy (%)	Params	FLOPs
MDPS	92.53	95.55	0.234	4.842
MCNN-LSTM	94.48	92.08	0.095	11.090
DCA-BiGRU	97.60	95.37	0.100	8.424
MCSwin-T	97.24	97.42	1.946	58.006
Convformer-NSE	95.29	95.55	0.245	1.773
SPCFormer	99.11	99.46	0.015	2.501

表 3-5 精确率、召回率和表 F1 分数实验结果


模型	SIL			HIL		
	P	R	F1	P	R	F1
MDPS	93.30	92.91	93.00	95.95	95.34	95.54
MCNN-LSTM	94.36	94.44	94.38	93.55	91.77	92.09
DCA-BiGRU	97.75	97.46	97.58	96.29	94.87	95.17
MCSwin-T	97.30	97.43	97.32	97.48	97.24	97.34
Convformer-NSE	95.71	94.81	95.04	95.78	95.13	95.30
SPCFormer	99.21	99.20	99.20	99.53	99.47	99.50


注: P 代表精确率; R 表示召回率; F1 代表 F1 分数。

从表 3-4 和表 3-5 可以清楚看出本文所提出的 SPCFormer 在准确率、精确率和召回率相较于另外五种对比故障诊断模型均取得了最高值。在 SIL 数据集中, 这些指标分别取得 99.11%、99.21%和 99.20%, 在 HIL 数据集中这些指标分别取得 99.46%、99.53%和 99.47%, 同时模型复杂度为 0.015M Params 和 2.501MFLOPs。可以看出相较于另外五种对比故障诊断模型, SPCFormer 在准确率、精确率、召

回率和 F1 分数上均取得了最好成绩,表现出了优异的性能。具体而言,与 MDPS、MCNN-LSTM、DCA-BiGRU、MCSwin-T 和 Convformer-NSE 相比,SPCFormer 在 SIL 数据集中分别提高了 6.58%、4.63%、1.51%、1.87%和 3.82%,在 HIL 数据集中分别提高了 3.91%、7.38%、4.09%、2.04%和 3.91%。在 Params 和 FLOPs 这两个指标中,本文所提方法也具有一定的优势。虽然 Convformer 在所有六种故障诊断模型取得了最低的 FLOPs,但是其在故障诊断准确率、精确率、召回率和 F1 分数上的表现均差于 SPCFormer。以上结果证明了 SPCFormer 在保持轻量化的同时,还能确保故障诊断性能的高效和准确。


从表 3-4 和表 3-5 中还可以看出,MCswin-T 在对比的故障诊断模型中故障诊断结果仅次于 SPCFormer,因此使用混淆矩阵对诊断结果进一步分析。在本文中,混淆矩阵对角线上的值越接近 1 颜色就越深,说明故障诊断模型的在该类别上的分类效果越好。各故障诊断模型在 SIL 和 HIL 数据集上的混淆矩阵如图 3-8 和图 3-9 所示。从图 3-8 (f) 和图 3-9 (f) 可以看出 SPCFormer 对所有类别的分类准确率都接近 100%或为 100%,表明本文所提出的故障诊断模型对于各类故障的分类效果出色。MDPS、MCNN-LSTM、DCA-BiGRU 和 Convformer-NSE 主要在类别 0 和类别 2 上表现不佳,存在一定程度的相互误分类情况,这表明这些模型的特征提取能力需要进一步地提升。





(c) DCA-BiGRU


(d) MCSwin-T



(e) Convformer-NSE

(f) SPCFormer

图 3-8 各模型在软件在环仿真数据集的混淆矩阵



(a) MDPS

(b) MCNN-LSTM




图 3-9 各模型在硬件在环仿真数据集的混淆矩阵

为了更好地展示各模型的特征提取能力，本文使用 t-SNE (T-distributed Stochastic Neighbor Embedding) 算法将各模型的输出特征信息进行可视化。t-SNE 是一个常用的数据降维和特征可视化的方法，其利用线性投影将高维数据映射到一个低维空间中，可以清晰且直观地展示各故障诊断方法的特征提取能力。图 3-10 和图 3-11 分别展示使用 t-SNE 各故障诊断模型在 SIL 和 HIL 数据集提取特征的可视化图。从图 3-10 (f) 和图 3-11 (f) 可以看出，SPCFormer 未能将部分类别在三种不同飞行状态下的数据完全聚集起来，这体现在类内间距较大、分散。不过和其他故障诊断方法相比，SPCFormer 的不同类别之间的边界相对清晰、距离大小适中。而其他故障诊断方法相对于 SPCFormer 而言，部分类别的特征分散且不同类别的间距过小，表明这些模型在提取和区分不同类别下三种不同飞行状况的特征能力不佳。Convformer-NSE 的特征聚集能力表现相对出色，然而其

在类别 0 和类别 2 的分类效果不佳拖累整体表现。以上发现进一步证明 SPCFormer 在故障特征提取方面的出色性能。




图 3-10 各模型在软件在环仿真数据集的 t-SNE 可视化图




图 3-11 各模型在硬件在环仿真数据集的 t-SNE 可视化图

最后，为了验证本文所提出的选择分块模块和选择通道模块的有效性，分别设置了 2 个对比模型。首先，使用三个连续的 ConvMixer 层代替本文所提出的选择分块模块，该对比模型记为 S1。其次，使用多头个数为 4 的多头注意力机制代替本文所提出的选择通道注意力机制，该对比模型记为 S2。表 3-6 列出了两个

对比模型在 SIL 和 HIL 数据集上关于准确率和复杂度的结果。从表 3-6 可以看出, ECA-Net 作为一个轻量级的注意力机制, 对模型的复杂度影响很小, 而多头注意力机制则显著提高了模型的复杂度。同时, SPCFormer 相较于两个对比模型 S1 和 S2, 在 SIL 数据集上的准确率分别提高了 0.18%和 1.60%, 在 HIL 数据集上的准确率分别提高了 0.35%和 0.53%。以上结果证明了选择分块模块和选择通道模块设计的有效性。

表 3-6 消融实验结果

模型	SIL	HIL	复杂度(M)	
	Accuracy (%)	Accuracy (%)	Params	FLOPs
S1	98.93	99.11	0.015	2.489
S2	97.51	98.93	0.804	12.701
SPCFormer	99.11	99.46	0.015	2.501

3.4 本章小结

本章提出了一种融合 CNN 和 Transformer 的轻量级四旋翼无人机故障诊断模型 SPCFormer。该模型克服了对模型精确度、复杂特征工程以及专家先验知识的需求, 实现了端到端的智能故障诊断。在 SPCFormer 中, 飞行数据会通过选择分块模块充分提取每一个数据通道的局部关键特征, 随后通过选择通道模块自适应挖掘全局特征表示, 能够在实现模型轻量化的同时具备更有效的故障特征提取能力。最后, 从包含 SIL 和 HIL 无人机仿真平台中收集了不同飞行状态下的故障数据, 并构建了故障数据集。在该数据集中, 开展了与其他故障诊断方法的对比试验, 实验结果验证了本章所提方法的有效性。

第4章 基于强化学习的四旋翼无人机容错控制方法

4.1 引言

在实现对四旋翼无人机的故障诊断之后,通常需要一个有效的容错控制方法来处置故障,从而确保飞行安全。传统的四旋翼无人机容错控制方法往往需要精确的系统模型或者复杂的调参过程才能发挥最大效果。这些方法虽然在当前被广泛使用,并且在理论和实际应用中取得了巨大的成功,但是随着人们对于四旋翼无人机容错控制要求的不断提高,这些方法已经无法满足现实复杂、多变的动态环境。近年来,基于学习的控制方法逐渐兴起,这其中基于深度强化学习的容错控制方法吸引了不少学者的注意力。然而,完全基于强化学习的端到端容错控制方法不仅训练时间过长,而且存在泛化性能弱、稳定性差等问题,从而限制了这类方法在实际中的应用。基于此,本文提出一种结合 PID 控制器和强化学习的四旋翼无人机容错控制方法。该方法在保留四旋翼无人机原有 PID 控制器的同时,引入强化学习算法作为辅助控制器。强化学习控制器通过补偿 PID 控制器的输出电机控制信号,从而增强了系统的容错控制能力,同时避免了强化学习中不必要的空间探索,并减少了对模型先验知识的依赖。在仿真平台上进行了执行器和传感器故障下的容错控制实验,实验结果验证了本章所提方法的有效性。

4.2 基于 SAC 算法的四旋翼无人机容错控制方法

4.2.1 四旋翼无人机飞行控制框架

为了更好地实现四旋翼无人机的容错控制,首先需要对四旋翼无人机的底层飞行控制框架有一定的了解。在第一章中曾提到过四旋翼无人机是一个典型的欠驱动系统,体现在其具有四个控制输入却有六个自由度的输出。具体而言,这四个控制输入分别为四个电机的转速。四旋翼无人机控制系统通过调整每个电机的转速从而实现对总推力 f 、绕 X 轴的滚转力矩 τ_x 、绕 Y 轴的滚转力矩 τ_y 和绕 Z 轴的滚转力矩 τ_z 的控制。输出的六个自由度分别为位置上 XYZ 轴的平移和姿态上的滚转角 (θ)、偏航角 (ψ) 和俯仰角 (ϕ)。参考文献[80]可知,四旋翼无人

机只能跟踪四个期望指令，分别是期望位置 p_d 和期望偏航角 ψ_d ，而另外两个自由度，即期望的滚转角 θ_d 和期望的俯仰角 ϕ_d ，可由 p_d 和 ψ_d 计算得出。在上述符号中，下标 d 代表期望的状态信息。图 4-1 给出了四旋翼无人机的飞行控制闭环框图^[80]。




图 4-1 四旋翼无人机飞行控制闭环框图

由图 4-1 可以看出四旋翼无人机的底层飞行控制算法采用内外环的控制策略，分别是处于外环的位置控制器和处于内环的姿态控制器。同时，位置控制器和姿态控制器内部通常采用串级双闭环 PID 控制方法。位置控制器的输入是 p_d 以及来自四旋翼无人机的当前实际位置 p 和速度 v ，反解出期望的拉力 f_d 、 ϕ_d 和 θ_d 。姿态控制器则会根据输入的 ϕ_d 、 θ_d 、 ψ_d 以及来自四旋翼无人机的当前实际的欧拉角 Θ 和角速度 w ，解算出期望的三轴力矩 τ_d 。 f_d 和 τ_d 经过控制分配器会得到期望的转速 ω_d 。最后电机控制器会根据 ω_d 生成期望的电机控制指令，然后控制指令会被送入四旋翼无人机模型。因此，从设计容错控制器的角度来说，理论上可以从位置环、姿态环、速度环以及电机层等控制环路切入，采用替换原有控制器、更改控制器参数或者设计补偿机制等方法，从而提升容错控制效果。

从上述描述还可以看出，选择一个有效的控制器跟踪目标值对于实现四旋翼无人机的控制至关重要。在四旋翼无人机控制领域中，虽然近些年来不断有新的控制方法被提出，而且这些方法通过仿真或者真机实验验证了可行性，但是在工程领域中大规模应用的仍然是基于 PID 的控制方案^[81]。例如，PX4 作为被一款被实际广泛使用的开源飞控系统，其也采用 PID 控制方案。

PID 控制器具有结构简单、不需要精准的数学模型和运算简单等优点，只要

完成了比例系数 K_p 、积分系数 K_i 和微分系数 K_d 的参数整定，就能达到有效的控制效果。图 4-2 展示了经典 PID 控制器的工作原理。




图 4-2 经典 PID 控制原理框图

首先，当前时刻 t 下的期望值 $r(t)$ 会与实际值 $y(t)$ 做减法得到偏差 $e(t)$ ，可用如下公式表示：

$$e(t) = r(t) - y(t) \quad (4-1)$$

随后， $e(t)$ 会经过比例项、积分项和微分项进行并行运算，各自的结果会相加得到控制器的输出 $u(t)$ ，该过程可用如下公式表示：

$$u(t) = K_p e(t) + K_i \int_0^t e(\tau) d\tau + K_d \frac{de(t)}{dt} \quad (4-2)$$

4.2.2 SAC 强化学习算法

强化学习算法的通常学习目标是通过优化策略来最大化累积奖励的期望，然而这种方式可能会导致智能体在缺乏对环境的充分探索的时候就收敛到一个局部最优解。软演员-评论家（Soft Actor-Critic, SAC）强化学习算法能够在实现累积奖励的期望被最大化的同时，还能具有良好的探索能力^[82]。

SAC 是一种基于最大熵强化学习的离策略算法，在不少具有连续状态和动作空间的任務中取得很好的成绩。在强化学习的语境下，熵是对一个随机变量的随机程度的度量，其值越大说明策略会采取更加随机的动作，从而增加对环境的探索能力^[83]。具体而言，最大熵强化学习中的学习目标中还额外加入了一项熵的正则项：

$$\pi^* = \arg \max_{\pi} E_{\pi} \left[\sum_t r(s_t, a_t) + \alpha \mathcal{H}(\pi(\cdot | s_t)) \right] \quad (4-3)$$

式中， π 代表策略； $\mathcal{H}(\pi(\cdot|s_t))$ 代表策略 π 在状态 s_t 下的随机程度； $r(s_t, a_t)$ 代表在状态 s_t 下执行动作 a_t 获取的奖励； α 是温度系数，用来控制熵的权重，较大的数值代表更多探索，较小的数值代表更多利用。

SAC 算法作为深度强化学习 (Deep Reinforcement Learning, DRL) 的一种，通过借助深度神经网络的强大拟合和学习能力，实现对价值函数和策略函数的逼近，能够有效处理具有高维、非线性且连续的状态空间和动作空间。现代 SAC 算法通常包含两个 Q 网络、两个目标 Q 网络和一个策略网络，其参数可以分别用 Q_{θ_1} 、 Q_{θ_2} 、 $Q_{\bar{\theta}_1}$ 、 $Q_{\bar{\theta}_2}$ 和 π_ψ 表示。为了缓解对 Q 值的过高估计，SAC 使用了两个 Q 网络中较低的输出值。同时，SAC 引入了两个目标 Q 网络用于稳定训练过程。Q 网络会对动作价值进行拟合，其可用如下公式更新参数：

$$L_Q(\theta_i) = E_{(s_t, a_t, r_t, s_{t+1}) \sim D} \left[\frac{1}{2} (Q_{\theta_i}(s_t, a_t) - (r_t + \gamma(V_{\bar{\theta}_i})))^2 \right] \quad (4-4)$$

$$V_{\bar{\theta}_i} = \min_{i=1,2} Q_{\bar{\theta}_i}(s_{t+1}, a_{t+1}) - \alpha \log(\pi_\psi(a_{t+1} | s_{t+1})) \quad (4-5)$$

式中， D 代表经验回放缓冲区(Replay Buffer)； γ 代表折扣因子。

在 SAC 算法中，策略网络会输出高斯分布的均值和标准差，但是直接从该分布中进行采样会导致梯度无法传播。为了解决这个问题，策略网络的参数更新需要使用重参数化技巧来解决这一个问题。重参数化会从一个单位高斯分布 $\mathcal{N}$ 中采样，然后将采样值与标准差相乘并加上均值。因此，策略网络的输出可以表示为如下形式：

$$a_t = f_\psi(\epsilon_t; s_t) \quad (4-6)$$

式中， ϵ_t 是独立的标准正态分布噪声。因此对于策略网络的损失函数可以用如下公式表示：

$$L_\pi(\psi) = E_{s_t \sim D, \epsilon_t \sim \mathcal{N}} \left[\alpha \log(\pi_\psi(f_\psi(\epsilon_t; s_t) | s_t)) - \min_{\theta_i} Q_{\theta_i}(s_t, f_\psi(\epsilon_t; s_t)) \right] \quad (4-7)$$

同时，SAC 算法中引入了自动调整 α 的机制， α 的损失函数如下：

$$L(\alpha) = E_{a_t \sim \pi_t} [-\alpha \log \pi(a_t | s_t) - \alpha \mathcal{H}_0] \quad (4-8)$$

从上式中可以看出，当策略的熵大于目标的熵时，会减小 α ；反之会增加 α 的值。

4.2.3 容错控制方法设计

在之前的一些基于深度强化学习的四旋翼无人机容错控制研究中,有部分研究取代了原有的控制器,完全使用深度强化学习从而实现端到端的容错控制的方案。在这些研究中,强化学习的策略网络将当前的状态直接映射为电机的 PWM 控制信号、PWM 控制信号的增量或者力和力矩信号,实现了从状态数据到电机控制指令的直接映射。也有部分研究使用强化学习替换原有控制器中部分控制环路。然而,在本文的实验条件下,通过完全控制电机输入信号来实现容错控制非常困难,四旋翼无人机往往没有学习到任何经验就会直接“坠毁”。重要的是在强化学习中,如果没有好的动作,那么策略网络就很难学习到一个好的控制策略。同时,由于四旋翼无人机的控制特性,一旦强化学习的策略网络输出值出现突变,也有可能导导致容错控制失败。通过强化学习实现从零开始训练四旋翼无人机实现容错控制不仅开销巨大,而且稳定性不足、泛化性能差。




图 4-3 强化学习容错控制框架

因此,受文献[51]和文献[84]的启发,本文将强化学习和传统控制策略相结合,设计了一种融合 PID 控制和 SAC 强化学习的四旋翼无人机容错控制方法。本文构建的基于强化学习的四旋翼无人机容错控制框架如图 4-3 所示。该方法通过借助 PID 控制器的基础控制能力,有效约束强化学习中不必要的空间探索。强化学习控制器则从数据中学习,对 PID 控制器输出的电机控制信号进行有效补偿,进而增强系统的容错控制能力。

（1）动作空间

由于四旋翼无人机具有四个电机，因此 SAC 的动作空间维度为 4 维，分别代表四个电机控制信号的补偿量。在 RflySim 中，四旋翼无人机的每个电机输入控制信号限制在[0-1]区间。本文对于每个电机的补偿范围在[0-0.3]之间。由于 SAC 算法的策略网络的输出会经过 $\tanh$ 激活函数被映射到[-1,1]，故本文还会进一步地将策略网络的输出动作值映射补偿范围内。

（2）状态空间

状态是 SAC 算法所能观测的环境信息。在本文中，状态空间由两部分构成：故障信息状态以及四旋翼无人机自身状态。具体而言，四旋翼无人机的每一个故障状态会被映射成一个固定的三维向量，作为 SAC 输入状态空间的一部分。同时，四旋翼无人机当前距离目标点的位置误差、速度误差、角速度误差、欧拉角和加速度这些信息会被当成无人机的自身状态。这两个向量拼接在一起会被当成 SAC 算法的状态空间。

（3）奖励函数

奖励函数的设计对于深度强化学习算法来说非常重要，因为四旋翼无人机的最终目标就是需要找到一个能够最大化累计期望奖励的策略。奖励函数可以视为一个与强化学习算法进行交互的接口，只有通过设置适当的奖励函数，才能引导智能体做出期望的行为。在本文中，容错控制器的目标是实现在执行器故障或传感器故障下的稳定悬停控制。因此，奖励函数的设计主要考虑位置误差，适当加入对角速度误差的惩罚，同时还需要避免设计过于复杂的奖励函数带来的参数调整困难。综合以上，本文中的奖励函数设计如下：

$$R = -w_1 \|e_p\| - w_2 \|e_\omega\| \quad (4-9)$$

式中， e_p 代表当前位置与目标位置的距离； e_ω 代表角速度误差； w_1 和 w_2 代表权重系数，本文中为 0.8 和 1.2。

（4）神经网络结构

由于全连接网络的强大拟合能力，大多数深度强化学习算法中的策略网络和价值评估网络采用包含多个隐藏层的结构设计。策略网络和价值评估网络的结构如图 4-4 所示。策略网络采用具有两个隐藏层结构的全连接网络，每个隐藏层包含 256 个神经元，激活函数选择为 ReLU。策略网络的输入为当前的状态，输出

的是四个动作值。需要指出的是，策略网络还会通过全连接网络分别输出每一个动作的均值和标准差，因此策略网络的实际动作输出是经过 $\tanh$ 激活函数处理的对应均值和标准差的概率分布下的采样值。价值评估网络也同样采用包含两个隐藏层的结构，激活函数和神经元个数同策略网络。价值评估网络输入是状态和动作的拼接向量，输出对应的动作价值。




图 4-4 神经网络结构

4.3 实验设置及结果分析

4.3.1 实验参数设置

所有实验均在同一台主机上完成，配置为 Intel i7-12700H CPU, RTX 3060 GPU。实验终止条件是到达每个回合的最大步数以及位置误差、俯仰角或者滚转角超出设定的安全范围。SAC 相比其他强化学习算法的优势之一在于较少的超参数。本文在训练 SAC 的具体超参数如表 4-1 所示：

表 4-1 训练参数表

参数	值
学习率	0.0002
折扣因子	0.99
经验回放缓冲区大小	20000
批次大小	64
优化器	Adam

4.3.2 实验结果分析

为了验证方法的有效性,本文设置了定点悬停任务用来测试容错控制方案的有效性。悬停是四旋翼无人机最基本也是最重要的飞行状态之一,在航空摄影、低空物流和电力巡检等任务中发挥着重要作用。例如,在电力巡检任务中,四旋翼无人机通常需要能够实现稳定悬停,才能使用自身携带的传感器对电力设施进行精细观察。在整个仿真实验过程中,首先使用 PID 控制器将无人机从初始坐标 $[0,0,0]$ 移动到 $[0,0,5]$ 的位置处悬停,待飞行状态稳定后再注入执行器故障或传感器故障开始容错控制实验。具体而言,执行器故障考虑的是单电机发生 40% 的效率损失故障,传感器故障为加速度传感器发生噪声故障,噪声类型与参数与第三章加速度传感器故障参数相同,并分别在 SIL 和 HIL 仿真平台开展容错控制实验。需要指出的是,在 RflySim 仿真平台中对四旋翼无人机注入上述故障后,四旋翼无人机仍然能维持一个相对稳定的姿态。四旋翼无人机从初始坐标起飞到目标点的飞行过程中的位置变化如图 4-5 所示,图中蓝色线为参考值,橙红色线为实际值。




图 4-5 正常飞行位置变化

RflySim 使用北东地坐标系表示无人机的位置数据，因此默认 Z 轴(高度方向)的数值为负。为了方便展示实验效果，图 4-5 对 Z 轴的数据做绝对值计算。从图 4-5 可以看出稳定后四旋翼无人机的实际位置与参考位置的误差较小。RflySim 作为一个高保真度的四旋翼无人机仿真平台，为了让仿真结果尽可能接近真实的物理世界，会给传感器的输出加上均匀分布的噪声，同时会有一定的环境风因素干扰。因此无法做到一些研究中实际值与参考值十分贴合。为了评估容错控制方法的有效性，本章使用位置的平均绝对误差、最大误差以及位置误差的方差来评估容错控制器在悬停任务中的性能。

图 4-6 和图 4-7 分别展示了在 SIL 仿真下，PID 控制器和强化学习控制器在发生执行器故障和传感器故障情况下的位置绝对误差的变化曲线，同时表 4-2 和表 4-3 给出了实验中平均绝对误差和最大误差的值。图 4-8、图 4-9、表 4-4 和表 4-5 则是在 HIL 仿真下的对应结果。上述图中紫色线代表强化学习控制的控制效果，橙红色线代表 PID 控制器的控制效果。




图 4-6 SIL 仿真中执行器故障位置绝对误差曲线




图 4-7 SIL 仿真中传感器故障位置绝对误差曲线




图 4-8 HIL 仿真中执行器故障位置绝对误差曲线




图 4-9 HIL 仿真中传感器故障位置绝对误差曲线

表 4-2 SIL 仿真中执行器故障误差指标

控制方法	平均绝对误差(m)			最大误差(m)		
	x	y	z	x	y	z
PID	0.15	0.12	0.17	0.28	0.45	0.35
RL	0.06	0.07	0.06	0.16	0.15	0.14

表 4-3 SIL 仿真中传感器故障误差指标

控制方法	平均绝对误差(m)			最大误差(m)		
	x	y	z	x	y	z
PID	0.31	0.50	0.20	0.48	0.57	0.29
RL	0.37	0.44	0.04	0.59	0.52	0.12

表 4-4 HIL 仿真中执行器故障下误差指标

控制方法	平均绝对误差(m)			最大误差(m)		
	x	y	z	x	y	z
PID	0.11	0.07	0.15	0.34	0.19	0.34
RL	0.05	0.03	0.05	0.11	0.13	0.13

表 4-5 HIL 仿真中传感器故障下误差指标

控制方法	平均绝对误差(m)			最大误差(m)		
	x	y	z	x	y	z
PID	0.44	0.12	0.14	0.66	0.30	0.22
RL	0.36	0.06	0.05	0.54	0.14	0.12

从上述图中可以看出,基于强化学习的容错控制方案在悬停控制任务中明显优于 PID 控制器。除了在 SIL 仿真下的执行器故障容错控制实验外,RL 容错控制器产生的绝对误差曲线大部分时刻在 XYZ 三个轴上的都低于 PID 的控制方案。具体来说,在 SIL 仿真中的执行器故障容错控制实验中,相较于 PID 控制器,强化学习容错控制方案在 XYZ 三轴上的平均绝对误差分别降低了 60%、42% 和 71%;在传感器故障容错控制实验中,X 轴上的平均绝对误差提高了 19%,但是在 Y 和 Z 轴上下降了 12%和 80%。在 HIL 仿真实验中,RL 控制方案相较于 PID 控制器,在执行器故障控制实验中,XYZ 三轴上的平均绝对误差分别降低了 54%、43%和 66%;在传感器故障容错控制实验中,XYZ 三轴上的平均绝对误差分别降低了 18%、50%和 64%。同时,在最大误差这个指标上,RL 控制方法也明显优于 PID 控制器。

图 4-10 和图 4-11 给出了在 SIL 仿真实验中,RL 控制方法和 PID 控制器关于位置误差的标准差。图 4-12 和图 4-13 则是对应 HIL 仿真下的结果。位置误差的标准差代表了误差的波动情况,值越小说明控制效果越好。从图中可以看出,除了 SIL 仿真中传感器故障容错控制实验的 X、Y 轴和 HIL 仿真中传感器故障容错控制实验的 Z 轴之外,RL 控制器的位置误差的标准差均小于 PID 控制器,证明了 RL 控制器具有更小的位置误差波动,控制稳定性更佳。以上的仿真实验数据表明了基于 RL 的容错控制方法的有效性,该方案相较于 PID 控制器能够实现更小的位置误差和振荡幅度,在悬停状态下的容错控制性能出色。




图 4-10 SIL 仿真中执行器故障位置误差的标准差




图 4-11 SIL 仿真中传感器故障位置误差的标准差




图 4-12 HIL 仿真中执行器故障位置误差的标准差




图 4-13 HIL 仿真中传感器故障位置误差的标准差

4.4 本章小结

本章提出了一种结合 PID 控制器和 SAC 强化学习的四旋翼无人机容错控制方法。首先设计了基于强化学习的四旋翼无人机容错控制框架。该容错控制框架充分结合了 PID 控制和强化学习控制的各自特性，利用强化学习作为辅助控制器补偿 PID 控制器输出的电机控制信号，从而降低了对系统先验知识的要求，同时增强了系统的容错控制能力。其次，在 SIL 和 HIL 仿真中开展了针对执行器故障和传感器故障的容错控制实验。最后，通过与 PID 控制器在定点悬停任务中进行容错控制性能的比较，验证了本章所提方法的有效性。

第 5 章 总结与展望

5.1 本文总结

随着四旋翼无人机的应用领域不断被深化和拓展,有效的故障诊断与容错控制方法对于确保四旋翼无人机在飞行过程中的安全性、稳定性和可靠性至关重要。传统的故障诊断与容错控制方法通常依赖于精确的数学模型或者专家先验知识,已难以满足现代四旋翼无人机对智能化水平的需求。如何从海量的数据中学习已经成为当今时代的热点。随着人工智能技术和硬件技术的突飞猛进,基于数据驱动的故障诊断与容错控制方法具有更加广阔的研究价值、应用前景和适用范围。因此,本文结合当下先进的人工智能技术,开展了数据驱动的四旋翼无人机故障诊断与容错控制研究,提出了在发生执行器故障和传感器故障下的解决方法,并通过软件在环仿真和硬件在环仿真实验验证了方法的可行性。具体的研究工作如下:

(1) 对国内外四旋翼无人机的故障诊断与容错控制现状进行了比较详细地分析和阐述,指出了传统方案的不足之处,以及开展基于数据驱动研究的必要性和研究意义。

(2) 提出了一种基于 CNN-Transformer 模型的四旋翼无人机故障诊断方法。该故障诊断方法充分利用了卷积神经网络和 Transformer 在局部特征提取和全局特征提取方面的优势,同时克服了基于 Transformer 故障诊断模型复杂度高的问题。该方法中设计了一个融合 ECA-Net 和轻量化卷积网络的模块,用于充分提取输入数据的局部细腻度特征。同时,提出了一种选择通道模块,在有效聚合全局特征的同时降低了网络的复杂度。最后,通过软件在环仿真和硬件在环仿真实验平台构建了一个故障数据集,并在该数据集上与其他故障诊断方案开展了对比实验,实验结果验证了本文所提故障诊断方法的有效性。

(3) 提出了一种基于 SAC 强化学习和 PID 控制相结合的四旋翼无人机容错控制方法。该方法保留了基于 PID 的控制环路,通过引入强化学习控制器输出电机控制信号的补偿量,能够有效利用 PID 控制器的基础控制能力和强化学习控制器的自学习能力,从而增强了无人机系统的容错控制能力。在具有执行器故

障和传感器故障的仿真环境下开展了容错控制实验,实验结果证明了本文所提容错控制方法的有效性。

5.2 未来展望

本文虽然在四旋翼无人机的智能故障诊断与容错控制领域进行了研究,并提出了相应的基于数据驱动的故障诊断和容错控制方法,但是限于研究水平和条件所限,仍存在一些不足:

(1) 本文的故障诊断与容错控制算法没有在真实四旋翼飞行器上进行验证。虽然在研究中选择采用了一个高保真度的四旋翼无人机仿真平台,但是仿真和真实环境仍然存在较大差距,同时还需要克服机载计算机有限的计算能力和存储空间给算法部署带来的巨大挑战。

(2) 本文研究的故障种类数量比较有限。现实中的四旋翼无人机在飞行过程可能会出现多种不同类型的故障,因此还需要在数据采集和健康管理方面开展研究。

(3) 本文的容错控制部分在实验方面只考虑了一个定点悬停任务,并没有考虑轨迹跟踪或者其它飞行状态下的容错控制性能。因此,还需要对容错控制方法进行更多的训练。

参考文献

- [1] Wang S, Liu Z, Jia Z, et al. Fault detection for UAVs with spatial-temporal learning on multivariate flight data[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 2529517.
- [2] He K, Yu D, Wang D, et al. Graph attention network-based fault detection for UAVs with multivariant time series flight data[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 3530213.
- [3] 甄红涛, 齐晓慧, 夏明旗, 等. 四旋翼无人直升机飞行控制技术综述[J]. 飞行力学, 2012, 30(04): 295-299.
- [4] 安雪, 李少波, 张仪宗, 等. 无人机飞控系统故障诊断技术研究综述[J]. 计算机工程与应用, 2023, 59(24): 1-15.
- [5] Thanaraj T, Sai S, Ng B F, et al. Hardware-in-the-loop simulation for quadrotor fault diagnosis enhancing airworthiness using OS-Fuzzy-ELM[C]//2022 International Conference on Unmanned Aircraft Systems (ICUAS). IEEE, 2022: 263-272.
- [6] 陈汉泉, 陶杰, 鲁仁全. 多传感器数据融合下的无人机高度扩张状态观测器设计[J]. 控制理论与应用, 2024, 41(12): 2365-2373.
- [7] Sun X, Lai J, Lyu P, et al. Fault-tolerant navigation method aided by dynamics model of quadrotors based on federated unscented Kalman filter on Lie group manifold[J]. IEEE Sensors Journal, 2024, 24(21): 34828-34842.
- [8] Okada K F Á, Morais A S, Ribeiro L, et al. Fault-tolerant control for quadcopters under actuator and sensor faults[J]. Sensors, 2024, 24(22): 7299.
- [9] 田宇阳. 基于数据驱动的四旋翼无人机故障诊断与容错控制[D]. 兰州理工大学, 2020.
- [10] Furlas G K, Karras G C. A survey on fault diagnosis methods for UAVs[C]//2021 International Conference on Unmanned Aircraft Systems (ICUAS). IEEE, 2021: 394-403.
- [11] 聂瑞, 王红茹. 基于神经网络观测器的无人机编队执行器故障诊断[J]. 空天

- 防御, 2022, 5(02): 32-41.
- [12] 杨苏桥, 郑恩辉, 田琛, 等. 基于 EKF 残差的无人机 GPS 故障诊断方法[J]. 电光与控制, 2024, 31(07): 61-65+72.
- [13] 黄庆南, 祁静茹, 戴喜生, 等. 基于观测器的四旋翼无人机故障诊断方法[J]. 广西科技大学学报, 2023, 34(02): 69-75+83.
- [14] Falcón R, Ríos H, Dzul A. A robust fault diagnosis for quad-rotors: A sliding-mode observer approach[J]. IEEE/ASME Transactions on Mechatronics, 2022, 27(6): 4487-4496.
- [15] Ren X L. Observer design for actuator failure of a quadrotor[J]. IEEE Access, 2020, 8: 152742-152750.
- [16] 戴凌宇, 程赟, 冯张棋, 等. 基于故障发生程度的四旋翼无人机故障诊断[J]. 现代机械, 2024, (04): 77-83.
- [17] 罗瑞士, 李少波, 张安思, 等. 基于卷积神经网络的固定翼无人机故障诊断研究[J]. 计算机与数字工程, 2024, 52(11): 3370-3374+3385.
- [18] Zhang C, Wei S, Dong G, et al. Time-domain sparsity based bearing fault diagnosis methods using pulse signal-to-noise ratio[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 3516804.
- [19] 李润泽, 姜斌, 余自权, 等. 基于数据驱动的无人机集群故障检测与诊断[J]. 北京航空航天大学学报, 2024, 50(05): 1586-1592.
- [20] Yaman O, Yol F, Altinors A. A fault detection method based on embedded feature extraction and SVM classification for UAV motors[J]. Microprocessors and Microsystems, 2022, 94: 104683.
- [21] Zhang X, Zhao Z, Wang Z, et al. Fault detection and identification method for quadcopter based on airframe vibration signals[J]. Sensors, 2021, 21(2): 581.
- [22] 舒畅, 李辉. 基于小波与 GBDT 的无人机传感器故障诊断[J]. 测控技术, 2017, 36(08): 41-46.
- [23] 任利强, 王海鹏, 潘新龙, 等. 基于小波时频图与轻量级 CNN-Transformer 混合神经网络的复杂机动动作识别方法[J/OL]. 北京航空航天大学学报, 1-24[2025-03-22]. <https://doi.org/10.13700/j.bh.1001-5965.2024.0745>.

- [24] 刘洋, 程强, 史曜炜, 等. 基于注意力模块及 1D-CNN 的滚动轴承故障诊断[J]. 太阳能学报, 2022, 43(03): 462-468.
- [25] 刘星辰, 周奇才, 赵炯, 等. 一维卷积神经网络实时抗噪故障诊断算法[J]. 哈尔滨工业大学学报, 2019, 51(07): 89-95.
- [26] Yang P, Geng H, Wen C, et al. An intelligent quadrotor fault diagnosis method based on novel deep residual shrinkage network[J]. Drones, 2021, 5(4): 133.
- [27] Chen G, Li S, He Q, et al. Fault diagnosis of drone motors driven by current signal data with few samples[J]. Measurement Science and Technology, 2024, 35(8): 086202.
- [28] Steinhoff L, Koschlik A K, Arts E, et al. Development of an acoustic fault diagnosis system for UAV propeller blades[J]. CEAS Aeronautical Journal, 2024, 15(4): 881-893.
- [29] Huang J, Li M, Zhang Y, et al. Fault detection and classification for sensor faults of UAV by deep learning and time-frequency analysis[C] //2021 40th Chinese Control Conference (CCC). IEEE, 2021: 4420-4424.
- [30] Pascanu R, Mikolov T, Bengio Y. On the difficulty of training recurrent neural networks[C]//International conference on machine learning. PMLR, 2013: 1310-1318.
- [31] 张雅婷, 杨蒲, 孟宪锋, 等. 基于 CNLS-MMD 的孪生混合网络四旋翼飞行器故障诊断方法[J]. 航空科学技术, 2023, 34(12):125-134.
- [32] Sadhu V, Zonouz S, Pompili D. On-board deep-learning-based unmanned aerial vehicle fault cause detection and identification[C]//2020 IEEE international conference on robotics and automation (ICRA). IEEE, 2020: 5255-5261.
- [33] 李俊卿, 张承志, 胡晓东, 等. 基于 CNN-ViT 的滚动轴承故障类型识别方法[J]. 电力科学与工程, 2023, 39(02): 64-71.
- [34] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[J]. Advances in neural information processing systems, 2017, 30.
- [35] He Y, Shen W. Msit: A cross-machine fault diagnosis model for machine-level CNC spindle motors[J]. IEEE Transactions on Reliability, 2023, 73(1): 792-802.

-
- [36] Ahmad M W, Akram M U, Mohsan M M, et al. Transformer-based sensor failure prediction and classification framework for UAVs[J]. *Expert Systems with Applications*, 2024, 248: 123415.
- [37] Wang Z, Chen F, Miao Y. A fault diagnosis method of quadrotor UAV based on self-attention mechanism[C] //2023 7th International Symposium on Computer Science and Intelligent Control (ISCSIC). IEEE, 2023: 292-296.
- [38] Fang H, Deng J, Bai Y, et al. CLFormer: A lightweight Transformer based on convolutional embedding and linear self-attention with strong robustness for bearing fault diagnosis under limited sample conditions[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 71: 3504608.
- [39] Nguyen N P, Pitakwachara P. Integral terminal sliding mode fault tolerant control of quadcopter UAV systems[J]. *Scientific Reports*, 2024, 14(1): 10786.
- [40] Ke C, Cai K Y, Quan Q. Uniform fault-tolerant control of a quadcopter with rotor failure[J]. *IEEE/ASME Transactions on Mechatronics*, 2022, 28(1): 507-517.
- [41] 王君, 骆明敏. 具有执行器故障的四旋翼无人机自适应鲁棒滑模控制[J/OL]. *飞行力学*, 1-7[2025-03-22]. <https://doi.org/10.13645/j.cnki.f.d.20250214.004>.
- [42] 张思洁, 吴怀宇, 郑秀娟. 具有执行器故障的四旋翼无人机有限时间容错控制[J]. *控制理论与应用*, 2023, 40(07): 1270-1276.
- [43] 周丹, 陈诚, 杜一鸣. 基于传感器偏置故障的无人机容错控制设计[J]. *科学技术创新*, 2022, (25): 135-140.
- [44] 任朝晖, 刘玉麟, 姜泽宇, 等. 基于模糊增益滑模四旋翼无人机自适应容错控制[J]. *东北大学学报(自然科学版)*, 2024, 45(02): 209-216.
- [45] Nan F, Sun S, Foehn P, et al. Nonlinear MPC for quadrotor fault-tolerant control[J]. *IEEE Robotics and Automation Letters*, 2022, 7(2): 5047-5054.
- [46] Mahran Y, Gamal Z, El-Badawy A. Reinforcement learning position control of a quadrotor using Soft Actor-Critic (SAC)[C]//2024 6th Novel Intelligent and Leading Emerging Sciences Conference (NILES). IEEE, 2024: 72-75.
- [47] Cao Q, Liu Z, Yu H, et al. Autonomous landing of the quadrotor on the mobile platform via meta reinforcement learning[J]. *IEEE Transactions on Automation*

- Science and Engineering, 2025, 22: 2269-2280.
- [48] Kaufmann E, Bauersfeld L, Loquercio A, et al. Champion-level drone racing using deep reinforcement learning[J]. Nature, 2023, 620(7976): 982-987.
- [49] Jiang H, Xu F, Wang X, et al. Active fault-tolerant control based on MPC and reinforcement learning for quadcopter with actuator faults[J]. IFAC-PapersOnLine, 2023, 56(2): 11853-11860.
- [50] 徐鑫峰, 柳春, 黄骁, 等. 基于零和博弈的四旋翼无人机强化学习容错跟踪控制[J]. 无人系统技术, 2024, 7(06): 19-29.
- [51] Liu X, Yuan Z, Gao Z, et al. Reinforcement learning-based fault-tolerant control for quadrotor UAVs under actuator fault[J]. IEEE Transactions on Industrial Informatics, 2024, 20(12): 13926-13935.
- [52] Sohège Y, Quiñones-Grueiro M, Provan G. A novel hybrid approach for fault-tolerant control of UAVs based on robust reinforcement learning[C]//2021 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2021: 10719-10725.
- [53] Sharma P, Poddar P, Sujit P B. A model-free deep reinforcement learning approach to maneuver a quadrotor despite single rotor failure[J]. arXiv preprint arXiv:2109.10488, 2021.
- [54] Dooraki A R, Lee D J. Reinforcement learning based flight controller capable of controlling a quadcopter with four, three and two working motors[C]//2020 20th International Conference on Control, Automation and Systems (ICCAS). IEEE, 2020: 161-166.
- [55] Wang G, Wang X, Li Y, et al. Reinforcement learning-based fault-tolerant control for unmanned aerial vehicles[C]//2024 39th Youth Academic Annual Conference of Chinese Association of Automation (YAC). IEEE, 2024: 109-114.
- [56] Zhao Z, Jiao Y. A fault diagnosis method for rotating machinery based on CNN with mixed information[J]. IEEE Transactions on Industrial Informatics, 2022, 19(8): 9091-9101.
- [57] Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by

- p>reducing internal covariate shift[C]//International conference on machine learning. PMLR, 2015: 448-456.
- [58] 邱锡鹏. 神经网络与深度学习 [M]. 北京: 机械工业出版社, 2020.
- [59] Hendrycks D, Gimpel K. Gaussian error linear units (gelus)[J]. arXiv preprint arXiv:1606.08415, 2016.
- [60] Han K, Wang Y, Chen H, et al. A survey on vision Transformer[J]. IEEE transactions on pattern analysis and machine intelligence, 2022, 45(1): 87-110.
- [61] 吴勇, 彭辉, 熊峰钥. 结合类脑导航的强化学习无人机自主导航[J]. 计算机测量与控制, 2024, 32(07): 225-231.
- [62] 郑心怡. 基于 SAC 算法的机器人路径规划研究[D]. 中北大学.
- [63] Koenig N, Howard A. Design and use paradigms for Gazebo, An open-source multi-robot simulator[C]//2004 IEEE/RSJ international conference on intelligent robots and systems (IROS). IEEE, 2004, 3: 2149-2154.
- [64] Shah S, Dey D, Lovett C, et al. Airsim: High-fidelity visual and physical simulation for autonomous vehicles[C]//Field and Service Robotics: Results of the 11th International Conference. Springer International Publishing, 2018: 621-635.
- [65] Dai X, Ke C, Quan Q, et al. RflySim: Automatic test platform for UAV autopilot systems with FPGA-based hardware-in-the-loop simulations[J]. Aerospace Science and Technology. 2021, 114: 106727.
- [66] Lin T, Wang Y, Liu X, et al. A survey of Transformers[J]. AI open, 2022, 3: 111-132.
- [67] Chen H, Wei J, Huang H, et al. Novel imbalanced fault diagnosis method based on generative adversarial networks with balancing serial CNN and Transformer (BCTGAN)[J]. Expert Systems with Applications, 2024, 258: 125171.
- [68] Dosovitskiy A, Beyer L, Kolesnikov A, et al. An image is worth 16x16 words: Transformers for image recognition at scale[J]. arXiv preprint arXiv:2010.11929, 2020.
- [69] Trockman A, Kolter J Z. Patches are all you need?[J]. arXiv preprint arXiv:2201.09792, 2022.

-
- [70] Ma S, Liu W, Cai W, et al. Lightweight deep residual CNN for fault diagnosis of rotating machinery based on depthwise separable convolutions[J]. IEEE Access, 2019, 7: 57023-57036.
 - [71] Wang Q, Wu B, Zhu P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2020: 11534-11542.
 - [72] Nie Y, Nguyen N H, Sinthong P, et al. A time series is worth 64 words: Long-term forecasting with Transformers[J]. arXiv preprint arXiv:2211.14730, 2022.
 - [73] Liu Y, Hu T, Zhang H, et al. Itransformer: Inverted Transformers are effective for time series forecasting[J]. arXiv preprint arXiv:2310.06625, 2023.
 - [74] Yan S, Shao H, Wang J, et al. LiConvFormer: A lightweight fault diagnosis framework using separable multiscale convolution and broadcast self-attention[J]. Expert Systems with Applications, 2024, 237: 121338.
 - [75] Zheng J, Yang C, Zheng F, et al. A rolling bearing fault diagnosis method using multi-sensor data and periodic sampling[C]//Proceedings of the 2022 IEEE International Conference on Multimedia and Expo (ICME). IEEE, 2022: 1-6.
 - [76] Chen X, Zhang B, Gao D. Bearing fault diagnosis base on multi-scale CNN and LSTM model[J]. Journal of intelligent manufacturing, 2021, 32(4): 971-987.
 - [77] 罗浩, 何超, 陈彪, 等. 基于 Laplace 小波卷积和 BiGRU 的少量样本故障诊断方法[J]. 振动与冲击, 2022, 41(24): 41-50.
 - [78] Chen Z, Chen J, Liu S, et al. Multi-channel calibrated Transformer with shifted windows for few-shot fault diagnosis under sharp speed variation[J]. ISA transactions, 2022, 131: 501-515.
 - [79] Han S, Shao H, Cheng J, et al. Convformer-NSE: A novel end-to-end gearbox fault diagnosis framework under heavy noise using joint global and local information[J]. IEEE/ASME Transactions on Mechatronics, 2022, 28(1): 340-349.
 - [80] 全权. 多旋翼飞行器设计与控制 [M]. 北京: 电子工业出版社, 2018.
 - [81] Lopez-Sanchez I, Moreno-Valenzuela J. PID control of quadrotor UAVs: A survey[J]. Annual Reviews in Control, 2023, 56: 100900.

- [82] Haarnoja T, Zhou A, Abbeel P, et al. Soft actor-critic: Off-policy maximum entropy deep reinforcement learning with a stochastic actor[C]//International conference on machine learning. PMLR, 2018: 1861-1870.
- [83] 张伟楠. 动手学强化学习 [M]. 北京: 人民邮电出版社, 2022.
- [84] 卢颂硕. 基于强化学习的无人机抗风扰控制策略研究[D]. 哈尔滨工业大学, 2023.

攻读学位期间发表的学术成果

- [1] Guo L, Ren Y, Li R, et al. Effective Fault Diagnosis for A Quadrotor Helicopter: A Lightweight Transformer with Selective Patches and Channels Modules Method[J]. IEEE Transactions on Cybernetics (已发表).

致谢

每次都是到临近关头才觉得时间流逝之快，而这一次，是真的要和校园生活说拜拜了。七年的校园时光，从之前的懵懂、浑浑噩噩，到现在逐渐形成自己看待问题的思路，总归有了成长。回首过去，虽有波折，但也收获了有数不清的美好记忆。这一路上，正是因为有父母、老师和朋友的帮助和支持，我才能做好自己的选择，踏实地走好每一步。

首先，我要衷心地感谢我的父母，感谢你们对于我每一次选择的无条件支持。漫漫求学路，如果没有父母的无私帮助和奉献，就没有我今天的成长。希望未来我能早日真正成为你们的依靠。

其次，我要特别感谢郭黎老师，感谢郭老师在我研究生生涯里对我的理解、包容和指导。在我学术研究和生活中遇到困难时，郭老师能够及时指引我走向正确的方向，帮助我克服苦难。祝愿郭老师事业有成、生活美满。

此外，感谢这三年遇到的所有好伙伴。这一路上，最幸运的就是遇到这一群善良的好伙伴，和大家相处是真的能感受到幸福与喜悦。而正是有了大家的陪伴和支持，我的人生才能多姿多彩。祝愿大家前程似锦、心想事成。

最后，感谢在百忙之中抽出时间参与本人论文评审的老师，感谢你们宝贵的意见。祝愿各位老师工作顺利、顺遂顺心。