

## 摘 要

航空发动机是飞机的核心部件，其性能状况对飞机的正常运行至关重要。在飞行任务中，飞机需要面对多样化和复杂的运行环境，这增加了通过物理模型预测发动机剩余寿命的难度。随着人工智能技术的快速发展，基于数据驱动的预测方法受到了广泛的关注，为评估航空发动机的健康状况以及预测剩余寿命提供了更合理的解决方案。本文主要对时间卷积网络（Temporal Convolutional Network, TCN）的结构进行优化，并将改进粒子群算法（Improved Particle Swarm Optimization, IPSO）用于优化改进时间卷积网络（Improved Temporal Convolutional Network, ITCN）的参数，通过建立 IPSO-ITCN 模型达到预期的剩余使用寿命预测效果。本文主要研究内容如下：

第一，提出了一种改进的时间卷积网络。时间卷积网络使用扩张因子来增加网络的感受野，但原有残差块的扩张因子以 2 的  $n$  次方进行增长，容易导致隐含信息缺失。本文补充了扩张因子以  $2n-1$  的规律进行增长的残差块并与原有残差块进行并联，再将两者输出进行拼接，避免了重要数据信息的遗漏。航空发动机数据量大且参数众多，将所监测的航空发动机数据直接输入 TCN 进行预测容易忽略关键特征影响，因此使用注意力机制来提取航空发动机寿命数据特征。将改进残差块后的时间卷积网络结合注意力机制得到改进时间卷积网络，并将改进时间卷积网络与时间卷积注意力网络（Temporal Convolutional Attention Network, TCAN）、双向长短时记忆网络（Bi-directional Long Short-Term Memory, BiLSTM）、深度置信网络（Deep Belief Networks, DBN）等方法通过实验进行性能对比。实验结果表明，改进的时间卷积网络拥有更高的精度。

第二，针对改进卷积网络的参数不同会导致模型预测精度波动等问题，本文提出一种 IPSO-ITCN 的剩余使用寿命（Remaining Useful Life, RUL）预测方法，使用改进粒子群算法来优化改进时间卷积网络的卷积核大小和卷积核数量。在测试函数上将改进粒子群算法与其他算法进行比较，结果表明改进粒子群算法能取得更好的测试结果。为了验证所提 IPSO-ITCN 模型的有效性，在 C-MAPSS 数据集上进行了实验，并将所提方法与支持向量回归（Support Vector Regression, SVR）、有向无环图（Directed Acyclic Graph, DAG）、深度卷积神经网络（Deep Convolution Neural Network, DCNN）、深度双向递归神经网络（Deep Bidirectional Recurrent Neural Networks, DBRNN）进行比较，结果表明 IPSO-ITCN 模型具有更优秀的性能。

**关键词：**时间卷积网络 剩余使用寿命 粒子群算法 注意力机制 扩张因子

## Abstract

Aero-engine is the core component of an aircraft, and its performance condition is crucial to the normal operation of the aircraft. In the mission, the aircraft needs to face a variety and complex operating environment, which increases the difficulty of predicting the remaining life of the engine through physical models. With the continuous progress of artificial intelligence technology, data-driven prediction method has been widely concerned, which provides a more reasonable solution for evaluating the health status of aeroengines and predicting the remaining life. In this thesis, the structure of Temporal Convolutional Network (TCN) is optimized, and the Improved Particle Swarm Optimization (IPSO) is used to optimize the parameters of the Improved Temporal Convolutional Network (ITCN), and the expected remaining useful life is predicted by establishing IPSO-ITCN model. The main research contents of this thesis are as follows:

Firstly, an Improved Time Convolution Network is proposed. Time Convolution Network uses expansion factor to increase the receptive field of the network, but the expansion factor of the original residual block increases by the  $n$  power of 2, which easily leads to the loss of implicit information. In this thesis, the residual block whose expansion factor increases with the law of  $2n-1$  is supplemented and connected in parallel with the original residual block, and then the outputs of the two blocks are spliced to avoid the omission of important data information. Aeroengine data is large in quantity and has many parameters. Directly inputting monitored aeroengine data into TCN for prediction can easily ignore the influence of key features. Therefore, attention mechanism is used to extract aeroengine life data features. Improved Time Convolution Network is obtained by combining the improved residual block with attention mechanism, and the Improved Temporal Convolutional Network is compared with Temporal Convolutional Attention Network (TCAN), Bidirectional Long Short-Term Memory Network (BiLSTM), Deep Belief Networks (DBN) and other methods through experiments. The experimental results show that the improved Temporal Convolutional Network has higher accuracy.

Secondly, in order to solve the problem that different parameters of the ITCN will lead to the fluctuation of the prediction accuracy of the model, this thesis proposes an IPSO-ITCN prediction method and uses IPSO to optimize the convolution kernel size and convolution kernel number of the ITCN. The IPSO is compared with other algorithms on

the test function, and the results show that the IPSO achieves better test results. In order to verify the effectiveness of the proposed IPSO-ITCN model, experiments are conducted on the C-MAPSS dataset, and the proposed method is compared with Support Vector Regression (SVR), Directed Acyclic Graph (DAG), Deep Convolutional Neural Network (DCNN), and Deep Bidirectional Recurrent Neural Networks (DBRNN). The results show that the IPSO-ITCN model has better performance.

**Key words:** Temporal convolutional network Remaining useful life Particle swarm Optimization Attention mechanism Expansion factor

# 目 录

摘 要.....	I
Abstract.....	II
<b>第 1 章 绪 论.....</b>	<b>1</b>
1.1 研究背景与意义.....	1
1.2 剩余使用寿命预测方法现状.....	2
1.2.1 基于物理模型的寿命预测方法.....	2
1.2.2 基于经验的寿命预测方法.....	2
1.2.3 基于数据驱动的寿命预测方法.....	3
1.3 论文创新点.....	5
1.4 论文组织结构.....	5
<b>第 2 章 相关理论基础.....</b>	<b>7</b>
2.1 卷积神经网络.....	7
2.2 长短时记忆网络.....	7
2.3 门控循环单元.....	9
2.4 粒子群算法.....	10
<b>第 3 章 基于改进时间卷积网络的剩余寿命预测方法.....</b>	<b>13</b>
3.1 改进时间卷积网络.....	13
3.1.1 时间卷积网络.....	13
3.1.2 时间卷积网络结构优化.....	15
3.1.3 改进时间卷积网络参数设置.....	18
3.2 数据预处理及参数分析.....	18
3.2.1 数据来源.....	18
3.2.2 数据预处理.....	20
3.2.3 超参数对剩余寿命预测结果影响分析.....	23
3.3 改进时间卷积网络剩余寿命预测实例.....	26
3.3.1 剩余寿命预测结果分析.....	26
3.3.2 消融实验.....	30
3.3.3 对比实验.....	31
3.4 本章小结.....	32

<b>第 4 章 基于 IPSO-ITCN 的剩余寿命预测方法</b> .....	<b>33</b>
4.1 改进粒子群算法 .....	33
4.1.1 粒子群算法的改进 .....	33
4.1.2 改进粒子群算法的寻优性能测试及分析 .....	36
4.2 IPSO-ITCN 预测模型结构 .....	39
4.2.1 模型原理叙述 .....	39
4.2.2 IPSO-ITCN 模型构建 .....	40
4.2.3 模型参数寻优结果 .....	41
4.3 IPSO-ITCN 模型的剩余寿命预测实例 .....	44
4.3.1 剩余寿命预测结果分析 .....	44
4.3.2 对比实验 .....	48
4.4 本章小结 .....	49
<b>第 5 章 结论与展望</b> .....	<b>50</b>
5.1 结论 .....	50
5.2 展望 .....	50
<b>参考文献</b> .....	<b>52</b>
<b>致 谢</b> .....	<b>58</b>
<b>作者简介</b> .....	<b>59</b>
<b>攻读硕士学位期间研究成果</b> .....	<b>60</b>

# 第1章 绪论

## 1.1 研究背景与意义

航空发动机是飞机核心部件之一，内部结构复杂并且需要在高温、高压等严酷的工作环境下运行，性能状态会直接影响飞机能否正常运行<sup>[1]</sup>，一旦发生故障会造成严重的财产损失。由美国国家运输安全委员会发布的统计报告显示，在2002-2012这十年，由于发动机故障而产生的飞行事故数达到了事故总数的36%<sup>[2]</sup>。近年来我国发生的飞机事故中，有60%是由于发动机发生故障无法正常运行而导致<sup>[3]</sup>。此外，航空发动机的故障还将导致高额的维修费用，国际航空运输协会所发布的费用数据显示，发动机维修所花费的费用占到了运维成本的13%<sup>[4]</sup>。因此，准确预测发动机故障发生时间点可以对发动机进行及时维修，从而有效降低发动机的维修成本以及事故发生的概率<sup>[5]</sup>。

常用的发动机维修方式为基于故障的维修和基于时间的维修。基于故障的维修方式是指当发动机出现故障无法正常运行时再进行维护，这种维修方式没有对故障发生情况进行提前预知并预防，也被称作“事后维修”<sup>[6]</sup>。与基于故障的维修策略不同，基于时间的维修方法按照预定的时间周期进行维护，而不是等到设备发生故障后才采取措施。由于每台航空发动机的操作条件和运行环境不同，统一的定期维修间隔可能无法精确匹配各发动机的实际使用状况，这会使得部分发动机可能面临过度维护或欠维护风险<sup>[7]</sup>。过度维护不仅会增加维护费用，还可能因频繁维修而造成发动机磨损<sup>[8]</sup>。欠维护忽视了故障的早期检测和预防，增加了飞机出现故障的概率。虽然基于故障的维修和基于时间的定期维修在特定条件下表现出了不错的效果，但对于高度复杂的航空发动机而言，这两种方法不能根据发动机的实际工况和使用环境来调整维护方案。因此，开发一种既能确保发动机运行安全又能降低维护成本的维修方法十分重要。

故障预测与健康管理（Prognostics and Health Management, PHM）是航空发动机进行故障监测的有效方式<sup>[9]</sup>，加速了维修方式由事后维修和基于时间维修向视情维修的转变。PHM技术在多个领域有着出色的表现，其主要包含故障预测和健康管理两部分内容<sup>[10]</sup>。航空发动机的故障预测是通过评估发动机当前健康状态来确定故障发生时刻，从而得到发动机的剩余使用寿命。航空发动机的健康管理主要为结合所得到的故障预测结果来制定发动机维修方案，降低“预防性维修”所导致的飞行成本。PHM技术在国内外应用广泛，是保障发动机正常运行以及合理维修的重要方法<sup>[11]</sup>。

PHM技术的应用突破了传统发动机维护技术的瓶颈，实现了设备的早期预警，

同时降低了发动机的使用和维护成本<sup>[12]</sup>，被广泛运用于工业领域。RUL 预测是 PHM 的核心内容，准确预测航空发动机的 RUL 能够在发动机还没有出现故障时就能制定相应维修计划，简化了相应的维修流程。此外，在获得航空发动机准确的 RUL 后能够根据发动机的运行情况在故障发生之前停止运行，有效的规避了故障发生。因此，RUL 预测在实际应用中有重要意义。

## 1.2 剩余使用寿命预测方法现状

作为 PHM 最重要的核心内容之一，剩余使用寿命的准确预测对于航空发动机的飞行安全和维护有重要意义<sup>[13]</sup>。剩余使用寿命是指设备从开始运行到运行失效的时间长度<sup>[14]</sup>。剩余使用寿命预测的主要任务就是根据所收集的传感器数据去准确预测故障发生的时刻，并得到设备的剩余使用寿命<sup>[15]</sup>。目前剩余使用寿命预测方法主要有基于物理模型的方法、基于经验的方法和基于数据驱动的方法<sup>[16]</sup>。

### 1.2.1 基于物理模型的寿命预测方法

基于物理模型的方法需要针对研究对象的内部结构以及在运行过程中产生的失效机理等因素，为其构建能够模拟其退化规律的物理模型<sup>[17]</sup>。结合所建立的物理模型以及研究对象所处工作环境、状态等因素来进行剩余使用寿命预测，能够得到发生故障时对应的时间点以及剩余使用寿命。对于一些失效机理明显的设备建立退化模型能够较为准确的展现设备的退化趋势，因此选择基于模型的方法对这种设备进行 RUL 预测会有较高的精度。Chelidze 等<sup>[18]</sup>使用基于模型的方法对真齿轮的 RUL 预测进行了研究。孙宇博等<sup>[19]</sup>将钛合金发动机叶片产生裂纹的规律作为研究的切入点，并预测了发动机叶片的 RUL。秦丽晔等<sup>[20]</sup>运用有限元方法对发动机机匣的健康状态以及损伤程度进行了评估，并对发动机机匣的 RUL 进行了预测。尽管基于物理模型的方法在特定条件下的预测精度高，但是建立物理模型需要准确获得研究对象的具体结构、退化机理以及运行环境等参数信息。当研究对象存在对剩余寿命有重要影响的未知参数时会直接影响 RUL 预测精度。不同种类设备的内部结构存在差异，相应的退化机理也不一致，基于物理模型的方法在不同设备之间的可迁移性差，这也在一定程度上限制了基于物理模型方法的应用。

### 1.2.2 基于经验的寿命预测方法

基于经验的设备寿命预估方法依赖于对设备运行特性的深入理解，并通过分析设备运行模式来推算其剩余寿命<sup>[21]</sup>。这类方法包括专家系统和模糊逻辑等技术<sup>[22]</sup>。

专家系统内嵌了大量领域专家的知识，通过模仿这些专家解决问题的思维过程，可以对现实问题进行逻辑推理<sup>[23]</sup>。例如，王鹏等<sup>[24]</sup>应用专家系统对电网设备的寿命进行了预测。Schuh 等<sup>[25]</sup>利用专家系统评估了风力涡轮机的健康状况，并显著提升了剩余寿命预测的准确度。然而，专家系统的有效性受限于知识库的质量<sup>[26]</sup>，若缺乏关键设备知识则可能导致预测结果不准确。模糊逻辑通过引入模糊规则来处理模糊性问题，在设备信息不完整时相较于专家系统能提供更可靠的分析结果<sup>[27]</sup>。Majidian 等人<sup>[28]</sup>采用模糊逻辑构建了推理规则，并将其应用于锅炉管道的剩余寿命预测，通过与其他预测模型的对比分析验证了该方法的有效性。

### 1.2.3 基于数据驱动的使用寿命预测方法

随着传感器技术的更新以及计算机功能的升级，设备运行期间所产生的退化数据被持续监测和储存，这为数据驱动方法的使用提供了良好的条件。基于数据驱动的方法的优势在于它不需要考虑设备的相关先验知识<sup>[29]</sup>，也不需要了解设备内部的具体构造以及退化机理，而是需要设备从开始运行到发生故障期间所产生的退化数据。在得到数据后使用统计、机器学习等数据驱动方法来提取数据中包含的退化特征，再建立相关模型来预测设备的 RUL<sup>[30]</sup>。区别于物理模型方法所需要的退化机理等先验信息，基于数据驱动的方法需要的是设备退化数据。与获取设备的退化机理相比，收集退化数据的方式更加简单，同时也能够避免由于设备内部复杂的关联性带来的影响。由于数据驱动方法只需要基于设备运行数据建立模型，不需要考虑不同设备之间物理性质差异，因此具有可迁移性。目前基于数据驱动的使用寿命预测方法主要有基于统计和机器学习方法<sup>[31]</sup>。

基于统计的 RUL 方法是使用所监测的设备数据建立随机过程模型<sup>[32]</sup>，以此来估计设备在运行过程中的退化情况。基于统计的 RUL 估计方法主要有基于 Wiener 过程的模型以及基于 Gamma 过程的模型<sup>[33]</sup>。例如郭庆等<sup>[34]</sup>提出一种非线性 Wiener 过程模型，使用极大似然估计建立似然函数来估计退化模型的未知参数，同时通过遗传算法寻找未知参数估计值，并将模型用于航空发动机 RUL 预测，验证了模型的优越性。徐峥等<sup>[35]</sup>提出一种将深度学习结合 Gamma 过程的 RUL 预测方法，使用连续小波变换处理振动信号，并输入卷积神经网络（Convolutional Neural Network, CNN）和 BiLSTM 网络，实验结果表明该方法有效解决了预测滞后问题。对于不同的预测对象，基于统计的方法不能进行通用而是需要根据研究对象重新建立模型，这限制了基于统计方法的广泛使用<sup>[36]</sup>。

机器学习方法应用广泛，常用于 RUL 预测的浅层机器学习方法主要有人工神经

网络 (Artificial Neural Network, ANN) 和支持向量机 (Support Vector Machines, SVM)。Mahamad 等<sup>[37]</sup>将人工神经网络用于轴承的剩余使用寿命预测得到了较好的预测效果。Nieto 等<sup>[38]</sup>使用粒子群算法优化 SVM 的超参数, 分析了参数设置对于 SVM 性能的影响, 经粒子群算法优化的 SVM 模型与其他 RUL 预测方法相比, 能够得到更高的预测精度。随着传感器技术广泛应用于设备状态监测, 所收集的监测数据随着设备运行时间的增加呈指数增长, 如何更加高效地从所收集的设备监测数据中提取退化特征并对设备的剩余使用寿命进行准确预测是一个值得深入研究的问题。机器学习方法在进行特征工程时需要手动提取特征, 特征的质量取决于特征设计方法, 这在一定程度上影响了机器学习方法的 RUL 预测精度。

深度学习方法不仅能够自发的从所提供的数据中提取特征并且对于高维特征能够有效的进行降维<sup>[39]</sup>。近年来, 深度学习方法被广泛应用于图像分类<sup>[40]</sup>、目标检测<sup>[41]</sup>、自然语言处理<sup>[42]</sup>和时间序列预测<sup>[43]</sup>等领域。在给出的数据足够满足预测要求的情况下, 深度学习挖掘数据内在联系的能力与传统的浅层机器学习相比更加强大<sup>[44]</sup>。随着人工智能的发展以及计算机硬件性能的提升, 深度学习方法在处理大规模数据方面的优势愈加凸显, 进行模型训练的效率显著提高, 是实现 RUL 预测的重要方法之一<sup>[45]</sup>。

深度学习方法中用于剩余使用寿命预测的常用神经网络主要有卷积神经网络、循环神经网络 (Recurrent Neural Network, RNN) 以及 TCN。Li 等<sup>[46]</sup>使用 CNN 学习轴承不同尺度上的特征, 通过结合轴承信息得到了一种高效的 RUL 预测方法。马忠等<sup>[47]</sup>使用不同的一维卷积核提取序列趋势信息来改进神经网络, 通过具体实验证明了所提方法具有更高的预测精度。全航等<sup>[48]</sup>使用 CNN 来预测轴承剩余寿命, 分析了 CNN 在实际 RUL 任务时的性能表现。Heimes 等<sup>[49]</sup>对 RNN 进行了改进, 使用时间梯度计算的反向传播和进化算法对 RNN 进行训练, 并通过实验验证了模型的有效性。然而, RNN 在对数据进行长期预测时会出现梯度消失现象, 影响了模型预测 RUL 的精度。长短时记忆 (Long Short-Term Memory, LSTM) 网络是 RNN 的一种改进结构, 所包含的遗忘门结构缓解了梯度消失问题, 并且在面对长序列信息时 LSTM 能够更加有效地处理更多历史信息。曾慧洁等<sup>[50]</sup>使用双向 LSTM 来预测航空发动机的 RUL, 预测精度与 LSTM 相比有明显提升。Wu 等<sup>[51]</sup>提出一种深度长短期记忆网络来融合多个传感器监测信号, 实现了航空发动机 RUL 的准确预测。由于 LSTM 提取时间序列历史信息的能力优于 RNN, 因此在长时间序列处理上, LSTM 的效果比 RNN 更好。但是, 随着时间序列数据的增多, LSTM 进行网络训练需要很长时间。门控循环单元 (Gated Recurrent Unit, GRU) 是 LSTM 的一种变体, 简化了 LSTM 的网络结构, 在网络训练过程中参数少于 LSTM, 因此更加容易进行网络训

以上内容仅为本文档的试下载部分，为可阅读页数的一半内容。如要下载或阅读全文，请访问：<https://d.book118.com/318070077125007031>