

分类号: TP183

密 级: 公开

学校代码: 10363

学 号: 2220320185



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题目 基于 FRANC3D 的桥梁钢桁架
裂纹寿命与扩展研究

论 文 作 者 王国栋

校 内 导 师 郭黎 教授

校 外 导 师 袁学超 工程师

专业学位类别 电子信息

研究方向 (领域) 新一代电子信息技术

论文提交日期: 2025 年 5 月 14 日

分类号: TP183

单位代码: 10363

密 级: 公开

学 号: 2220320185

题 目 基于 FRANC3D 的桥梁钢桁架裂纹寿命与扩展研究

题 目 Research on Crack Life and Propagation in Bridge
Steel Trusses Based on FRANC3D

论文作者: 王国栋

校内导师: 郭黎 教授

专 业: 电子信息

研究方向: 新一代电子信息技术

论文答辩日期: 2025/05/06

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：

王国栋

日期： 2025 年 5 月 14 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或部分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：

王园桦

指导教师签名：

邵子

日期： 2025 年 5 月 14 日

日期： 2025 年 5 月 14 日

基于 FRANC3D 的桥梁钢桁架裂纹寿命与扩展研究

摘 要

桥梁健康监测是保障桥梁结构安全、延长使用寿命、优化维护管理的重要手段，对于保障公共安全、促进交通基础设施可持续发展具有重大意义。在役期间的桥梁时刻都在承受着自然的侵蚀与动态载荷的压力，其良好的状态是安全通行的保证。现阶段桥梁建设中大都使用钢材料的桁架结构作为支撑，桁架支撑起桥梁的形状并承担着外在压力，为桥梁中最重要的部分。随着现代制造水平的提升，桁架抵御自然环境的侵蚀能力已越来越强，现对桁架最有威胁性的是疲劳载荷，这也是金属材料共有的一个弱点，它会导致材料在长时间承受交变应力下逐渐发生性能退化，最终可能引发结构失效。桁架在疲劳载荷的施加下极易发生裂纹，并可能会进一步发展扩大，这对整个桥梁的正常使用产生了极大的安全隐患，所以根据裂纹发展状况及时预测裂纹寿命、判断裂纹发展状态，从而反映桥梁的健康情况，避免安全事件的发生具有重要现实意义。

本文以桥梁为研究背景，钢桁架裂纹为研究对象，围绕 FRANC3D 的仿真扩展结果开展了对裂纹寿命与扩展阶段的研究。具体主要内容如下：

(1) 针对 FRANC3D (FRacture ANalysis Code for 3D) 软件计算量大，计算步骤复杂等缺点，所以利用神经网络强大的拟合能力预测仿真软件的运算结果。钢桁架具有一定的韧性，疲劳裂纹的发展是一

个十分缓慢的过程，采用一般的物理模拟法进行研究并不适用，因此在工程软件上建立桁架的仿真模型，使用 FRANC3D 对疲劳裂纹的扩展进行模拟。由于软件计算步骤繁琐、耗费时间长效率不高，因从构建了裂纹特征的数据集，从而能够使用神经网络快速预测结果。

(2) 针对长短期记忆网络 (Long Short-Term Memory, LSTM) 训练效率不高，性能表现依赖于输入质量的问题，提出自编码器+注意力的结构对原数据进行重构。长短期记忆网络有效缓解了梯度爆炸、消失等问题，且能很好的捕捉序列数据的特征并能做出较高准确度的预测，但是网络的预测效果不仅与网络本身的原理、结构、参数有关，还与学习的输入数据的质量有关，高质量的输入定会带来更好的预测效果，因此提出自编码器和注意力相结合的网络结构对原输入数据进行重构，结合自编码器和注意力的各自优势重构出更高质量的输入数据，实验结果显示重构后的数据能有效加快收敛速度，提升寿命预测的准确率。

(3) 针对裂纹扩展过程中部分区域扩展阶段难以区分，提出使用半监督学习的方式对裂纹扩展所属阶段进行识别。裂纹扩展是一个连续不断的过程，此过程的三个阶段中部分区域难以进行明确的划分，所以人为的赋予数据少量的扩展阶段标签，在经过少量标签学习后的神经网络训练完成后拟合标签缺失的数据并进行迭代更新生成伪标签，实验对比了三种网络 (LSTM, Transformer, 自编码器) 下的识别效果，均获得较高的准确率。

综上，本文关注桁架上裂纹的扩展过程，基于 FRANC3D 的裂纹

仿真数据，使用 LSTM 网络对裂纹的寿命进行预测，并提出自编码器+注意力的结构对数据进行重构，使得网络预测效果更加准确。同时因为标签标注困难，以半监督学习的训练方式对裂纹扩展阶段进行识别，均取得了较准确的效果。

关键词：疲劳裂纹，寿命预测，注意力，长短期记忆网络，Transformer 网络

RESEARCH ON CRACK LIFE AND PROPAGATION IN BRIDGE STEEL TRUSSES BASED ON FRANC3D

ABSTRACT

Bridge health monitoring is an important technological means to ensure the safety of bridge structures, extend their service life, and optimize maintenance management, which is of great significance for ensuring public safety and promoting the sustainable development of transportation infrastructure. Bridges under service constantly endure natural erosion and dynamic load pressures, and their good condition is the guarantee of safe passage. At present, steel truss structures are mostly used as supports in bridge construction. The truss supports the shape of the bridge and bears external pressures, making it the most important part of the bridge. With the improvement of modern manufacturing levels, the ability of trusses to withstand natural environmental erosion has become increasingly strong. Currently, the most threatening factor to trusses is fatigue loading, which is a common weakness of metallic materials. It can cause gradual performance degradation of materials under long-term alternating stress and may eventually lead to structural failure. Trusses are prone to cracks under fatigue loading, which may further develop and expand, posing significant safety hazards to the normal use of the entire bridge. Therefore, it is of great practical significance to timely predict

crack life and judge crack development conditions, so as to reflect the health status of the bridge and prevent safety incidents.

In this thesis, the bridge is taken as the research background and the steel truss crack is taken as the research object, and the crack life and propagation stage are studied based on the simulation expansion results of the FRANC3D. The specific main contents are as follows:

(1) In view of the shortcomings of FRANC3D (FRacture ANalysis Code for 3D) software, such as large computation and complicated calculation steps, the powerful fitting ability of neural networks is utilized to predict the operation results of the simulation software. Steel trusses have certain toughness, and the development of fatigue cracks is a very slow process. General physical simulation methods are not applicable for research. Therefore, a simulation model of the truss is established on engineering software, and FRANC3D is used to simulate the propagation of fatigue cracks. Due to the cumbersome calculation steps and low efficiency of the software, a dataset of crack features is constructed to enable the neural network to quickly predict the results.

(2) To address the issues of low training efficiency and performance dependence on input quality of Long Short-Term Memory (LSTM) networks, an autoencoder combined with an attention mechanism is proposed to reconstruct the original data. The LSTM network effectively alleviates problems such as gradient explosion and disappearance and can

capture the characteristics of sequence data well and make predictions with high accuracy. However, the prediction effect of the network is not only related to the principle, structure, and parameters of the network itself but also to the quality of the input data for learning. High-quality input will definitely bring better prediction results. Therefore, a network structure combining autoencoder and attention mechanism is proposed to reconstruct the original input data. By combining the advantages of autoencoder and attention mechanism, higher-quality input data is reconstructed. Experimental results show that the reconstructed data can effectively accelerate convergence speed and improve the accuracy of life prediction.

(3) In response to the difficulty in distinguishing some areas during crack propagation stages, a semi-supervised learning approach is proposed to identify the stages of crack propagation. Crack propagation is a continuous process, and it is difficult to clearly divide some areas among the three stages of this process. Therefore, a small amount of crack propagation stage labels is artificially assigned to the data. After training the neural network with a small amount of labeled data, the trained network fits the label-missing data and iteratively updates to generate pseudo-labels. The experiment compares the recognition effects under three networks (LSTM, Transformer, Autoencoder) and achieves high accuracy.

Based on the FRANC3D crack simulation data, this thesis uses the LSTM network to predict the crack lifetime, and proposes the structure of the autoencoder attention to reconstruct the data, so as to make the network prediction effect more accurate. At the same time, because of the difficulty of labeling, the semi-supervised learning training method was used to identify the crack propagation stage, and a more accurate effect was obtained.

KEY WORDS: Fatigue crack, Life prediction, Attention, Long Short-Term Memory network, Transformer network

目录

摘 要.....	I
ABSTRACT.....	IV
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.....	2
1.2.1 裂纹寿命预测的研究现状.....	2
1.2.2 裂纹扩展的研究现状.....	6
1.3 本文工作内容及安排.....	6
1.3.1 研究路线.....	6
1.3.2 本文的章节安排及创新点.....	7
第 2 章 相关理论.....	9
2.1 引言.....	9
2.2 裂纹相关理论.....	9
2.2.1 裂纹类型.....	9
2.2.2 应力强度因子理论.....	10
2.2.3 裂纹扩展速率模型.....	11
2.3 深度学习理论.....	12
2.3.1 神经网络.....	12
2.3.2 LSTM 网络.....	13
2.3.3 Transformer 网络.....	14
2.3.4 注意力机制.....	16
2.3.5 自编码器网络.....	16
2.3.6 半监督学习.....	17
2.4 本章小结.....	18
第 3 章 钢桁架参数化建模与裂纹数据集建立.....	19
3.1 引言.....	19
3.2 钢桁架模型建立.....	20

3.3 裂纹的建立与扩展.....	20
3.4 数据预处理.....	24
3.5 本章小结.....	25
第 4 章 基于 FRANC3D 的桥梁钢桁架裂纹寿命预测	26
4.1 引言.....	26
4.2 注意力位置及参数寻优.....	26
4.3 LSTM 网络参数寻优.....	28
4.4 裂纹寿命预测总体框架.....	29
4.5 评价指标.....	30
4.6 模型训练与参数配置.....	31
4.7 实验结果与分析.....	31
4.8 本章小结.....	34
第 5 章 半监督学习下的裂纹扩展阶段识别.....	35
5.1 引言.....	35
5.2 数据集扩充.....	36
5.3 网络搭建.....	36
5.3.1 LSTM 网络搭建.....	36
5.3.2 Transformer 网络搭建.....	37
5.3.3 自编码器搭建.....	37
5.4 半监督学习方式的裂纹扩展阶段识别框架.....	38
5.5 评价指标.....	39
5.6 训练结果与分析.....	40
5.7 本章小结.....	45
第 6 章 总结与展望.....	46
6.1 全文总结.....	46
6.2 工作展望.....	47
参考文献.....	48
攻读硕士期间取得的学术成果.....	55
致谢.....	56

第 1 章 绪论

1.1 研究背景及意义

随着经济的快速发展和城镇化率的不断上升，中国迎来了大基建时代，各种高楼、道路、桥梁的建设如火如荼的进行着，其中桥梁的震撼建设更是取得了令人震惊的成就。我国的桥梁建设起步较晚，在十九世纪 80 年代末桥梁的建设以小规模为主，所需的钢材主要依靠进口，建设技术较为落后，大型桥梁主要由外商承包建设。1937 年我国自主设计并建造了双层公铁两用的钢桁架桥——钱塘江大桥，成为我国桥梁史上的一座里程碑；1957 年铆接米字形连续钢桁梁结构的桥梁——武汉长江大桥建成；后来我国建设水平一路高歌猛进，陆续建设了南京长江大桥、九江长江大桥等一系列重要桥梁，标志着我国在桥梁设计与建设技术上的飞速进步。21 世纪后，中国的桥梁建设又是达到了前所未有的高度，创造了一系列世界之最。



(a) 桁架正面



(b) 桁架侧面

图 1-1 桥梁钢桁架

桥梁的建设使得通行变的便捷方便，但桥梁也在时刻承受着内外的压力作用。桥梁在役期间，桁架对道路有着关键的支撑作用。在经过不断往来车辆的动态压力下，桁架开始累计损伤，其性能也在逐渐退化，慢慢发展成裂纹。裂纹产生之时就已会对桥梁的正常使用产生影响。且当裂纹扩展到一定程度时，桁架的寿命会随时到达末端值从而断裂，从而影响整个桥梁的正常通行且具有极大的安全隐患。为了探究钢桁架部件的裂纹扩展状态与剩余寿命，传统方法是使用疲劳试验机对试件做疲劳分析，通过实验获得材料的 S-N 曲线（应力-寿命曲线）或 E-N（应变-寿命曲线）曲线，然后采用应力疲劳分析或应变疲劳分析对试件的疲劳

寿命进行计算^[1]。但这种实验效果效率不高，因为试件是一次性的，一种裂纹特征只能获得一组实验数据，且比较费时费力。

随着损伤力学和断裂力学的理论不断发展，有限元方法被提出用来分析模型的裂纹扩展和寿命计算，并在一些有限元分析软件上得以运用，方便了裂纹扩展过程的可视化分析，多次改变裂纹特征进行分析也变得高效快捷^[2]。虽然现在计算机的算力一直在大幅提升，但对于有限元软件做裂纹扩展计算的时候有时还是比较费力，会遇到网格划分困难、裂纹形状拟合失败甚至计算量过大导致死机等问题，这就需要操作人员找出问题并进行优化。即使是在一切顺利的情况下，完成整个裂纹扩展过程的计算也需要较多时间。因此，有限元软件需要更好的算法改进或者找到一种能快速根据相关特征预测出寿命的方法。

这几年，人工智能领域的神经网络因其强大的学习能力又掀起一波热潮，使得众多学者对其加以研究并应用。给与神经网络一些用来训练的数据，训练完成之后，将新数据送入保存好的模型内，在极短的时间内便可给出结果且具有较高的准确性，由此神经网络强大的学习和拟合能力也为我们预测桥梁裂纹寿命、识别裂纹扩展阶段提供了新的方法^[3]。所以本文在有限元仿真的基础上，构建了裂纹特征的数据集，应用神经网络对当下裂纹状态的寿命进行预测，对裂纹扩展的所属阶段进行识别，可以根据当下裂纹发展状况快速预测裂纹寿命、判断扩展所属阶段，及时对桥梁桁架进行维护，提前避免重大损失和危险事件的发生具有重要现实意义。

1.2 国内外研究现状

疲劳裂纹寿命的预测问题被许多学者讨论和研究，基本上分为三种方式：基于损伤力学的寿命预测、基于断裂力学的寿命预测和基于机器学习的寿命预测。裂纹的扩展基于扩展速率模型实现，在国内外也不断地被应用与发展。

1.2.1 裂纹寿命预测的研究现状

基于损伤力学的寿命预测。损伤力学上认为，疲劳破坏是一个损伤累积的过程，目前较为常用的疲劳累积损伤模型主要有：线性累积损伤理论、双线性累积损伤理论和非线性累计损失理论^[4]。线性累积损伤理论，又称 Palmgren-Miner 理

论,该理论假定材料在各个应力水平下的疲劳损伤是独立进行的,总损伤由各个独立损伤线性叠加所得^[5];双线性累积损伤理论更细致的将疲劳分析过程分为疲劳裂纹成形阶段和疲劳裂纹扩展阶段,理论认为这两个阶段的损伤线性规律不同应分别进行处理;非线性理论更全面的反映了载荷加载顺序、载荷历程与载荷交互影响对疲劳损伤的影响。商博世^[6]通过 S-N 曲线的经验公式估算出钢圈材料的 S-N 曲线并进行修正,之后基于 Minner 累计损伤原则对钢圈的寿命进行计算;姚森^[7]对风机齿轮箱高速级斜齿轮副进行有限元分析,并根据其结果以及载荷时间历程,使用疲劳分析软件 nCode 对斜齿轮副进行疲劳寿命分析,其中 nCode 的计算依据即为 Minner 线性累计损伤准则;彭杰^[8]使用有限元软件 ANSYS 和疲劳分析软件 nCode,系统地研究了叶片根部与调浆轴承内圈连接的高强度螺栓的强度;Ren 等人^[9]通过对模型进行瞬态动力学分析得到各部件的应力变化,基于应力损伤理论对轴承进行疲劳分析得到轴承的损伤和疲劳寿命;Zhang 等人^[10]以某轿车后扭梁为研究对象,采用名义应力法估算其疲劳寿命,在 ANSYS Workbench 中对扭转梁进行强度校核,对复合材料的 S-N 曲线和疲劳累积损伤理论进行 nCode 设计寿命分析,得到扭转梁的疲劳寿命;Lhoussaine 等人^[11]对 11kW 小型风叶片进行结构设计与分析,采用 FAST-MLife 程序和 nCode 对叶片疲劳进行了充分的计算分析,得出转子叶片在设计寿命为 20 年时将是安全的抗疲劳的。Li 等^[12]基于广义线性累计损失理论对高速列车轴承疲劳寿命预测;Xue 和 Du^[13]基于非线性累计损伤构建焊接疲劳设计模型;Xiao 等^[14]基于载荷作用和强度退化提出了新的非线性疲劳累计损伤模型;Peng 等^[15]使用改进的非线性损伤模型用于高低周疲劳寿命的组合预测;Riley 与 Isaac^[16]基于非线性累计损伤对齿轮寿命进行分析;Yutaro 等^[17]对使用线性累计损伤对 Ti-6Al-4V 合金冷留完成了寿命评估。

基于断裂力学的寿命预测。断裂力学领域国外的研究起步较早,并且率先提出了多种裂纹扩展速率模型,寿命预测也在此模型上实现。早在 1963 年 Pairs 在断裂力学方法的基础上,提出了表达裂纹扩展规律的著名关系式——Pairs 公式(Paris formula),给疲劳研究提供了一个估算裂纹扩展寿命的新方法,从而使断裂力学和疲劳这两门学科逐渐结合起来^[18]。之后,又有其他学者对公式做出了更多的改进:Walker 等在 Pairs 的基础上引入应力比 R 并称为 Walker 公式^[19];

针对 Pairs 公式只能描述裂纹扩展的稳定阶段这一局限性, Forman 在 Pairs 的基础上考虑断裂韧性提出了改进后的 Forman 公式, 此公式可以描述裂纹扩展从低速到稳定再到高速扩展的过程^[20]; 后来 NASGRO 公式不仅能够描述裂纹在低速扩展区、稳定扩展区和失稳扩展区的扩展, 此外还描述了裂纹扩展门槛值、应力比和失稳临界值等因素对裂纹扩展的影响, 应用更为广泛^[21]; Qu 等^[22]研究了双裂纹对疲劳裂纹扩展寿命的影响, 采用 Forman-Newman-de Koning 模型和线弹性断裂力学理论, 给出叶轮在单裂纹和双裂纹条件下的扩展规律; Kumar^[23]讨论了利用 NASGRO 裂纹扩展模型的 AFGROW 软件预测考虑加劲肋效应的断裂参数、疲劳裂纹扩展寿命和检验间隔的方法; Feng 等^[24]基于 Forman 模型实现了裂纹扩展的长期预测; Pandey 等^[25]改进了 Liu-Murakami 蠕变损伤模型, 用于预测各种裂纹试样的蠕变寿命; Pereira^[26]考虑了非比例加载和裂纹面相互作用影响的最大切向应力 (MTS) 取向准则的扩展, 以改进对圆柱形垫板结构的裂纹路径和扩展寿命的预测。

吴秀平^[27]以某三跨连续钢桁拱桥为研究背景, 利用 ABAQUS 软件建立了研究节点的局部模型, 对在列车载荷作用下的含裂纹的整体节点板进行了裂纹扩展仿真, 并使用 Pairs 公式对裂纹的扩展寿命进行评估; 车福炎^[28]结合 Paris 裂纹扩展速率计算公式, 建立 10CrNi5MoV 钢耐压结构的疲劳裂纹扩展寿命计算模型; 徐田^[29]分别基于 Paris 公式、修正 Paris 公式和 NASGRO 方程对车轴钢断裂性能试验数据进行拟合, 并基于 Miner 线性损伤累积理论采用修正 Paris 公式对应力谱作用下微动裂纹扩展寿命进行计算; 龙慧^[30]应用 Walker 方程建立疲劳裂纹扩展增量计算公式, 基于振动响应与裂纹扩展循环同步分析法计算出疲劳裂纹扩展寿命; 赵龙^[31]基于有限元模型与实际情况, 在旋挖钻机底架结构上进行预制裂纹, 并考虑到裂纹扩展时的闭合效应, 基于 NASGRO 模型对旋挖钻机底架的疲劳裂纹扩展寿命进行预测, 并与传统 Paris 模型计算出的寿命进行对比分析; Wang 等^[32]分别在 600°C、650°C、700°C 和室温下对含人工表面缺陷的 FGH96 试样进行低周疲劳试验, 然后通过 ABAQUS-FRANC3D 联合仿真进行基于断裂力学的寿命预测; Zhang^[33]基于鼓胀效应对表面裂纹立方体的应力强度因子进行修正, 并利用几何特征和载荷特征计算应力强度因子, 在不划分有限元网格的情况下计算裂纹扩展寿命; Zhu 等^[34]提出一种基于三维断裂力学的方法, 通过考虑

塑性诱导的疲劳裂纹闭合来评估拉伸和弯曲载荷下表面裂纹扩展寿命；Wang 等人^[35]采用 Q345B 高强度低合金结构钢制作了 50 个主板（12 毫米厚）和搭接板（8 毫米厚）的纵向角焊缝搭接接头，接头试样在室温和低温（0℃、-20℃ 和 40℃）下进行常幅加载疲劳试验，试验寿命结果采用 S-N 曲线进行了模拟；Zhou 等人^[36]采用 MTS 准则分析海底管道裂纹扩展模式，采用有限元法结合节点位移法求解裂纹应力强度因子，然后基于 Paris 公式采用 da/dN 法预测海底管道的疲劳寿命；Wang 等人^[37]采用扩展有限元法对单边缺口试样的疲劳裂纹扩展进行了数值模拟，根据计算得到的应力强度因子和广义 Paris 公式，得到单边缺口试样的疲劳裂纹扩展速率，并预测疲劳裂纹扩展寿命。

基于机器学习的寿命预测。神经网络经历了两起两落后，又在 21 世纪初迎来了它的第三次复兴，多种新型的网络结构和名称层出不穷，被各行业的学者加以应用。王志航^[38]采用 MTS 疲劳试验机对含有两孔及三孔的铝合金平板进行疲劳裂纹扩展试验，对得到的原始裂纹扩展试验数据标准化，使用向量回归（Support Vector Regression, SVR）算法预测裂纹扩展长度和寿命；刘瑞萍^[39]将声发射实验获得的信号筛选后进行小波变换，接着用变换后的小波系数构成特征输入到深度信念网络（Deep Belief Networks, DBN）进行剩余寿命的预测；张云超^[40]基于一种与时序模式注意力机制相结合的 LSTM 网络建立了轴承性能退化预测模型，利用公开的轴承退化实验数据进行验证分析；Zafer 等^[41]使用随机森林回归和 k-近邻回归预测基于不同谱载荷的飞机单搭接剪切接头的裂纹扩展寿命；Zhang 等^[42]通过对局部数据点进行二次 B 样条插值，提高了灰色模型预测疲劳裂纹扩展寿命的能力；Lu 等^[43]研究了基于神经网络的方法来模拟高温下的裂纹扩展，通过对裂纹扩展速率进行建模和积分，建立了一种评估裂纹扩展速率的间接方法；Yao 等人^[44]提出采用多分支残差特征融合网络结构并耦合注意力机制的方法进行轴承的故障检测和剩余使用寿命的预测；Li 等人^[45]提出了一种传感器感知的胶囊神经网络（Sensor Aware Caps Net, SACN）框架用于剩余寿命预测；Wang 等人^[46]集成了粒子滤波（Particle Filter, PF）、支持向量回归 SVR 和高斯过程回归三个模型的结果以预测剩余使用寿命；同样的，Shi 等^[47]使用了一种双重注意力和长短期记忆的轻量级模型；Jiang 等^[48]设计了一种新颖的时域卷积网络-多头自注意力模型。众多学者对网络结构的改进都取得了较好的效果。

1.2.2 裂纹扩展的研究现状

裂纹扩展过程分为裂纹萌生, 稳态发展, 失稳发展三个阶段。国内外学者对不同阶段的裂纹扩展进行了研究。Cheng 等^[49]研究了 P92 钢在高温三点弯曲疲劳过程中的裂纹萌生机制, 发现具有更大先验奥氏体晶粒尺寸的组织有更好的抗开裂性能; Zhang 等^[50]考虑了不同孔隙形态和位置影响下的裂纹萌生扩展机制, 得到的裂纹萌生寿命与实验结果吻合较好; Li 等^[51]对裂纹萌生和早期扩展行为进行研究, 得出裂纹扩展从早期到稳定阶段的过渡过程中速度减慢且裂纹在早期扩展阶段中倾向于沿边界扩展的结论; Tang 等人^[52]基于断裂力学建立数值模型对疲劳裂纹进行模拟分析, 考虑残余应力影响所建立的多尺度模型能有效预测裂纹萌生与扩展寿命; Guo 等人^[53]对高周疲劳下的 M50 轴承钢的裂纹萌生机制进行研究, 亚表面应力强度因子低于该材料的应力范围阈值时裂纹萌生主要发生在缺陷处, 高于裂纹扩展门槛值时裂纹在鱼眼区域扩展; Wang 等人^[54]基于双线性黏聚力模型和有限元-离散元联合方法, 研究了冲击荷载作用下岩石中拉伸和剪切裂纹的动态扩展规律; 更多学者^{[55]-[57]}对不同材料下的试样裂纹的稳态扩展进行了研究。马天宇等^[58]运用分子动力学分析了渗碳体对裂纹萌生和扩展的影响; 钱师雄等^[59]对拉索高强钢丝的疲劳裂纹萌生机理进行分析, 得出不同应力范围对裂纹萌生寿命占总寿命的影响; 包骐乐等^[60]使用数字相关技术对裂纹萌生和扩展阶段分别进行表征; 戚钊等^[61]探究了应力比对含缺陷选区的稳态扩展的影响; 肖瑞与杨明^[62]开展了不同淬火工艺对裂纹扩展速率的影响研究; 孙立臣等^[63]基于离散元对裂纹失稳机理进行探讨, 陈光波等^[64]开展轴向加载试验对比了不同裂隙对煤岩组合体的影响情况, 并基于耗散结构理论对失稳破坏机制作出分析。

1.3 本文工作内容及安排

1.3.1 研究路线

本文以桥梁为研究背景, 钢桁架裂纹为分析对象, 基于 FRANC3D 模拟裂纹的扩展进行进一步的研究分析, 本文工作的流程如下图 1-2 所示。




图 1-2 本文工作流程图

1.3.2 本文的章节安排及创新点

本文具体的章节安排如下：

第一章：首先阐述本文的研究背景与意义，之后介绍了寿命预测在损伤力学、断裂力学、机器学习三个领域上以及裂纹扩展的国内外研究现状。

第二章：介绍了裂纹的相关理论包括裂纹类型、应力强度因子理论及裂纹扩展速率模型；深度学习理论方面，详细介绍了 LSTM、自编码器和 Transformer 三种神经网络的组成结构以及半监督学习的特点与几种常用方式。

第三章：建立了钢桁架的仿真模型，与 FRANC3D 联合仿真，详细介绍了疲劳裂纹的扩展过程。多次建立不同的裂纹并收集其在扩展过程中时的数据，构建了含裂纹特征信息的数据集并对该数据集进行归一化处理。

第四章：LSTM 基本网络的裂纹寿命预测。为了能更准确的预测裂纹寿命，首先对注意力和 LSTM 网络参数进行寻优以达到更好的性能，使用提出的自编

码器+注意力对原数据进行重构，重构后的数据在同样 LSTM 网络的训练下取得了更快的训练速度与更准确的结果，并在测试数据集上得到验证。另外分析了网络预测与 FRANC3D 运行结果的误差。

第五章：对裂纹扩展阶段进行识别。人为的赋予部分数据类别标签以适应半监督学习的训练方式。搭建 LSTM、自编码器和 Transformer 网络分别对标签数据进行预训练，之后对无标签数据进行预测并将满足置信度要求的结果作为伪标签，模型继续训练，直到伪标签的生成趋于稳定。接着对裂纹数据抽样验证网络分类的准确度，并对比了三种网络各自对监督数据的依赖程度。

最后，对本文的工作进行了总结和展望。

本文的创新之处在于：

在寿命预测阶段中，首先使用 FRANC3D 模拟疲劳裂纹的扩展过程，并从中提取裂纹的相关特征，包括长度、宽度、位移量、应力比和增长量，构建了裂纹特征信息的数据集，并将这一系列数据送入 LSTM 网络中进行训练以预测寿命，实现了有限元与神经网络的结合。为了优化训练过程及效果，将网络结合自编码器和注意力机制，以达到更好的效果。具体的，数据首先进入自编码器网络的编码器中，经过一系列线性变换和线性单元的修正（ReLU）后，成为低维数据，简化了数据的繁杂程度，同时为了保证数据的有效性，引入注意力机制对此数据进行优化得到更加含有有效信息的数据；接着数据进入自编码器的解码器中，数据又恢复到与初始数据一样的维度，之后进入 LSTM 网络。原数据通过此结构的重构，使得训练过程更加高效便捷，预测的结果有更高的准确性。

针对裂纹扩展阶段的识别，同样基于裂纹扩展数据，创新性的采用了半监督的训练方式，将裂纹扩展阶段类别与神经网络进行结合，既弥补了先验知识不足的影响，又提高了网络泛化能力。在此过程中，选用 LSTM、Transformer 和自编码器三种网络分别通过标签数据的学习后，对缺失标签选择高置信度的预测结果作为伪标签并不断的训练更新，最终能够较准确地预测出裂纹扩展所属阶段，随机对裂纹数据集样本进行抽样验证网络识别的结果，同时比较了各个网络在不同标签率下的准确率，探究了网络对有标签数据量的依赖程度。

第 2 章 相关理论

2.1 引言

桁架对桥梁有着重要的支撑作用，其良好状态是桥梁正常通行的重要保障。由于车辆的持续来往，桥梁上动态载荷的应力压力分配在桁架上。长期如此，桁架在疲劳载荷的作用下造成性能退化，后期极易发展成裂纹，极大影响桁架的支撑能力，从而引起路面的坍塌，造成不可估量的损失。针对这一问题，引入深度学习技术对裂纹进行寿命预测与扩展阶段的识别，及时对桁架进行养护与维修。本章节对裂纹和深度学习的理论进行介绍。

2.2 裂纹相关理论

断裂力学的研究起步较晚，但在众多科研人员和相关学者的不懈努力下，断裂力学获得了飞速的发展，理论体系趋于完整且在不断的改进创新，并推演出各种准则来分析断裂行为。在裂纹扩展和寿命计算方面，应力强度因子一直是研究的重点，在此基础上，又发展了几种经典且常被科研人员当作研究基石的扩展速率模型。本部分内容为裂纹的类型、应力强度因子和扩展速率的理论介绍。

2.2.1 裂纹类型

实际中裂纹的形状多种多样，产生的原因也各不相同，所以可以从不同角度对裂纹进行分类^[65]。断裂力学中从力学特征将裂纹分为三类，如图 2-1 所示。




图 2-1 三种裂纹类型

图中I型为张开型裂纹，载荷在垂直于裂纹面的方向上下拉伸，裂纹在平面内张开形成。这种类型在工程上最为常见也最被受关注，本文研究的裂纹类型即是张开型裂纹。

II型为滑开型裂纹，载荷在平行于裂纹面且垂直于裂纹前缘方向上前后剪切作用，裂纹在平面内错开形成。

III型为撕开性裂纹，载荷在平行于裂纹面且平行于裂纹前缘方向上剪切作用，裂在平面外错开形成。

实际状况中裂纹不一定只属于某一类型，而是二种甚至是三种类型的复合式裂纹，这种裂纹分析起来更为复杂。此种裂纹的分类方式常用于断裂力学领域中。也有学者从裂纹的几何特征对裂纹进行分类，包括穿透裂纹、表面裂纹和深埋裂纹。这种裂纹分类方式更贴近于生活认识，用于学术研究的不多。

2.2.2 应力强度因子理论

断裂力学领域在研究裂纹问题时，通常引入应力强度因子 K 、应变能释放率 G 、 J 积分等参数作为研究。这是由于裂纹尖端的应力大小常趋近于无穷大，即存在奇异性，这给运算分析带来了困难，而这些参数的引入解决了这种困扰。应力强度因子 K 描述弹性裂纹尖端应力场的强弱，能够表征靠近裂纹尖端区的应力场与位移场奇异性的强度，其计算依赖于裂纹前端的局部应力场； J 积分描述的是因裂纹存在而吸收的能量；应变能释放率 G 描述的是产生裂纹所需要的能量。线弹性材料下这三个参数可以通过一定关系式联系起来相互进行表达。本次研究中使用材料为具有线弹性的钢材料，且在建模环境中该材料更被认为具有理想的线弹性特征，所以用 K 参数来对应应力强度因子作为表达具有一定的准确度。

线弹性断裂力学理论认为，试样受到外载作用时，裂纹尖端附近会产生弹性应力场，应力强度因子（Stress Intensity Factor, SIF）是反映裂纹尖端弹性应力场的强弱，通常用 K 表示，量纲为： $[\text{应力}][\text{长度}]^{1/2}$ 。

对于有限尺寸的构件，I型裂纹应力强度因子 K 表示为：

$$K = f\sigma\sqrt{\pi a} \quad (2-1)$$

式中： σ 为与裂纹面垂直的正应力； a 为裂纹尺寸； f 为几何修正系数，反映构件和裂纹几何尺寸对裂尖应力场的影响。裂纹扩展模型采用 $K_{th} < K < K_{IC}$ 作为判

断裂纹扩展的条件，其中 K_{th} ， K_{IC} 分别为裂纹扩展门槛值和断裂韧性值，两者的值一般通过物理疲劳试验所得。

2.2.3 裂纹扩展速率模型

裂纹扩展过程一般分为三个阶段：裂纹的萌生，稳态扩展，失稳扩展。如下图 2-2 所示。




图 2-2 裂纹扩展速率模型

该图中的裂纹扩展速率曲线划分为三个区域，依次代表了裂纹扩展过程中的三个阶段。在第一区域裂纹萌生过程中，只有当裂纹尖端的应力强度因子大于裂纹扩展门槛值时，裂纹才得以萌生和发展，否则会被认为无限寿命。此阶段裂纹的发展趋势不明显， $\frac{da}{dN}$ 较小，约为 $10^{-8} \sim 10^{-6} \text{mm/cycle}$ ，过程中试件在应力的循环载荷作用下，会形成微观裂纹，规模较小不易发现；第二区域是裂纹的稳态扩展阶段， $\frac{da}{dN}$ 一般在 $10^{-5} \sim 10^{-2} \text{mm/cycle}$ 。此时裂纹的形状已初具规模，并很容易沿着此形势进行扩展下去，且这一阶段中裂纹尖端的应力强度因子幅值与扩展速率在对数的坐标轴下近似成一条直线，因此也常作为裂纹扩展研究的重点。第三区域是裂纹的失稳扩展阶段，此阶段裂纹尖端的应力强度因子已经接近断裂韧性值裂纹扩展极不稳定，试件随时会发生断裂的情况，故一般不作为重点研究的范围。

在线弹性断裂力学领域，裂纹扩展速率模型在国外得到了更早的发展且已衍生出了多种修正方式。最早的疲劳裂纹扩展速率模型由 Pairs 提出，其公式内容

为:

$$\frac{da}{dN} = C(\Delta K)^m \quad (2-2)$$

式中: $\frac{da}{dN}$ 为裂纹扩展速率, a 为裂纹尺寸, N 为疲劳循环次数, 也被称为寿命值, ΔK 为应力强度因子幅值。将 Paris 公式积分, 可得到疲劳裂纹扩展寿命公式 N 为:

$$N = \int_{a_0}^{a_n} \frac{da}{C(\Delta K)^m} \quad (2-3)$$

式中: a_0 为预制裂纹尺寸, a_n 为裂纹扩展后的尺寸。

2.3 深度学习理论

深度学习是人工智能领域的一个重要分支, 其核心思想是通过构建和训练深层神经网络模型, 从大量数据中学习和提取特征, 以实现复杂任务的自动化处理和决策。神经网络在经历了三起三落之后又开始在各领域得到了更高的重视和更为广泛的研究及应用。一般来说, 数据特征的提取是模型学习的第一步, 现常使用的方式是用卷积计算或者非线性映射计算: 对于图像更多的是使用卷积来提取相关特征, 经典网络如 CNN、VGG、ResNet 等^{[66]-[68]}; 对于数据则使用卷积和非线性映射都可以, 且非线性映射的方式更多一些, 如 RNN^[69]、LSTM、编码器等; 对于文本类型的数据则相对困难一些, 一般要通过词嵌入等处理方式之后再再进行下一步的学习, 表现优秀的网络模型如 BERT^[70]、Transformer、GPT 系列等, 其中均少不了神经元和激活函数下的非线性映射作用。以下将主要介绍工作中使用的网络模型: LSTM、自编码器与 Transformer。

2.3.1 神经网络

神经元是神经网络的基本构成单位, 构成了神经网络的隐藏层、连接层等。其作用是拟合非线性函数关系, 其输出表达式为:

$$y = \sigma(\sum_{i=1}^n (\omega_i x_i + b_i)) \quad (2-4)$$

其中, x_i 为输入, ω_i , b_i 为可学习的权重和偏置。 σ 为某种激活函数, 现常用的激活函数有:

1) Sigmoid 函数表达式为:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2-5)$$

2) ReLU 函数, 即修正线性单元, 表达式为:

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2-6)$$

3) Softmax 函数, 常用于分类任务, 表达式为:

$$f(x) = \frac{e^i}{\sum_j e^j} \quad (2-7)$$

4) Tanh 函数表达式为:

$$f(x) = \frac{e^{2x} + 1}{e^{2x} - 1} \quad (2-8)$$

神经网络通过不同的权值连接, 最终建立输入与输出的映射关系。

2.3.2 LSTM 网络

长短期记忆网络模型 (LSTM) 于 1997 年被提出, 并得到广泛应用。LSTM 引入了遗忘门、输入门与输出门三个门控单元, 选择性地遗忘部分输入, 保留重要信息, 从而更好地利用较广范围内的上下文信息, 获得长期记忆的能力^[71]。其结构如下图 2-3 所示。




图 2-3 LSTM 结构示意图

其中, σ 一般为 *sigmoid* 函数, f_t 为遗忘门, i_t 为输入门, C_t 为当前时刻的细胞状态, h_t 为输出门。表达式如下:

$$f_t = \text{sigmoid}(W_f x_t + U_f h_{t-1} + b_f) \quad (2-9)$$

$$i_t = \text{sigmoid}(W_i x_t + U_i h_{t-1} + b_i) \quad (2-10)$$

$$C_t = f_t * C_{t-1} + i_t * \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (2-11)$$

$$h_t = \text{sigmoid}(W_o x_t + U_o h_{t-1} + b_o) * \tanh(C_t) \quad (2-12)$$

2.3.3 Transformer 网络

Transformer 网络起初由 Google 团队提出并在自然语言领域取得显著效果，一问世就大放异彩。其结构与传统神经网络不同，主要由编码器、解码器、多头注意力机制、位置编码、前馈神经网络组成^[72]。如图 2-4 所示。




图 2-4 Transformer 网络结构

网络结构图中位于底端的左侧是输入嵌入，右侧是输出嵌入层，其作用是将输入转化为连续空间的变量。

输入后经过位置编码。这是由于序列数据的位置信息十分重要，尤其在自然语言方面，某处位置的小变动对语义就可能会有很大的影响，因此位置编码为输入序列提供了位置信息，使得数据在序列中保持稳定的顺序，更好的处理相关任务。公式基于三角函数实现。

编码器和解码器两大模块是网络最核心的部分。两者均由多头注意力，前馈神经网络和残差网络组成，且一般在数量上对称存在。

多头注意力意在使网络能像人眼一样抓住于事物的焦点位置，忽视非重点信息。其在网络中的使用能够使得学习过程抓住主要特征，忽视非重点信息，从而更加高效快捷的学习，其计算过程如下：

首先，三个权重矩阵 W_Q 、 W_K 、 W_V 将输入序列数据进行随机映射为 Q 、 K 、 V ，如式所示：

$$Q = X \cdot W_Q, K = X \cdot W_K, V = X \cdot W_V \quad (2-13)$$

之后计算注意力权重，对每个位置的 Q 与所有位置的 K 进行点积操作，经过 Softmax 归一化后得到注意力权重，将这些权重乘以对应位置的 V 并求和，得到每个位置的自注意输出，如下式所示。

$$\text{Attention} = \text{Softmax}\left(\frac{Q \cdot K^T}{\sqrt{d_k}}\right)V \quad (2-14)$$

其中， d_k 是每个头的维度， Softmax 函数应用于点积得到的矩阵，将每个位置的注意力权重归一化为概率。

最后，根据每个注意力头的权重矩阵重复以上步骤得到多个注意力的输出，将这些输出拼接并经过最终的权重矩阵 W_0 得到多头注意力的最终输出，见下式。

$$\text{Multihead} = \text{concat}(\text{Attention}_1, \text{Attention}_2, \dots, \text{Attention}_h) \cdot W_0 \quad (2-15)$$

前馈神经网络由两个线性转换和一个 ReLU 激活函数组成，用于非线性变换和特征提取。其结构较为简单，运算速度快，且能有效提升模型的表征能力。

残差网络，主要由残差块组成，结构如图 2-5 所示。




图 2-5 残差结构

这种跳跃式的连接结构对前后特征信息有效地建立了联系，保证了特征的多样性和有效性。 Transformer 中将“多头注意力+标准化层”和“前馈神经网络+标准化层”交叉作为残差块进行连接，实现了特征的传递，保证了特征信息在深

层变换时的信息不丢失，有效解决深度学习中容易出现的梯度爆炸、梯度消失等问题。

最后网络经过线性层和 Softmax 层将最大概率的结果输出。

2.3.4 注意力机制

注意力机制源于多头注意力，并被单独分离出来加以应用。与多头注意力作用一样，能够调整输入权重，从而加大对重要信息的关注程度，减小非重要信息的干扰。其计算过程要比多头注意力更为简单，运算速度更快。其计算过程示意图 2-6 如下：




图 2-6 注意力计算过程图

首先，对输入 X 进行分别进行两次线性变换（线性变换的权重与偏置均随机），得到两个不同的查询向量 Q 与键向量 E ，向量 Q 与键向量 E 的转置向量进行相乘，得到的矩阵归一化后，每个矩阵的值作为原输入的权重值，将该权重值与同样由随机线性变换得到的向量 V 相乘，所得结果作为自注意力的输出。

注意力结构更为简单，因此计算速度更快。将其搭配在神经网络的结构中仅增加了较小的计算量，却能有效地使网络抓住主要特征，使训练过程更快收敛。

2.3.5 自编码器网络

自编码器是一种无监督的神经网络，由编码器和解码器组成，结构一般为对称存在，如图 2-7 所示。编码器和解码器两部分的实现均由线性变换层和激活函数层（常用 ReLU）完成，因此计算量不大，迭代过程较快^[73]。




图 2-7 自编码器结构示意图

编码器将输入数据进行升维，解码器将此高维数据又进行降维，一升一降的过程完成了数据的重构，在多次迭代下，自编码器将输入数据不断地进行升维与降维，最终满足一定的损失之后迭代完成。重构后的数据具有以下的特点：

- 1) 数据压缩降维。自编码器的输出一般是低于输入的维度，这使得数据有了更鲜明的，维度更小的特征，使得在之后的预测阶段更容易收敛，加快训练的速度与效率。
- 2) 数据去噪。自编码器通过编码器将潜在特征表示映射回原始数据空间，有效对数据进行去噪，这在数据去噪和修复等任务有很大的益处。
- 3) 异常值检测与剔除。自编码器通过对大部分正常数据的学习进行不断地更新重构，而异常数据在重构时会一次次的进行修正，直到将其映射到一个正常的数据空间，或者将其更改到正常的数据空间。

所以自编码器后的数据不仅高效低维的表示了原始输入，更是对其进行了降噪与异常值更正，减小了网络对错误特征数据学习的概率，提升了数据的合理性，进而有利于后续网络的学习。

2.3.6 半监督学习

半监督学习结合有标签数据和无标签数据进行训练。不同于传统监督学习的训练方式，半监督学习旨在用一些少量的有标签数据进行学习，大量的未标记数据来增强模型的性能和泛化能力，在标签数据不全或标注任务困难等情况下常以应用^[74]。

常见的半监督学习方式有：

- (1) 自训练^{[75]-[77]}。自训练是一种最便捷常见的半监督学习方法。它首先使

用标记数据训练一个初始模型，然后使用该模型对未标记数据进行预测，并根据一定的准则选择预测结果作为伪标签加入已标记数据中，接着继续训练模型。整个过程迭代进行，伪标签也在不断更新，直到预测效果达到稳定。

(2) 协同训练^[78,79]。协同训练是一种类似于分布式的半监督学习方法。它假设数据可以分成多个视角或子空间，并使用不同的特征子集来训练多个模型。每个模型使用标记数据进行训练，然后使用其他模型对未标记数据进行预测，并将其中的高置信度预测样本加入其它视图的标记样本中，分别使用各个子集中的标签原本和预测原本训练新的预测模型，直至满足要求。

(3) 标签传播^[80,81]。标签传播是一种基于图的半监督学习方法。它将数据样本构建成图结构，其中节点表示数据样本，边表示数据之间的相似性或关系。已标记节点的标签被传播到未标记节点，通过考虑节点之间的相似性和连接关系来推断未标记节点的标签。

(4) 基于图的半监督分类方法^[82,83]。采用半监督分类算法的方法，可以利用邻接图 $G(V, E)$ 来描述未被标记的数据与被标记的数据之间的关联，其中 V 指的是所有被训练的数据的总数，而 E 则指的是根据计算出的数据与数据之间的差异，给出每个数据的相似度权重。通常情况下，只用相互近邻的样本之间才会出现连接，因此 $G(V, E)$ 绘制了一张所有样本之间的近邻图，如果样本之间不存在边进行连接，则样本之间的权重值为 0。

以上的每个方法都有其特点和适用场景，应根据数据集的特性、标记数据的数量和质量，以及任务的要求和目标选择适当的半监督学习方法。本文使用的数据集为数字格式，数据的特征数量与分类的类别数量不多，所以自训练的方式能够满足标签的生成要求。

2.4 本章小结

本章分为两大部分，分别介绍了疲劳裂纹扩展相关的理论与深度学习理论。裂纹方面，介绍了裂纹的类型，应力强度因子以及扩展速率模型（以 Pairs 公式为主）。深度学习方面，介绍了三种神经网络 LSTM、Transformer、自编码器的组成及原理；介绍了半监督学习特点及常见的几种训练方法，为后文实验提供理论基础。

第3章 钢桁架参数化建模与裂纹数据集建立

3.1 引言

一些工程项目在设计之初，常建立三维立体模型进行分析与改进。常用的建模软件有 SolidWorks, Pro/E, CAD/CAE, ANSYS 以及 ABAQUS 等。前三个软件具有强大的建模和分析能力，而后两者更多的应用于建模及建模后使用有限元方法的分析。由于本文的分析对象为钢桁架并着重于其裂纹生长的研究，所以更适合用有限元的方法分析，在此方面，ANSYS 和 ABAQUS 都各自有不同的优劣势。ANSYS 在分析固体、流体、电磁场等受力问题更具优势，其中的 Workbench 平台也提供了简单便捷的可视化操作页面；ABAQUS 则更擅长处理复杂的非线性问题，材料中提供的多种属性为建模时材料的赋予提供了方便。在裂纹分析方面，ABAQUS 提供了更丰富的裂纹形式且支持自定义，能更好的观察到裂纹的状态；而 ANSYS 则只提供了三种裂纹形式且裂纹形状受到很大的限制极易在计算时发生错误；因此本文以桥梁为背景使用 ABAQUS 建立钢桁架的 3D 模型并以此作为后续研究的基础。

FRANC3D 是 FAC 公司开发的一款裂纹分析软件，可以用来计算微动疲劳裂纹萌生寿命（包括裂纹萌生位置和起裂方向）以及工程结构在任意复杂的几何形状、载荷条件和裂纹形态下的三维裂纹扩展轨迹和寿命。该软件提供了十分丰富的计算功能，可以引入任意三维裂纹，含材料界面裂纹、跨材料界面裂纹、对称裂纹、空腔及有限体积“厚”裂纹等；可考虑温度、裂纹面接触、裂纹面载荷和各种残余应力的影响；可计算弹塑性 J-积分、高温蠕变 C-积分、COD 和 T-应力；具备载荷计划编辑器（Load Schedule），可定义任意复杂载荷谱等。在裂纹仿真方面，该软件又有独特的优势。其采用对话框和向导式的操作方式，任务界面友好，上手难度不大；采用有限元法来计算断裂力学参数，与 ANSYS、ABAQUS、NASTRAN 等工程仿真软件均有接口；能够同时计算各向同性和各向异性材料中 K_I 、 K_{II} 、 K_{III} 的断裂力学软件等。本文的数据来源均源于该软件的运行结果，并在此基础上作进一步研究。得益于有限元的不断发展与完善，FRANC3D 也在不断的被应用和验证，仿真结果有较高的可信度。

3.2 钢桁架模型建立

首先利用 ABAQUS 绘制桥梁钢桁架的结构模型，赋予钢的材料属性如表 3-1。在桁架顶部的结点设置垂直向下大小为 1kN 的载荷，将桁架底部外侧的四个结点固定。整体模型网格采用 T3D2（两结点线性三位桁架单元）单元划分共得到 59 个 T3D2 单元。

表 3-1 钢材料属性

弹性模量 (GPa)	泊松比	密度 (kg/m ³)
208	0.28	7850

建立好的钢桁架的有限元模型如图 3-1 (a) 所示。由于裂纹相对于钢桁架而言是十分微小的存在，为了更有利于对局部裂纹扩展状况的观察，且考虑到钢桁架模型的复杂性和实际工程中算力的局限性，实验中针对最容易发生疲劳断裂的部件进行分析，因此从钢桁架中分割出子模型开展研究，将桁架有限元模型导入到 FRANC3D 中分割出子模型并设置裂纹，这样可以降低算力损耗且大幅提升预测效率。分割出桁架的子模型后建立裂纹，含有裂纹的桁架子模型如图 3-1 (b) 所示。




图 3-1 桁架有限元模型及含有裂纹的桁架子模型

3.3 裂纹的建立与扩展

FRANC3D 为一款模拟三维裂纹扩展的专业软件，但软件本身不具有建模功能，在仿真计算过程中，也需要调用有限元软件的有限元算法来进行计算。因此必须通过 FRANC3D 与仿真软件的接口建立连接才能完成裂纹的扩展仿真工作。本文以 ABAQUS 与 FRANC3D 联合仿真为例，具体的工作过程如下：

(1) 在 ABAQUS 建立实体模型，赋予材料属性，施加约束和载荷，完成网格地划分后在软件中提交计算。计算完成后 ABAQUS 会产生含不同信息地各种文件，如以.log 结尾地文本文件，以.odb 结尾地输出文件，以.inp 结尾地输入文件等。其中 inp 文件包含模型的节点、单元、截面、材料属性、集合、边界条件、载荷、分析步及输出设置等信息，是接口连接的介质文件。

(2) 打开 FRANC3D，进入菜单栏 file 中选择 import，选中 inp 文件。软件读取完成后，会询问是否要切割子模型。这是由于我们平常建立的 3D 模型体积较大，在网格划分时导致产生的数量很多，占据了很大的计算机资源，而裂纹相对于整个模型来说是很微小的存在，如果在整个模型的基础上运算，计算机的计算压力过大，很容易死机；且不能很好的观察裂纹的扩展情况，所以一般都会分割子模型，集中于裂纹产生的那一部分领域。钢桁架模型分割后只保留了存在裂纹扩展的区域，子模型如下图 3-2 所示。




图 3-2 桁架分割后子模型

分割后的桁架子模型形状为长方体，裂纹就在其中心的底部产生。之后保留有限元模型中施加的约束与载荷表面。FRANC3D 无法设置约束与载荷，只能从 inp 文件中读取并继承来自 ABAQUS 的设置。

(3) 设置裂纹。FRANC3D 提供了多种形式地裂纹，如下图 3-3 所示。




图 3-3 裂纹形状选择界面

本文在模拟裂纹扩展时，选择半椭圆片状裂纹模型，即上图中第一种类型。

a, b 为初始裂纹的几何参数, 在设置时可以根据实体模型的几何尺寸, 也可以依据现实中所测得的数据。之后将裂纹放置在子模型适当的位置, 得到了含初始裂纹的子模型图 3-4, 软件调用 ABAQUS 划分网格后如图 3-5 所示。




图 3-4 含裂纹的子模型




图 3-5 子模型网格划分示意图

在这个过程中, 所设定的裂纹嵌入在模型中的预定位置, 接着在实体的表面划分有限元网格, 网格呈三角形形状, 之后对带有初始裂纹的整个实体模型划分有限元网格, 可见裂纹处的网格十分密集, 这是由于裂纹在下一步的扩展时形状会发生变化, 而网格的细密度程度越高, 越能细致的展现裂纹的发展变化, 同时也极大增加了运算量。最后 FRANC3D 对网格进行平滑处理后输出展示。

(4) 静态分析。初始裂纹添加在模型上之后, 就可以计算初始裂纹前缘的应力强度因子、J 积分以及应力大小等。FRANC3D 软件本身并没有有限元求解器, 必须调用有限元软件 ABAQUS 来计算这些参数。在模拟裂纹扩展的过程中, 此步主要是为了检验裂纹是否可以正常扩展, 熟练者可以跳过此步。

(5) 裂纹动态扩展。这是裂纹扩展的关键过程, 也是整个计算最为繁琐耗时的阶段。选择裂纹动态扩展, 选择疲劳扩展方式, 这也是最为常见的扩展方式。

接着选择扩展角度方式为 MTS，计算方式如下式 (3-1)，编辑载荷器设置应力比（本文取值为 0.1，0.2），循环次数为无限循环。

$$\theta = \cos^{-1} \left(\frac{3K_{II}^2 + \sqrt{K_I^4 + 8K_I^2 K_{II}^2}}{K_I^2 + 9K_{II}^2} \right) \quad (3-1)$$

进一步选择裂纹扩展模式如 Pairs、Walker、Forman 等，本次扩展选用的是 Pairs 公式，并如表 3-2 所示设置好公式相关参数^[84]，参数无误的话即可进行裂纹的自动扩展。

表 3-2 Pairs 公式参数

C	m	$K_{th}(\text{MPa}\sqrt{\text{mm}})$	$K_c(\text{MPa}\sqrt{\text{mm}})$
4.5552e-17	4.1987	3.16	191.4

在此扩展过程中，软件根据设置的扩展程度分步进行扩展，每完成一次裂纹扩展，系统将自动重新划分有限元网格，再继续下一次，直至让软件判定模型断裂结束此过程。如图 3-6 是裂纹扩展到某个步时的内部图，图中每一条扩展的路径即是一次扩展。




图 3-6 裂纹扩展到某步时内部图

(6)数据收集。裂纹尖端的应力强度因子到达扩展断裂值时裂纹扩展结束，裂纹扩展整个过程中的扩展长度和应力强度因子变化情况如下图 3-7。




图 3-7 扩展长度与应力强度因子变化示意图

可以看到，I型应力强度因子随着裂纹的扩展在逐渐增大。在扩展前期，应力强度因子变化幅度缓慢，之后变化幅度越来越大，一直到接近断裂韧性值扩展过程结束，试件断裂。多次改变裂纹的尺寸（a 与 b），偏移底部中心点的距离，载荷编辑器的应力比设置，分别进行扩展仿真，并收集扩展过程中的裂纹增长量与循环次数（即寿命值），构造裂纹特征的数据集，部分数据如下表 3-3 所示。本文共模拟了 46 个裂纹，最终构建的数据集维度为 1831*6。

表 3-3 部分数据

a (mm)	b (mm)	Displace (mm)	R	Growth (mm)	cycle
2	2	0	0.1	0.3277	558573.6
3.5	3.5	5	0.1	4.1217	1047883
1	2	0	0.1	2.14	3018093
2	1.8	5	0.2	9.12	5122167
3	2	15	0.1	8.0931	5862851
1.8	1.8	10	0.2	6.201	8652612
3	2	15	0.1	5.9095	5853764
2	1.8	10	0.2	7.205	8042917
1.2	1	5	0.2	3.165	5290909

3.4 数据预处理

本次构造的数据特征包括裂纹的长度、宽度、应力比、（距离中心）偏移距

离、扩展长度，目标数据是寿命值。数据集的各列数据之间单位不同，数据量不同，如裂纹的长度为毫米级，而裂纹的寿命值可达百万次，所以有必要对数据进行归一化预处理。归一化按式进行：

$$\dot{X} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (3-2)$$

$\dot{X}$ 为归一化后的数据， X 为原数据， X_{max} ， X_{min} 分别为此列数据中的最大值，最小值。归一化后，所有的数据均在[0,1]上，更好的计算数据间的距离且网络在训练过程中更易收敛。归一化后的部分数据如下：

表 3-4 归一化后部分数据

a	b	Displace	R	Growth	cycle
0.423	0.4	0	0	0.020777	0.010279
1	1	0.25	0	0.371586	0.032699
0.038	0.4	0	0	0.18835	0.122976
0.423	0.32	0.25	1	0.833749	0.219385
0.808	0.4	0.75	0	0.738798	0.253324
0.346	0.32	0.5	1	0.563847	0.381152
0.808	0.4	0.75	0	0.536893	0.252908
0.423	0.32	0.5	1	0.656681	0.353216
0.115	0	0.25	1	0.283125	0.227117

3.5 本章小结

本章首先在 ABAQUS 工程软件上建立钢桁架的物理模拟模型，将相关文件导入到 FRANC3D 实现了软件间的连接交互。较详细的介绍了 FRANC3D 的裂纹仿真扩展过程并在此基础上构造了裂纹特征数据的数据集，考虑到特征间的量纲不同，将数据进行了归一化预处理。数据集的构造为下文神经网络预测的基础，并在此工作之上进行下一步的研究。

第4章 基于 FRANC3D 的桥梁钢桁架裂纹寿命预测

4.1 引言

裂纹的产生与发展对桥梁的安全通行时刻都产生着威胁,及时预测裂纹在当前状态下的寿命对桥梁的养护与维修有着关键参考作用。现阶段对疲劳裂纹寿命预测的研究总体分为两类:一种基于裂纹扩展速率模型,通过物理实验对模型进行拟合后计算寿命;另一种不考虑裂纹扩展机制,采用数学方法建立数学模型。后者可将裂纹的寿命预测看成一个时间序列预测问题,可以通过采用建立数学模型进行预测。

因此,本章将两者相结合,通过疲劳裂纹的扩展仿真所得的数据关注裂纹的扩展状况,收集裂纹特征信息并以此为基础开展对裂纹疲劳寿命的预测研究。借助于神经网络模型的拟合和学习能力,利用数据集直接预测出裂纹寿命,可以节约大量的计算成本,同时简化软件仿真计算步骤。另外,神经网络良好的性能表现也取决于输入的质量,由此提出的自编码器+注意力结构对数据重构,为神经网络提供了更高质量的输入,提升训练效率,也获得更高的准确率。

4.2 注意力位置及参数寻优

依据第二章节自编码器和注意力机制理论,本章想结合两者优点对原数据进行重构和优化。由于神经网络的结构和参数对数据的学习方面特别敏感,不同的结构和参数设置对学习的结果会有较大的影响,所以神经网络中的结构搭配与参数的设置对最终的结果至关重要。为了更好的使注意力机制与自编码器的融合,充分发挥两者的优势,分别进行了注意力不同位置和注意力不同维度的对比试验,以达到两者更好的融合结果。

自编码器由编码器和解码器构成,编码器部分输出为低维数据,解码器部分输出为高维特征。注意力其自身较有很大的灵活性,无论数据形状如何,其都可以简洁快速的映射在相应的维度空间上,所以注意力机制与高维数据,低维数据都能很好的融合,为了探究两者如何融合才能发挥其最大的优势,由此设计以下四种方案进行对比:(1)注意力放置在编码器输出位置上,与低维数据融合;(2)

注意力放置在解码器输出位置上，与高维数据融合；（3）注意力分别放置在编码器输出位置和解码器输出位置上，与低维和高维数据分别进行融合；（4）自编码器本身，无注意力机制的融合。

自编码器为无监督学习方式的神经网络，所以将五列特征数据和对应的目标数据一共六列数据均作为数据加载到自编码器网络中，实现对原数据集的重构。原始输入形状为 1831×6 的数据，编码器中线性变换将其映射为 1831×16 的高维数据，解码器中将其映射为 1831×4 的低维数据，每个线性变换层后添加 ReLU 层完成非线性映射，编码器与解码器对称设置；数据加载批次大小为 16，迭代次数为 150，选择 Adam 作为优化器，学习率设置为 0.001，使用均方误差损失函数 MSE 计算损失，公式如下：

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (4-1)$$

n 为观测值的数量， y_i 是第 i 个实际观测值， $\hat{y}_i$ 第 i 个实际预测值。

上述三种方案的训练结果如下：




图 4-1 四种方案下的训练损失曲线

由图可知，四种融合方案下自编码器均能较快收敛并在迭代次数达到 60 次左右趋于稳定。方案 1 与方案 2 的结果较为接近，在迭代次数到达 95 次左右时两者几乎重合，但在此之前，方案 1 以更低的损失值快速收敛，表现稍比方案 2 好；方案 3 与前两者相比结果较差，损失值均在其余两种方案之上；方案 4 的损失值最高且最不容易稳定。由此可得，自编码器中注意力的使用有助于训练过程

损失的降低及稳定，且注意力与低维数据的融合更具优势，更有利于数据收敛，与高维数据的融合效果次之；而同时融合了低维和高维的数据表现却没能达到较好的效果，说明多次融合并不一定能达到更好的效果，过度融合反而会弄巧成拙。

由此确定方案 1 为最优方案，即在编码器输出位置添加注意力模块，使得低维数据与注意力机制进行计算。自注意力的实现由线性变换所得，理论上可以进行任意维度的变化，但当维度过大时，归一化后的每个元素会很小，此元素后续又作为权重与 V 向量相乘，所以一般将其控制在较小的数字。本次选取维度为 1 到 5 的整数，在使用方案 1 的基础上迭代次数为 100 其它延续上述网络设置并做出不同维度的训练实验，结果如下图所示。




图 4-2 不同维度时的训练损失曲线

很明显看到，注意力中维度在 1 到 5 的变化范围内，整体的训练效果十分接近，迭代次数到 50 次时趋于稳定，五种维度下损失曲线几乎重合，只有维度为 3 时损失值要比其它的低一些。由此可知，自注意力机制不同维度的设置对训练的影响结果十分接近，但维度为 3 时还是更有优势。由两次的对比实验确定，在编码器输出位置即低维数据处进行注意力计算效果更好一些，注意力机制的维度设置为 3 损失值平均更低一些，由此为下文网络的搭建与设计提供参考。

4.3 LSTM 网络参数寻优

LSTM 网络有效缓解了梯度爆炸、消失的问题，在时序数据预测上具有良好

的表现。网络的参数选择对网络预测的性能有较大影响，因此有必要在数据集上对 LSTM 网络参数进行寻优，以达到更好的性能表现。

参数寻优以 MSE 损失值结果为标准，其值越低认为网络效果越好，计算公式见（4-1）。综合训练效率与性能，最终选择的参数组合如下表 4-1。

表 4-1 LSTM 参数设置表

参数选项	优化范围	最优选择
优化器	Adam, GD	Adam
Lstm 层数	2, 4, 6	2
隐藏层数	2, 4, 6	4
学习率	0.01, 0.001	0.01

4.4 裂纹寿命预测总体框架

本章基于前两节的实验结果，确定了自编码器与注意力更有效的结合方式及 LSTM 网络模型更优性能的参数设置，提出了裂纹寿命预测的总体框架如图 4-3 所示。




图 4-3 本章寿命预测总体框架

具体包含以下几个步骤：

步骤 1 在 ABAQUS 中建立钢桁架的有限元模型，编辑材料参数、载荷等信息后提交计算，计算完成后会得到 odb、inp 等文件，其中 inp 文件为记录建模指令和数据的文本文件，记录了模型构造过程、材料属性、边界条件等内容。

步骤 2 将该 inp 文件导入 FRANC3D 中，结合 2.1.3 节中的公式（2-2）-公

式 (2-3)，建立尺寸为 a_0 的裂纹进行裂纹静态扩展，此过程软件根据模型的形状尺寸计算得到 f 并与 a_0 相乘得到裂纹尖端的应力强度因子 K 。载荷设置为 40Hz 正弦波并将上文表 3-2 中 Pairs 公式的参数及应力比 R 代入，得到寿命计算公式：

$$N = \int_{a_0}^{a_n} \frac{da}{(4.5552e - 17)(1 - RK)^{4.1987}} \quad (4-2)$$

a_n 为扩展后的裂纹尺寸。接着软件计算裂纹扩展后时的 K ，若仍满足 $3.16 < K < 191.4$ ，裂纹将进行下一步的扩展，直至扩展结束。多次改变裂纹特征，记录信息并构造数据集。

步骤 3 数据经过自编码器和注意力机制的重构和学习之后，作为 LSTM 的输入进行寿命的预测。数据首先在编码器中经过线性层变为 1831×16 ，ReLU 之后经过线性层变为 1831×4 的低维数据 X ；自注意力机制通过线性变换从低维数据 X 中分别获得 1831×3 的 Q 、 K 和 V ，将 Q 与 K 的转置进行相乘后经过 Softmax 得到权值，该权值与 V 相乘后得到了含有重要信息的低维数据；之后此数据经过解码器的线性层成为 1831×16 的高维数据，经过 ReLU 和线性变换后形状又转为 1831×6 。

步骤 4 满足一定损失值后的重构数据输入至 LSTM，训练完成后进行裂纹寿命的预测。

4.5 评价指标

为了显示设计的网络结构在此数据集上的表现，引入均方误差和决定系数作为模型效果的衡量指标。均方误差 MSE 是预测值与真实值之间差值的平方的平均值，能够反映模型预测的整体误差，在许多回归问题上都得以应用。其值越低，表明预测值与真实值越接近，网络的效果越好。均方误差 MSE 计算公式见上式 (4-1)。

决定系数 R^2 是衡量模型拟合度的一个指标，它表示模型解释的数据方差的比例，计算公式如下：

$$R^2 = 1 - SS_{RES}/SS_{TOT} \quad (4-3)$$

式中, SS_{RES} 是残差平方和 (Sum of Squares Residuals), 表示实际观测值与模型预测值之间的差异; SS_{TOT} 是总平方和 (Sum of Squares Total), 表示实际观测值的方差。因此, R^2 越接近 1, 说明模型拟合度越好, 模型预测的准确性越高。

4.6 模型训练与参数配置

模型的搭建基于 pytorch 框架, 训练在 Pycharm 平台上完成, CPU 是 Intel i5-8265u, 网络设置如下:

(1) 批次大小 (batchsize): 在训练过程中, 批次设置值过大时, 梯度计算准确率低, 容易陷入局部极小值; 批次设置值过小时, 训练时花费时间多, 梯度震荡严重, 不利于收敛, 虽然梯度计算的准确率较高, 但需要计算整个数据集来求梯度, 在数据集太大的情况下, 效率不高, 因此将此值设置为 16。

(2) 迭代次数 (epoch): 迭代次数设置过大, 损失下降到某个值后易产生振荡, 容易过拟合; 迭代次数过小, 易导致学习不充分, 出现欠拟合, 因此 epoch 设置为 100。

(3) 数据集划分: 80% 为训练集, 20% 为测试集。

(4) LSTM 模型其余参数设置与表 4-1 保持一致。

4.7 实验结果与分析

图 4-4 分别是 LSTM 迭代 100 次的损失和决定系数变化图, 数据集直接在 LSTM 网络下训练的损失与决定系数曲线分别为误差 1 和 $R^2 1$, 在所提结构下数据重构后经过 LSTM 网络训练的损失与决定系数曲线分别为误差 2 和 $R^2 2$ 。实验发现: 由 LSTM 直接训练的最终损失值在 0.0031 左右, 决定系数达到 0.9959; 数据重构后训练的最终损失值在 0.0030 左右, 决定系数达到 0.9989。虽然不论数据是否经过自编码器和注意力的数据重构, 两者最终的损失值和决定系数都很接近, 但从训练的整个过程可以看出在数据重构后网络的损失下降的更快, 下降趋势更稳定; 决定系数更接近于 1 且大幅减少了振荡。




图 4-4 迭代 100 次的损失与决定系数曲线图

将迭代 100 次后的模型参数进行保存，20%的数据用于进行测试。原数据集经过 LSTM 训练后在测试集上的损失和决定系数曲线分别为误差 1 和 $R^2 1$ ，重构后的数据在测试集上的损失和决定系数曲线分别为误差 2 和 $R^2 2$ 。这两种处理方式下的模型表现如图 4-5 所示，其中横坐标代表测试样本的数量。




图 4-5 测试集上的损失和决定系数曲线图

可以发现，经过自编码器和注意力融合后的重构数据在测试集上的表现要比未进行数据重构优秀的多：其在测试集上的损失值更低，决定系数同样更高达到 0.998 且整体趋势更加稳定。未数据重构的损失值相对来说偏高且跳动幅度巨大，充分证明了所提结构下的数据更利于网络的训练，不仅加快学习速度还使得训练

过程更加稳定。

将载荷大小调整为 5KN 并构建新的测试集。LSTM 与所提方法的预测效果如下。图中横坐标代表测试的样本数量，蓝色曲线为仿真值，预测 1 为 LSTM 网络的预测值，预测 2 为所提结构下网络的预测值。纵坐标均为归一化后的寿命值。




图 4-6 LSTM 与所提方法预测效果图

显然，所提结构的预测结果与 LSTM 相比效果更佳，其预测值与仿真值几乎完全吻合，只存在微小的差距。表明所提方法更适于疲劳裂纹寿命的预测，能更准确可靠的预测结果。原因在于：自编码器能对原始时序数据进行高低维的转化融合，同时实现降噪作用；注意力机制能有效地关注重要信息，减少对非重要信息的关注，有效提升网络的学习效率。自编码器中引入自注意力机制的融合优势在于：1）自注意力机制不需要定义查询（Q）、键（K）和值（V），而是从编码器输出位置直接通过线性变换获取并计算相似度得分，使得模型在处理任务时更加灵活，能自动适应不同的维度数据；2）自注意力机制能够考虑编码器输出数据的全部信息而不是局部信息，使得模型更好的关捕捉全局的关联性，减少部分信息丢失；3）自注意力机制参数少，复杂度低，训练速度也快；也使得数据在解码器中低维向高维的转换减少了信息冗余，从而完成高质量的数据重构。虽然所提方法增加了算法的复杂性，需要对原数据进行预训练，但是能够有效的提升网络训练效率，使结果更为准确，且所提结构的训练过程迭代速度快，参数量少，并没有增加太多的计算量，因此具有较高的可行性。

选取几组裂纹特征对网络进行测试，得到的预测值与 FRANC3D 的仿真值进

行比较并计算误差，结果如表 4-2 所示。

表 4-2 裂纹信息与预测误差

长度 (mm)	宽度 (mm)	位置 (mm)	应力 比	增长值 (mm)	仿真值 (10^{10})	结果 1 (10^{10})	结果 2 (10^{10})	误差 1 (%)	误差 2 (%)
2.0	1.8	5.0	0.2	9.12	5.122	5.271	5.088	2.910	0.664
1.8	1.8	0.0	0.2	8.90	4.357	4.449	4.320	2.112	0.849
2.0	1.8	10.0	0.2	0.55	2.652	2.707	2.646	2.074	0.226
1.5	1.0	5.0	0.1	3.50	4.820	4.949	4.814	2.676	0.124
1.0	2.0	15.0	0.1	9.40	13.50	13.92	13.42	3.111	0.593

注：仿真值，预测值与误差均保留四位有效数字。表中结果 1 和误差 1 分别表示传统 LSTM 得到的预测值和相应误差，结果 2 和误差 2 分别表示本文所提改进后的 LSTM 得到的预测值和相应误差。

由表 4-2 可以看出，数据重构后 LSTM 网络训练的误差最大在 0.849%，最低在 0.124%，整体均低于原始 LSTM 的训练误差。证明所提结构能有效优化 LSTM 模型，使其预测的结果具有更高的准确度。另外，将裂纹特征信息送入训练好的网络中，其可以立刻预测出结果，整个过程所用时间可以忽略不计，而使用 FRANC3D 进行裂纹扩展并分步计算寿命，至少要花费十几分钟的时间。由此，利用神经网络进行寿命预测大幅节约时间成本的同时极大地提高了预测效率。实际应用中，可搭配数字相关技术测得裂纹数据，使用神经网络对该状态下的裂纹寿命进行预测，省去了数值模拟的繁琐过程，便捷的为维护人员提供参考结果。

4.8 本章小结

本章针对 FRANC3D 裂纹寿命计算步骤繁琐，计算过程耗时较长，所以提出 FRANC3D 与深度学习相结合的方法进行大跨径桥梁钢桁架裂纹寿命预测，在框架中提出了一种自编码器和注意力的融合结构对数据进行重构，实验结果表明：1) LSTM 网络可以很好的预测裂纹疲劳寿命，且数据经过自编码器和注意力的融合重构后，损失值下降的更快，决定系数也更快接近于 1，表明所提结构能有效的加快训练促进网络收敛。2) 经数据重构的 LSTM 训练完成后在测试中有着更低的误差，最大误差也在 0.849%，表明所提结构能有效提升模型性能并具有更高的准确度。

第 5 章 半监督学习下的裂纹扩展阶段识别

5.1 引言

在第四章中由 LSTM 网络预测疲劳寿命，并使用所提结构进一步提升了网络的性能，使结果更加准确。但是裂纹的形状与初始大小不一，只依据寿命结果并不能直接表征裂纹扩展的程度。之前的疲劳裂纹仿真工作中得到了裂纹完整寿命的相关数据，由此可以绘制出扩展速率曲线来判断裂纹扩展阶段的类别。裂纹扩展速率模型将裂纹扩展阶段分为裂纹萌生，裂纹稳态和失稳扩展三个阶段，由于裂纹扩展过程是个连续不断的过程，其中的三个阶段是紧密相连的。裂纹扩展的第一阶段裂纹萌生阶段扩展速度缓慢容易判别，第三阶段快速扩展阶段变化迅速也容易识别，第二阶段稳态扩展阶段处于两者中间，此阶段的中间部分比较平稳因此可以区分，但是第二阶段的两端尤其是其与其它阶段的过渡处很难判断属于哪个阶段，而半监督的学习方式可以有效解决这种困惑。半监督学习是在标签数据缺乏的情况下，通过对现有标签数据的学习对网络进行预训练，训练完成的网络对没有标签的数据进行预测并通过迭代学习进行更新。这种训练模式对与数据标签缺乏的情况提供了很好的解决方法。

本章通过半监督学习的训练方式对裂纹扩展所属阶段进行识别。首先，在扩展过程中对于易于确定的扩展所属阶段给以相应的标签，难以确定所属阶段的数据标签为空白，构建适合半监督学习方式的数据集。LSTM 模型有效缓解了梯度消失或爆炸问题，在捕捉裂纹扩展过程中的长期依赖关系方面表现出色；近几年 Transformer 由于在处理文本语言的强大性能引起学术界的广泛关注并产生了各自变体应用于各个领域。Transformer 在数据预测中尤其是在处理长序列数据时也具有其明显的性能优势，这主要得益于其中的注意力机制和前馈神经网络结构，有效提升特征表征效率和模型的泛化能力；自编码器模型，自编码器在特征提取和数据降噪方面得以广泛的应用。由此，本章分别训练 LSTM、Transformer、自编码器三种网络模型用于裂纹扩展阶段的识别，并对各模型的识别效果进行对比分析。

5.2 数据集扩充

在之前的工作中，已成功构建桥梁钢桁架的有限元模型，并使用 FRANC3D 完成了疲劳裂纹的扩展仿真，在仿真过程中记录相关信息并处理构建数据集。将长度、宽度、位置、应力比和裂纹增长量作为五个学习特征，现将部分可以确定裂纹扩展所属阶段的样本数据赋予 0，1 或 2 作为学习标签，具体赋予方法如下：在裂纹扩展初期，扩展量数值和变化幅度很小，很容易认定此阶段属于扩展中的第一阶段，所以赋予标签 0；在扩展中期，扩展量数值稳定的增大，扩展阶段比较平稳，此阶段的中间区域样本赋予标签 1；扩展临近结束时，扩展量极速增大，模型很快到达断裂状态，赋予标签 2；对于无法确定所属阶段的样本数据无标签赋予，由此将数据集分为有标签数据和无标签数据。其它无法确定所属阶段的数据标签为空白。由此构造了适用于半监督学习方式的数据集。数据集中共记录了 1831 条信息，有标签数据约占总数据量的 70%，将裂纹特征信息部分进行归一化处理。部分数据集如表 5-1 所示。

表 5-1 归一化后的部分数据赋予类别标签

长度	宽度	位置	应力比	增长值	标签
0.42308	0.4	0	0	0.20715	0
1	1	0	0	0.63318	
0.61538	0.6	0	0	0.52083	1
0.80769	0.8	0.25	0	0.44617	
0.80769	0.8	1	0	0.868410	2
0.34616	0.4	0	0	0.49172	1

5.3 网络搭建

5.3.1 LSTM 网络搭建

不同于前一章的回归预测任务，LSTM 网络输出层维度为 1，针对本章的分类任务，对该网络输出层作出调整。由于分类的类别总量为 3，所以将输出维度改为 3，输出值归一化后每个维度的值认为是该类别的概率。网络其余的设置与上表 4-1 一致。

5.3.2 Transformer 网络搭建

Transformer 网络结构主要由编码器，解码器，注意力机制，位置编码，前馈神经网络组成。面对数据类型的分类任务，本章对其结构进行了以下改变来满足需要。

首先，由于输入数据是数字形式，因此不需要像文本数据一样进行嵌入操作，所以嵌入层由线性层代替；数据集中只包含 5 个数据特征，并不像文本有很强的长度和顺序要求，所以删掉了原本网络中的位置编码部分。另外编码器结构足以对数据的特征进行有效地提取和学习，所以为了减少过度学习，造成过拟合的可能，同时对网络进行轻量化，删去原网络中解码器部分，在编码器之后经过线性层输出。保留原网络的多头注意力、前馈神经网络、残差结构等，加入 Dropout 层提高泛化能力。由此，构建的 Transformer 网络具体结构如图 5-1 所示。




图 5-1 本文使用的 Transformer 模型

其中嵌入层维度为 4，注意力头数为 4，编码器数量 N 为 2。

5.3.3 自编码器搭建

自编码器为一种无监督学习网络，通过数据的降维升维完成对数据的学习，可将数据特征映射在某空间。自编码器包含编码器和解码器两个部分。编码器和解码器均有线性层和 ReLU 层构成。输入数据在编码器的作用下从高维映射到低维，然后解码器进行反操作，使数据从低维扩展到高维，最终变化到合适的维度

并经过线性层输出。自编码器由于自身经过不断的维度变换，所以有助于原始数据的降噪与重构，从而根据更新后的特征进行训练学习。自编码器结构如下图。图中，M 设置为 8，P 为 3。




图 5-2 自编码器结构示意图

三个模型数据集加载批次大小均为 32，学习率、优化器与 LSTM 网络一致。网络的运行环境和使用的语言框架与上章节均一致。

5.4 半监督学习方式的裂纹扩展阶段识别框架

针对裂纹在扩展过程中所属阶段部分无法确定，所以本文用半监督学习的训练方式，整体框架如下。




图 5-3 裂纹扩展阶段识别框架

具体的识别算法如下：

表 5-2 扩展阶段识别算法

扩展阶段识别算法步骤:
假设数据集中标签数据为X，无标签数据为X'。 For epoch=1,2,..., Num 将X输入到某神经网络内进行训练学习； If epoch=150 保存网络参数； End for 设置伪标签置信度阈值 $\text{pseudo_label_threshold} = 0.95$； For epoch=151,152,...,200 1.网络遍历无标签数据X'进行初次预测并输出； 2.将所有批次的预测输出沿着第一个维度拼接，得到完整的预测输出集 'unlabeled_outputs = torch. cat(unlabeled_outputs, dim=0)'; 3.使用 'torch.max' 函数沿着第二个维度找到每个预测结果的最大值和对应的索引， 分别作为预测概率 'pseudo_probs' 和伪标签 'pseudo_labels'； 4.根据置信度阈值筛选出满足要求的伪标签：'confident_indices = (pseudo_probs >= pseudo_label_threshold). nonzero(as_tuple=True)[0]'; 5.网络继续训练，期间网络参数不断更新，伪标签也根据新的预测结果不断更新，生成更高质量及稳定性的伪标签； End for

5.5 评价指标

对于分类任务，交叉熵函数常用来损失计算。其表达式如（5-1）。

$$\text{loss} = -\log\left(\frac{e^{y_c}}{\sum_{i=0}^2 e^{y_i}}\right) \quad (5-1)$$

其中 y_i 表示网络输出层赋予 i 类别的分值， y_c 表示 i 中某类别 c 的分值，该公式衡量的是模型预测的概率分布与真实标签的概率分布之间的差异，其值越小，表明预测结果越接近，模型性能越好。本章中标签数据与伪标签的损失计算都使用该公式，总损失如式（5-2）。 loss1 是标签数据的损失， loss2 是伪标签的损失。

$$\text{Loss} = \text{loss1} + \text{loss2} \quad (5-2)$$


准确率，分类任务中最常用的评价指标，衡量模型预测正确的样本所占的比例。准确率越高，说明模型的性能越好，表达式如（5-3）。

$$Acc = T/S * 100 \quad (5-3)$$


T 表示预测值与结果相等的样本数量， S 表示所有样本数量。

5.6 训练结果与分析


图 5-4（a）、（b）、（c）依次是 LSTM、Transformer、自编码器三种网络模型的训练过程示意图。蓝色曲线代表有标签数据的损失，橙色曲线代表无标签数据的损失。从图中可以明显看出，三种网络的损失均随着迭代次数的增加不断下降，并都获得了较高的准确率。其中，自编码器有着更为突出的训练效果，损失曲线很快收敛到一定值，准确率确定很快接近 100%并能稳定下来；与之相比，Transformer 和 LSTM 网络的效果稍微差一点，损失曲线和准确率曲线到达一定值后并不能稳定下来，而是产生了轻微波动；三者相比效果最差的是 LSTM 网络，收敛速度最慢且准确率相对而言较低；或许是对于长度较短的数据量 LSTM 失去了处理长序列数据的优势，以至于效果不太理想；而三种网络下的伪标签在自更新过程中随着迭代次数的增加，损失值呈波动下降，准确率也呈波动上升；LSTM 网络和 Transformer 网络效果接近，而自编码器同样在伪标签的预测上性能明显优于两者，损失最低，准确率也最高，甚至波动程度也最低。



（a） LSTM 的损失和准确率曲线图




(b) Transformer 的损失和准确率曲线图




(c) 自编码器的损失和准确率曲线图

图 5-4 三种网络模型训练过程图


三种模型迭代训练完成后, 得到伪标签的混淆矩阵如下。



(a) LSTM 伪标签预测



(b) Transformer 伪标签预测



(c) 自编码器伪标签预测

图 5-5 三种模型的伪标签预测结果图


类似的可以看出，三种模型对于无标签数据预测的效果均有较高的准确度，特别是自编码器网络的预测结果在各类别均在不低于 98% 的准确率，而 LSTM 和 Transformer 网络预测效果较为接近，虽然也都有不低的准确率但是小部分样本预测结果出现错误。三种模型训练结果如表 5-3。

表 5-3 三种模型训练结果


	有标签 Loss	有标签 Acc	无标签 Loss	无标签 Acc	时间/s
LSTM	0.0435	98.0326	0.1756	96.24	136.72
Transformer	0.0365	98.5831	0.1526	97.41	65.73
自编码器	0.0227	99.0543	0.0979	99.03	27.86

为了更好的展现三种网络对无标签数据生产的伪标签，抽取无标签数据样本


及各个网络生成的伪标签类别，结果如下图 5-6。




(a) 裂纹样本 1 分类结果



(b) 裂纹样本 2 分类结果



(c) 裂纹样本 3 分类结果



(d) 裂纹样本 4 分类结果

图 5-6 裂纹长度归一化后在不同网络下的分类结果

如上图所示,对 4 个裂纹扩展阶段的分类结果总体上三种网络的结果较为接近,有很大的重复性,但第二阶段与其它阶段衔接的过渡部分则极易产生不同的结果,均出现某种网络的结果与其它两者分类的结果不同。具体的,如裂纹 1,Transformer 网络的分类结果偏激进一点,LSTM 与自编码器的分类还在第一阶段时,Transformer 分类在第二阶段,Transformer 也是最早将分类结果划分在第三阶段;对裂纹 4,LSTM 网络的分类结果偏滞后一点,其在第一阶段和第二阶段的划分要比其余两者要长。虽然三种网络在扩展阶段的过渡时期易出现不同的分类结果,但并没出现阶段的跳跃即某种网络的分类为第一阶段而某网络的分类为第三阶段,由此三种网络能较好的学习裂纹扩展的速率曲线,其识别结果还是具有较高的准确度。

由于上述实验中自编码器相对于 LSTM 和 Transformer 网络能更准确的预测伪标签,所以将自编码器预测的伪标签作为无标签数据集中标签的补充,以此构成了全标签的新数据集。将原标签数据集中已存标签不同程度的删除,并研究不同标签率下三种网络在此新数据集下的准确率。结果如下:




图 5-7 不同标签率下三种网络的预测准确率

显然，三种网络在标签率不断提升的情况下，准确率也随之提升；标签率为 50% 时三种网络均达到了较高的准确率且结果十分接近；标签率为 30% 时，Transformer 与自编码器的准确率相近，LSTM 与两者相比结果偏低；标签率为 10% 时，自编码器的准确率要比其余两者高，LSTM 偏低，表明自编码器在标签很少的情况下仍然可以快速学习有效特征并有较高的准确率；而 LSTM 更依赖于标签的学习，随着标签率的上升最终也能达到较高的准确率。

5.7 本章小结

本章针对裂纹扩展过程部分阶段所属阶段难以确定，基于 FRANC3D 构建了适用于半监督学习方式的训练集，分别使用 LSTM, Transformer 和自编码器网络进行训练并进行扩展阶段的识别，结果发现：（1）自编码器网络对扩展阶段的识别效果要优于其它两者，其使用最短的训练时间达到了最准确的预测效果；（2）生成伪标签预测的结果也具有很高的准确性；Transformer 网络和 LSTM 网络效果次之；（3）在标签不同程度的缺失情况下，自编码器能凭借更少的标签达到一定的准确度，而 LSTM 则更依赖于标签的学习。

第 6 章 总结与展望

6.1 全文总结

本文以桥梁钢桁架为研究对象,对裂纹扩展过程中的寿命与扩展的不同阶段进行了研究。首先建立桥梁桁架的仿真模型并与 FRANC3D 联合仿真,以此作为进一步研究的基础。确立经典的 Pairs 公式为裂纹扩展速率模型,较详细的介绍了疲劳裂纹扩展仿真的计算过程并多次进行了不同裂纹的仿真;构建了扩展过程中含裂纹特征信息的数据集,从而建立了深度学习与物理模型的联系。

在寿命预测阶段,选择在时序数据预测表现较好的 LSTM 为基本网络,对此网络参数进行局部寻优以达到更好的性能表现。考虑自编码器的数据优化及重构作用与自注意力机制对重要信息的关注作用,对两者如何更加有效地融合进行了比较,试验确定自注意力机制位于自编码器中的编码器输出位置效果更好,以此为基础搭建自编码器+注意力机制对原数据集的数据完成了重构,同样使用 LSTM 网络进行寿命的预测。实验结果发现,所提自编码器+注意力机制的结构重构的数据更有利于网络的学习,其不仅能在训练过程中更快的趋于收敛,损失值也能进一步降低,决定系数也有所提高。

对于裂纹扩展阶段的识别研究,由于现阶段先验知识难以给出一个确定的所属阶段,所以采用半监督学习的训练方式,以数据集中较少的人为标签去完成全部数据的分类标签,搭建了 LSTM、自编码器、Transformer 三种网络模型进行比较分析。先选择某个网络模型对标签数据进行学习,损失值降低到一定程度时,保存此次迭代后的网络参数对无标签数据进行拟合,选取置信度为 95%以上的结果作为无标签数据中标签的补充,网络继续迭代,网络的参数也在变化,因此生成的伪标签也在不断更新变化,直至迭代结束。实验结果发现,自编码器的效果最好,收敛速度最快且伪标签的生成效果也更加稳定;Transformer 网络效果次之,伪标签的生成有小幅震荡;LSTM 的网络三者中最差,收敛速度较慢且伪标签的生成效果震荡幅度较大。最后抽样验证了三种网络的分类结果并对比了三种网络不同标签率下的结果。

6.2 工作展望

本文仍有许多地方可以改进：

1) 在扩展速率模型的选择上，使用了最常用最传统的 Pairs 公式。随着断裂力学的发展，已有更多的模型公式得到发展，仅考虑 Pairs 公式较为单一，比较多种公式结果应更佳。FRANC3D 中在载荷编辑器页面还可以选择温度对裂纹扩展的影响，但本数据集中并未将其考虑进去；速率模型的参数对裂纹的扩展影响重大，由于受到实验设施和测量技术的限制，文中参数的选定基于他人的实验结果及已发表的成果中获取，后续工作中将考虑到环境气候等综合特征并结合实际物理实验对裂纹寿命预测的结果进行验证和修正，以更接近于实际的工况和应用，为桥梁安全运行和健康管理提供有用的理论和工程价值。

2) 本文的创新点之一是使用自编码器+自注意力的结构对原数据进行重构，但并没有对原网络的结构做出较大的改变和创新。众多学者在原网络的基础上，对其结构进行改变和创新也取得了较好的结果。考虑网络的改变与所提结构更好的搭配使其效果更佳是进一步的工作；对于伪标签的生成方式比较单一，采用了自训练生成和置信度筛选的方法，后续应该进一步考虑其它伪标签的生成与评价方法，得到更高质量更佳准确的伪标签，将更有利于网络识别结果的准确。

参考文献

- [1] Ye H W, Yang Z, Duan Z C, et al. S-N fatigue curve determination for corroded high-strength bridge wires[J]. *Journal of Engineering Mechanics*, 2021, 147(5).
- [2] Hassen B M, Elechi B S, Mrad H. Crack propagation in Axial-Flow fan blades under complex loading conditions: A FRANC3D and ABAQUS co-Simulation approach[J]. *Applied Sciences*, 2025, 15(3): 1597.
- [3] 郑史雄, 雷川鹤, 贾宏宇, 等. 人工智能技术在桥梁抗震领域的应用综述[J]. *地震工程与工程振动*, 2023, 43(04): 1-13.
- [4] 周传月, 郑红霞, 罗慧强, 等. MSC. Fatigue 疲劳分析应用与实例[M]. 北京: 科学出版社, 2005, 18-44.
- [5] Rychlik I. A new definition of the rainflow cycle counting method[J]. *Fatigue*, 1987: 119-121.
- [6] 商搏世. 基于台架试验的工程钢圈疲劳裂纹萌生寿命研究[D]. 广西科技大学, 2022.
- [7] 姚森. 基于 SCADA 系统运行数据的风机齿轮箱齿轮疲劳寿命分析[D]. 宁夏大学, 2020.
- [8] 彭杰. 大型风力机叶根连接结构强度分析与疲劳寿命研究[D]. 湘潭大学, 2018.
- [9] Ren H L, Zhou A G, Jia J J, et al. Fatigue life analysis of bearing in oscillatory applications based on Ncode DesignLife[J]. *Journal of Physics: Conference Series*, 2023, 2489(1).
- [10] Zhang G X, Niu G G, Guo S S. Analysis of fatigue life of a torsion beam based on nCode Design-Life[J]. *IOP Conference Series: Materials Science and Engineering*, 2018, 423(1).
- [11] Lhoussaine T, Yassine K, Farid A, et al. Structural design and analysis of a small wind turbine blade using Simple Load Model, FAST-MLife codes, and ANSYS nCode DesignLife[J]. *Wind Engineering*, 2021, 45(2): 213-230.
- [12] Li H F, Wei J L, Li S H, et al. Fatigue life prediction of high-speed train bearings based on the generalized linear cumulative damage theory[J]. *Fatigue and*

- Fracture of Engineering Materials and Structures, 2023, 46(6): 2112-2120.
- [13] Xue Q W, Du X Y. Fatigue design of welded structure based on the non-linear cumulative damage theory[J]. Journal of Mechanical Engineering, 2019, 55(6): 32-38.
- [14] Xiao Q, Wang X L, Chen D Y, et al. A new nonlinear fatigue cumulative damage model based on load interaction and strength degradation[J]. International Journal of Fatigue, 2025, 191: 108709.
- [15] Peng Y, He L, Yan D, et al. A modified nonlinear cumulative damage model for combined high and low cycle fatigue life prediction[J]. Fatigue & Fracture of Engineering Materials & Structures, 2024, 47(4): 1300-1311.
- [16] Riley D, Isaac H. Influence of nonlinear cumulative damage in gear lifetime analysis[C]. American Gear Manufacturers Association Fall Technical Meeting 2024, FTM 2024.
- [17] Yutaro O, Kei K, Yasuhiro Y. The life evaluation by linear cumulative damage rule for cold dwell fatigue of Ti-6Al-4V alloy[J]. Fatigue & Fracture of Engineering Materials & Structures, 2022, 45(1): 259-269.
- [18] Paris P, Erdogan F. A critical analysis of crack propagation laws[J]. Transaction ASME, Journal of Basic Engineering, 1963, 85: 528-534.
- [19] Walker K. The effect of stress ratio during crack propagation and fatigue for 2024-T3 and 7075-T6 aluminum[J]. ASTM International, 1970, 1: 334-348.
- [20] Forman R G, Kearney V E, Engle R M. Numerical analysis of crack propagation in cyclic-loaded structures[J]. Journal of Basic Engineering, 1967, 89(3): 459-464.
- [21] Maierhofer J, Pippan R, Gänser H. Modified NASGRO equation for physically short cracks[J]. International Journal of Fatigue, 2014, 59: 200-207.
- [22] Qu A B, Li F C. Effect of double crack on fatigue crack growth life of 3D printing compressor impeller[J]. Thin-Walled Structures, 2023, 189.
- [23] Kumar A S, P.K A. Influence of stiffener on fracture parameter and fatigue crack growth life of a finite aluminium alloy plate[J]. Journal of the Brazilian Society of Mechanical Sciences and Engineering, 2021, 43(5).

- [24] Feng Q S, Sun K, Chen H P, et al. Long-Term prediction of fatigue crack growth in ballastless track of high-speed railway due to cyclic train load[J]. Construction and Building Materials, 2021, 292.
- [25] Pandey B V, Singh V I, Mishra K B. A stress triaxiality based modified Liu–Murakami creep damage model for creep crack growth life prediction in different specimens[J]. International Journal of Fracture, 2020, 221(1): 101-121.
- [26] Pereira K, Wahab A M. Fretting fatigue crack propagation lifetime prediction in cylindrical contact using an extended MTS criterion for non-proportional loading[J]. Tribology International, 2017, 115: 525-534.
- [27] 吴秀平. 钢桁节点板疲劳裂纹扩展及寿命评估[D]. 重庆交通大学, 2022.
- [28] 车福炎. 10CrNi5MoV 高强度钢耐压结构疲劳裂纹扩展寿命研究[D]. 中国舰船研究院, 2021.
- [29] 徐田. 铁路车轴轮座微动疲劳裂纹扩展的仿真研究[D]. 西南交通大学, 2022.
- [30] 龙慧, 刘义伦, 李松柏. 基于有限单元法的裂纹梁结构疲劳寿命预测模型[J]. 中南大学学报(自然科学版), 2020, 51(04): 953-961.
- [31] 赵龙. 旋挖钻机底架损伤容限设计及疲劳可靠性分析[D]. 长安大学, 2023.
- [32] Wang Z F, Shi Y, Yang X G, et al. Low-cycle fatigue performance and life prediction of a P/M nickel-based superalloy with artificial surface defect at elevated temperature[J]. Engineering Fracture Mechanics, 2023, 294.
- [33] Zhang L, Wei X H. Crack growth life calculation approach of surface cracked landing gear strut under eccentric compression load by bulging effect[J]. International Journal of Fatigue, 2023, 173.
- [34] Zhu J C, Xu L, Guo W L. The influence of bending loading on surface fatigue crack growth life[J]. International Journal of Fatigue, 2023, 167(PA).
- [35] Wang Z Y, Wang Y Q, Gu H Y, et al. Study on fatigue behavior and crack propagation life of longitudinal fillet welded lap joint[J]. International Journal of Fatigue, 2023, 167(PA).
- [36] Zhou C Y, Zhang J N, Zhang Y H, et al. Research on fatigue crack propagation life prediction method for subsea pipelines[J]. Journal of Physics: Conference Series, 2022, 2390(1).

- [37] Wang S Q, Wu Z R. Numerical simulation of fatigue crack growth life of single side notched specimen[J]. Journal of Physics: Conference Series, 2021, 1965(1).
- [38] 王志航. 疲劳裂纹扩展与寿命预测的集成学习算法研究[D]. 华北理工大学, 2022.
- [39] 刘瑞萍. 基于小波变换和DBN的车轴疲劳裂纹声发射信号实验数据分析[D]. 大连交通大学, 2021.
- [40] 张云超. 旋转机械剩余寿命预测方法研究[D]. 南京航空航天大学, 2021.
- [41] Zafer Y, Pasa Y, Alev T. Crack propagation life prediction of a single lap shear joint: A linear elastic fracture mechanics based machine learning approach[J]. Procedia Structural Integrity, 2022, 42: 663-671.
- [42] Zhang L, Wei X H. Prediction of variable amplitude fatigue crack growth life based on modified grey model[J]. Engineering Failure Analysis, 2022, 133.
- [43] Lu S S, Liu B C, Yang R, et al. Prediction of crack growth life at elevated temperatures with neural network-based learning schemes[J]. Aerospace, 2022, 9(10): 600.
- [44] Yao Y R, Liang T, Tan J X, et al. A bearing fault detection and remaining useful life prediction method based on a multi-branch residual feature fusion mechanism and optimized weight allocation[J]. Measurement Science and Technology, 2024, 35(2).
- [45] Li D P, Chen J X, Huang R Y, et al. Sensor-aware CapsNet: Towards trustworthy multisensory fusion for remaining useful life prediction[J]. Journal of Manufacturing Systems, 2024, 72: 26-37.
- [46] Wang Z Y, Wei S G, Cai B G, et al. A weight-allocation-based ensemble remaining useful life prediction approach for a single device[J]. Measurement, 2024, 224.
- [47] Shi J Y, Zhong J S, Zhang Y X, et al. A dual attention LSTM lightweight model based on exponential smoothing for remaining useful life prediction[J]. Reliability Engineering and System Safety, 2024, 243.
- [48] Jiang G J, Duan Z W, Zhao Q, et al. Remaining useful life prediction of rolling bearings based on TCN-MSA[J]. Measurement Science and Technology, 2024,

35(2).

- [49] Cheng L, Cao C, Chen Z Y, et al. In-situ study the crack initiation mechanism of P92 steel under high-temperature three-point bending fatigue process[J]. Materials Characterization, 2024, 218(P1): 114447.
- [50] Zhang N Y, Liu W Q, Shi T, et al. Pore-based prediction of crack initiation life in very-high-cycle fatigue[J]. International Journal of Fatigue, 2025, 190: 108655.
- [51] Li X, Ye T, Du Y H, et al. Effect of microstructure on small fatigue crack initiation and early propagation behavior in super martensite stainless steel[J]. International Journal of Fatigue, 2025, 190: 108604.
- [52] Tang K, Cui C, Liu W J, et al. Multiscale and multifield coupled fatigue crack initiation and propagation of orthotropic steel decks[J]. Thin-Walled Structures, 2024, 199: 111843.
- [53] Guo J, Zhao A M, Yang M S. Crack initiation mechanism of M50 bearing steel under high cycle fatigue[J]. International Journal of Fatigue, 2023, 174.
- [54] Wang Y L, Zhao Y C, Zhang X. Dynamic propagation of tensile and shear fractures induced by impact load in rock based on the dual bilinear cohesive zone model[J]. Engineering Computations, 2024, 41(7): 1865-1883.
- [55] Jape S, Young B, Haghgouyan B, et al. Actuation-Induced stable crack growth in near-equiatomic Nickel-Titanium shape memory alloys: Experimental and numerical analysis[J]. International Journal of Solids and Structures, 2021, 221(15): 165-179.
- [56] Foroozmehr F, Bocher P. Effect of low temperature intercritical heat-treatment on stable crack growth behavior in 13% Cr-4% Ni martensitic stainless steel multipass weldments[J]. Engineering Fracture Mechanics, 2020, 240(12): 107360.
- [57] Huang X, Shi C, Ruan H N, et al. Stable crack propagation model of rock based on crack strain[J]. Energies, 2022, 15(5): 1885.
- [58] 马天宇, 巩固, 曹宏瑞, 等. 8Cr4Mo4V 轴承钢微观裂纹萌生与扩展机制的分子动力学模拟研究[J/OL]. 中国机械工程, 1-13.

- [59] 钱师雄, 林铭毅, 赵秋. 拉索高强钢丝疲劳寿命与疲劳裂纹萌生机理[J]. 铁道建筑, 2024, 64(12): 6-13.
- [60] 包骐乐, 代巧, 邱睿. 基于 DIC 的工业纯钛缺口疲劳裂纹萌生及扩展表征[J]. 机械强度, 2024, 46(05): 1258-1264.
- [61] 戚钊, 王斌, 张鹏, 等. 应力比对含缺陷选区激光熔化 TC4 合金稳态疲劳裂纹扩展速率的影响[J]. 金属学报, 2023, 59(10): 1411-1418.
- [62] 肖瑞, 杨明. 20CrMnTiH 低碳马氏体钢疲劳裂纹稳态扩展模型[J]. 钢铁, 2018, 53(01): 72-78.
- [63] 孙立臣, 娄培杰, 李成杰, 等. 基于离散元的平行双裂隙砂岩破裂特征和失稳机理研究[J]. 矿业研究与开发, 2024, 44(08): 182-189.
- [64] 陈光波, 唐薇, 李谭, 等. 裂隙煤岩组合体单轴压缩力学响应及失稳机制[J]. 岩土力学, 2024, 45(09): 2633-2652.
- [65] 曹彩芹, 华军. 工程断裂力学[M]. 西安交通大学出版社, 2015.
- [66] Krizhevsky A, Sutskever I, Hinton E G. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [67] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[J]. CoRR, 2014, abs/1409.1556.
- [68] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[J]. CoRR, 2015, abs/1512.03385.
- [69] Zaremba W, Sutskever I, Vinyals O. Recurrent neural network regularization[J]. CoRR, 2014, abs/1409.2329.
- [70] Devlin J, Chang M W, Lee K, et al. BERT: Pre-training of deep bidirectional transformers for language understanding[J]. arXiv, 2018.
- [71] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation. 1997, 9(8): 1735-1780.
- [72] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[J]. arXiv, 2017.
- [73] Kingma P D, Welling M. Auto-encoding variational bayes[J]. CoRR, 2013, abs/1312.6114.
- [74] Berthelot D, Carlini N, Goodfellow I, et al. Mixmatch: A holistic approach to

- semi-supervised learning[J]. Advances in neural information processing systems, 2019, 32.
- [75] Samadi N, Tanha J, Jalili M. Graph theory-based semi-supervised self-training for data stream classification and emerging class detection[J]. Information Sciences, 2025, 698: 121762.
- [76] Wang H Q, Chen L, Hao K R, et al. A novel self-training framework for semi-supervised soft sensor modeling based on indeterminate variational autoencoder[J]. Information Sciences, 2025, 690: 121565.
- [77] Gu X J, Yu S P, Huang F, et al. Consistency self-training semi-supervised method for road extraction from remote sensing images[J]. Remote Sensing, 2024, 16(21): 3945.
- [78] Chen M C, Wang C J. Multi-head co-training: An uncertainty-aware and robust semi-supervised learning framework[J]. Knowledge-Based Systems, 2024, 302: 112325.
- [79] Li J X, Zhu X Y, Wang H R, et al. Stacked co-training for semi-supervised multi-label learning[J]. Information Sciences, 2024, 677: 120906.
- [80] Peng Z X, Zheng G Z, Huang W. Semi-supervised learning with close-form label propagation using a bipartite graph[J]. Symmetry, 2024, 16(10): 1312.
- [81] Zheng Y F, Liu Y F, Qing D P, et al. A novel ensemble label propagation with hierarchical weighting for semi-supervised learning[J]. Knowledge and Information Systems, 2024, 67(3): 2521.
- [82] Wang Z S, Li Y G, Yang C H, et al. Graph-based active semi-supervised learning: Case study in water quality monitoring[J]. Advanced Engineering Informatics, 2024, 62(PD): 102902.
- [83] Qiao Y H, Cui C Q, Wang Y Y, et al. A debiased self-training framework with graph self-supervised pre-training aided for semi-supervised rumor detection[J]. Neurocomputing, 2024, 604: 128314.
- [84] 熊勋, 杨莹, 汪舟, 等. 基于 FRANC3D 和 ABAQUS 联合仿真三维疲劳裂纹扩展分析及寿命预测[J]. 武汉理工大学学报(交通科学与工程版), 2020, 44(03): 506-512.

攻读硕士期间取得的学术成果

- [1] 郭黎, 王国栋, 龚建业, 等. 基于FRANC3D和LSTM的桥梁钢桁架裂纹寿命预测[J]. 振动、测试与诊断, 2024, 44(04): 646-651.
- [2] Zhang H, Guo L, Wang G D, et al. Noise reduction and reconstruction of acoustic emission signals from industrial robot gearboxes based on wavelet transform and CEEMDAN[C]. 2023 6th International Conference on Robotics, Control and Automation Engineering (RCAE), 2023: 285-289.

致谢

行文至此，落笔为终。回望在安徽工程大学求学的三年时光，心中既有即将踏上新旅程的憧憬，也满溢着对这段珍贵岁月的感恩。

首先感谢我的导师郭黎教授。三年时间里从论文的选题，到实验的设计，再到论文撰写时的修正，您始终耐心的对我进行指导，是我科研道路上的指明灯。不仅是科研，同时生活上也给予关心与指导，您的教诲是我宝贵的财富。

感谢课题组的小伙伴们，你们的到来使严肃寂静的实验室多了几分生机，在科研道路上很荣幸与你们共同探讨、共同进步。感谢寝室的室友，闲暇时候的聚餐、游玩是我很快乐的回忆。

感谢我的父母。谢谢你们一直辛苦支持我。求学二十余载，一直愧于对家人的亏欠。无时无刻，你们都是我奋斗的动力，我也会尽早扛起身上的担子让你们不再劳累。

最后，感谢对本论文进行评审的各位老师，感谢你们在百忙之中抽出时间审阅论文。祝愿你们身体健康，工作顺心！