

数据驱动的正交异性钢桥面板 RD 节点裂纹疲劳寿命评估

田亮^{1,2,3}, 王宗御¹, 樊健生³, 樊立龙^{2,4}, 张海顺^{2,4}, 赵健^{2,4}

(1.天津城建大学, 土木工程学院, 天津 300384; 2. 中国铁建大桥工程局集团有限公司, 天津 300300; 3.清华大学, 土木工程系, 北京, 100084; 4. 天津市装配式桥梁智能建造技术与装备重点实验室, 天津, 300300)

摘要: 为克服传统 S-N 曲线与名义应力法无法精确描述 U 肋-顶板节点 (Rib-Deck, RD) 微观局部复杂应力状态及其受制造工艺影响显著的局限性, 提出了一种数据驱动的 RD 节点裂纹寿命评估方法。通过将双向门控循环单元 (BiGRU) 与自注意力机制 (SA) 嵌入至卷积神经网络 (CNN) 中, 结合仿真实验所构建数据集, 以实现 RD 节点裂纹疲劳寿命的预测。研究表明: 验证集平均误差约 35 万次循环, 最大误差控制在 124 万次循环内; 独立测试集误差收敛至 2 万次循环左右, 峰值误差不超过 4.6 万次循环。消融实验证明: BiGRU 与 SA 的协同作用可显著提升预测精度。本研究为钢桥面板关键节点的裂纹疲劳寿命评估提供了高效、精准的数据驱动解决方案。

关键词: 正交异性钢桥面板; 数据驱动; 数值仿真; 裂纹扩展; 疲劳寿命预测

中图分类号: U446

文献标志码: A

Data-Driven Fatigue Life Assessment of Cracks in RD Joints of Orthotropic Steel Bridge Decks

Tian Liang^{1,2,3}, Wang Zongyu¹, Fan Jiansheng³, Fan Lilong^{2,4}, Zhang Haishun^{2,4}, Zhao Jian^{2,4}

(1. College of Civil Engineering, Tianjin Chengjian University, Tianjin 300384; 2. China Railway Construction Bridge Engineering Bureau Group Co., Ltd., Tianjin 300300; 3. Department of Civil Engineering, Tsinghua University, Beijing, 100084; 4. Tianjin Key Laboratory of Prefabricated Bridge Intelligent Construction Technology and Equipment, Tianjin 300300)

Abstract: To overcome the limitations of traditional S-N curves and nominal stress methods in precisely characterizing the complex local stress state at the rib-to-deck (RD) joint and their significant susceptibility to manufacturing processes, a data-driven method for assessing crack initiation life at RD joints is proposed. By integrating BiGRU and self-attention mechanisms into a CNN framework and utilizing a dataset constructed from simulation experiments, this study achieves accurate prediction of fatigue crack life in RD joints. The specific research process is as follows: First, a finite element model of the rib-to-deck (RD) joint was developed in ABAQUS, and fatigue crack growth analysis was performed using FRANC3D software to construct a corresponding dataset. Second, a CNN-BiGRU-SA model is constructed, where the CNN extracts local features from the dataset, the BiGRU captures temporal dependencies in crack propagation, and the SA suppresses irrelevant information while highlighting critical features, thereby obtaining more salient feature representations. Finally, the trained CNN-BiGRU-SA data-driven model is employed to predict the fatigue crack life of RD connections. The results show that the average error on the validation set is approximately 350,000 cycles, with the maximum error controlled within 1.24 million cycles. On an independent test set, the error converges to around 20,000 cycles, with the peak error not exceeding 46,000 cycles. Ablation experiments confirm that the synergistic effect of BiGRU and SA significantly enhances prediction accuracy. This study provides an efficient and precise data-driven solution for evaluating the fatigue crack life of critical details in orthotropic steel bridge decks.

Keywords: OSDs; Data-driven; Numerical simulation; Crack propagation; Fatigue life prediction

收稿日期: 2025-09-22

基金项目: 天津市自然科学基金面上项目 (24JCYBJC00850); 中国铁建股份有限公司科研重大专项 (2023-A01); 中国铁建大桥局集团有限公司科技创新项目 (DQJ-2024-B05); 中国铁建大桥局集团有限公司科技创新项目 (DQJ-2023-A02)

近年来,中国公路交通工程呈现跨越式发展,在建与在役道路桥梁规模稳居全球首位。在此背景下,OSDs 凭借其自重轻、承载能力大、安装方便等核心优势,已成为大跨径桥梁建设的首选结构形式之一^[1]。然而,随着钢桥面板的规模化应用,大量工程实践表明:焊缝连接处普遍存在疲劳裂纹萌生与扩展问题,尤以顶板-U肋焊缝为甚^[2-3]。此类损伤的持续演化将直接削弱结构耐久性,威胁桥梁全寿命周期安全运营。因此,如何实现对 OSDs 典型节点的裂纹扩展分析与寿命评定,已成为保障中国桥梁长效服役的关键所在。

针对 OSDs 疲劳裂纹演化规律分析与及其服役寿命评估,国内外科研人员基于物理方法进行了众多研究,并获得了大量的成果。张清华等^[4-5]提出了一种三维裂纹扩展模拟方法,并开展疲劳试验对裂纹扩展数值结果进行了验证,实现了不同萌生位置多条裂纹的扩展模拟,研究结果表明 RD(Rib-Deck, RD)节点焊根处的疲劳裂纹以I型裂纹为主且多裂纹扩展特性并不明显。田亮等^[6]通过试验与仿真,采用结构应力法评估了UHPC 加固钢桥面板 RD 节点的疲劳性能。结果表明,UHPC 铺层使焊缝应力降低 87.2%,应力分布更平缓,结构应力法预测误差仅 8%,优于热点应力法与临界距离理论,该方法为钢桥面板疲劳寿命评估与维护提供了高效可靠的解决方案。伍星臣^[7]将应力强度因子作为分析参量,融合断裂力学理论与有限元方法,对面板与纵肋连接处的疲劳性能进行了研究,结果降低原始裂纹长度或增加顶板厚度可使裂纹尖端应力强度因子变小,以延长疲劳寿命。白文畅等^[8]采用有限元法分析了车轮荷载对顶板-U肋焊缝处疲劳裂纹的萌生与扩展行为。其研究揭示:当轮载偏离焊缝位置时,裂纹多萌生于顶板处的焊根或焊趾,并沿板厚方向以I型主导模式扩展;而当轮载正对焊缝时,裂纹则起源于顶板焊根或U肋焊趾,沿垂直于腹板的方向呈I-II-III复合型扩展,且扩展速率显著加快。陈荣峰^[9]提出并验证了一种基于断裂力学、结合试验、通过 ABAQUS 与 FRANC3D 协同实现三维疲劳裂纹扩展的高效仿真方法。并应用该方法评估了关键易损细节(顶板-U肋焊缝的焊根和焊趾)在车辆荷载下的疲劳裂纹扩展寿命,为桥梁维护提供了依据。

除了上述基于物理的方法外,计算技术的进步也推动了数据驱动方法的发展,使其成为一种颇具前景的工具,能够在无需预设函数形式的前提下通过机器学习直接学习复杂非线性损伤过程。Ma 等^[10]研发了面向增量学习的全连接神经网络策略。在预测疲劳裂纹扩展方面,该方法相较于传统的拟合公式及常用神经网络(如递归神经网络和长短期记忆方法),展现出显著优势。Zhang 等^[11]提出了一种结合计算机视觉和机器学习的基于机器学习的疲劳裂纹扩展检测方法,结果表明机器学习模型可以帮助我们实现实时可见的疲劳裂纹检测。王晓鹏^[12]基于 CNN-BiGRU-HAM 剩余寿命预测模型,构建了具备数据处理、训练及可视化功能的剩余使用寿命(Remaining Useful Life, RUL)预测系统,从而实现对发动机结构的健康管理。Yang 等^[13]基于深度学习分别分析了 6 组不同材料的现有疲劳数据,所提出的基于深度学习的方法预测精度很高,每个研究案例的预测寿命几乎落在 1.5 倍的散射带内。Wang 等^[14]提出了一种基于极限学习机(Extreme Learning Machine, ELM)、径向基函数网络(Radial Basis Function Network, RBFN)和遗传算法优化的反向传播网络(Genetic Algorithm Optimized Backpropagation Network, GA-BPN)的三种不同机器学习算法的疲劳裂纹扩展预测模型。结果表明,在预测精度和有效性方面,基于 ELM 的模型优于 RBFN 和 GA-BPN 模型;与经典双参数模型对比,ELM 模型在全局优化和外推能力方面表现优异,与实验数据的一致性最好。

当前,在 OSDs 领域,国内外学界与工程界普遍采用传统方法对其疲劳寿命进行计算,但此类方法在计算效率方面存在显著瓶颈。基于此,本文通过对 OSDs 典型构造细节的疲劳性能开展研究,提出一种基于 CNN-BiGRU-SA 的 RD 节点裂纹疲劳寿命预测方法,具体实施过程如下:以 Paris 公式为理论基础,通过开展疲劳裂纹扩展仿真实验来系统构建相关数据集,所得数据将服务于后续模型的开发与评估;设计

CNN-BiGRU-SA 模型：首先，利用 CNN 层对输入信号中蕴含的局部空间特征进行深度提取，以此进一步提升预测模型对 RD 节点局部特性的精准感知能力并结合 BiGRU 层对数据之间存在的时序动态特性进行有效建模，从而为疲劳寿命预测提供更为丰富且全面的时序特征依据；其次，利用特征融合层将提取到的局部特征与序列特征进行组合，构建出包含多维度信息的综合特征；随后，通过自注意力机制对整合后的特征重新调整权重，使模型能够自动聚焦于对预测结果影响更为关键的特征信息；最后，由回归输出层对处理后的特征进行运算分析，进而得到 RD 节点裂纹的疲劳寿命预测值。

1 相关理论及方法

1.1 疲劳裂纹扩展理论

顶板 U-肋焊缝作为钢结构中的关键传力连接区域，其开裂行为的分析需结合具体开裂形态与线弹性断裂力学理论展开。该区域存在四种典型开裂模式，其典型形态图 1 所示；线弹性断裂力学的基本理论框架，主要包含三种不同的裂纹断裂模式^[15]，见图 2。其中，在外部荷载作用下，I 型裂纹面主要承受法向拉应力，致使裂纹上下表面产生张开的相对位移。此类裂纹是工程实践中的高发形态，也是结构断裂的主要诱因^[16]。本文主要针对 I 型（张开型）裂纹行为展开研究。

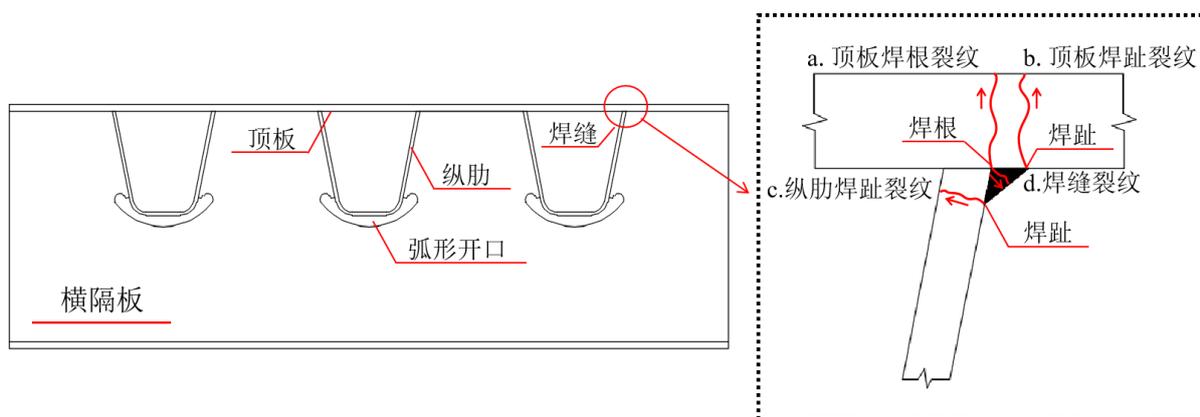


图 1 RD 连接焊缝典型开裂位置

Fig.1 Typical cracking locations of RD connecting welds

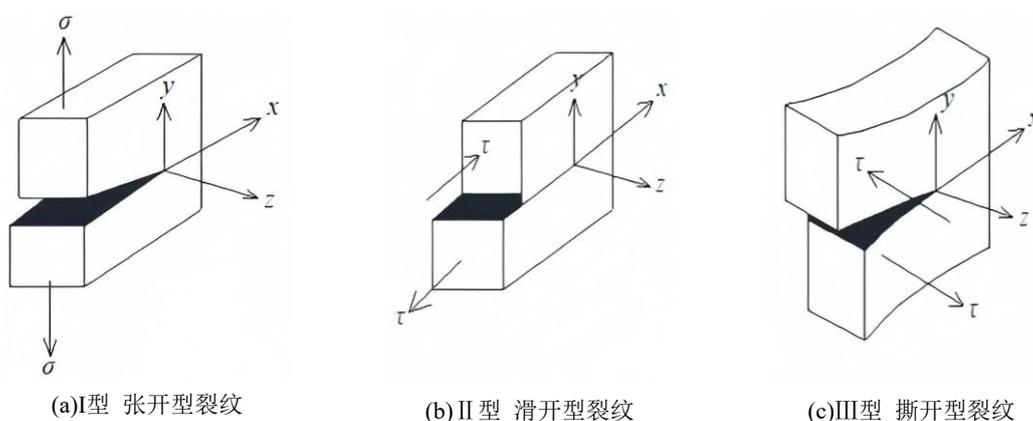


图 2 三种裂纹断裂模式

Fig.2 Three types of crack fracture modes

在断裂力学中，应力场强度因子作为核心断裂参数，量化表征了裂纹尖端附近弹性应力场的强度水平。该参数通常表达为以下数学形式：

$$K_I = \sigma\sqrt{\pi a} \quad (1)$$

式中： σ 表示名义应力（无裂纹假设下的理论计算应力）， a 代表裂纹特征尺寸。

该模型以裂纹扩展门槛值 K_{th} 和材料断裂韧性 K_C 为界，当 $K_{th} < K_I < K_C$ 时，裂纹发生扩展。

在结构损伤评估中，裂纹尺寸及其扩展速率是重要的判据，特别是通过裂纹临界长度来估算疲劳寿命。Paris 公式以裂纹尖端应力强度因子为参量，构建了疲劳裂纹扩展速率的量化模型。

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

其中： a 用于表征裂纹尺寸， N 则记录了所施加的载荷循环次数； C 和 m 为与疲劳裂纹扩展速率的相关常数； ΔK 为应力强度因子幅值。对式（2）进行积分，可以得到裂纹疲劳寿命 N ：

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

其中： a_0 用于表征裂纹的起始状态，即初始尺寸； a_n 则用于描述扩展后的最终尺寸。

1.2 裂纹扩展数值模拟方法

本研究采用 ABAQUS 与 FRANC3D 进行协同仿真，以模拟裂纹扩展过程，FRANC3D 可直接驱动 ABAQUS 求解器，最大程度利用其断裂分析能力。在 ABAQUS 完成全域三维建模与分区后，将裂纹潜在扩展区的数据移交至 FRANC3D，进而定义裂纹并求解，其间程序会自动对扩展中的裂纹尖端网格进行精细化重构。ABAQUS 软件通过应力场计算可得 ODB 结果文件，包含位移、裂纹尖端应力等信息，同样导入至 FRANC3D 计算应力强度因子 K 。若 K 满足 $K_{th} < K < K_C$ ，则基于用户设定的载荷谱（如恒幅循环载荷）和疲劳扩展模型（如 Paris 公式）进行寿命计算。软件在每一计算步中会求解当前的 K 值，并据此判定裂纹扩展条件是否依然成立，以决定模拟是否继续，当 $K > K_C$ 时，判定结构发生临界失稳断裂，裂纹扩展数值模拟结束。ABAQUS-FRANC3D 交互工作流程如图 3 所示。

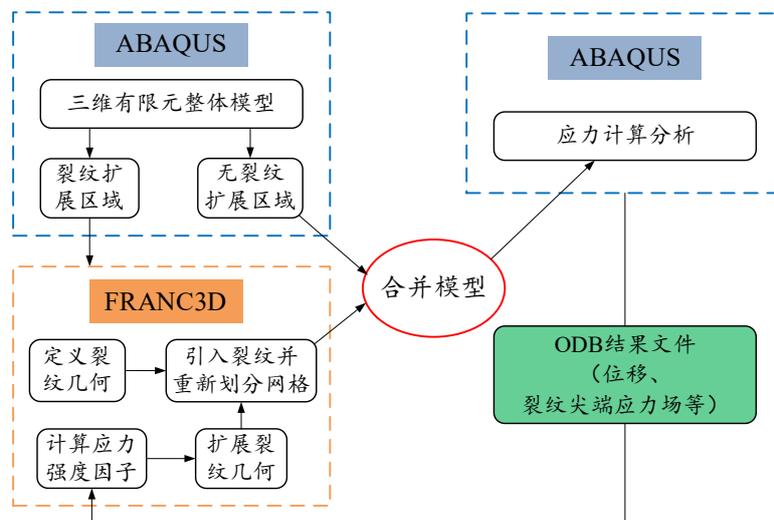


图 3 ABAQUS-FRANC3D 交互工作流程

Fig.3 ABAQUS-FRANC3D interactive workflow

1.3 深度学习理论

1.3.1 CNN

CNN 是深度学习的一种典型架构，通过局部感知与权值共享机制提取输入数据的层次化特征，其中一维卷积神经网络（1D-CNN）通过卷积操作提取一维数据的局部特征。本文所用卷积模块由 1 层卷积层、1 层 ReLU 激活函数、以及 1 层 MaxPooling 层和 1 层 Flatten 层组成。卷积层通过卷积核扫描输入数据，从而提取局部模式并生成对应的特征响应，ReLU 激活函数提供非线性变换。MaxPooling 层执行下采样操作，实现降维并保留最具判别性的特征信息。最后所有特征图将经由 Flatten 层被压缩至一维，以便馈入后续的全连接层以及进行最终的全局特征学习与整合。CNN 网络架构图如图 4 所示。1D-CNN 的卷积运算表达式如下：

$$y_{i,j} = f(W_k * x_{i,j} + b_k) \quad (4)$$

式中： $y_{i,j}$ 为输出数据； W_k 为第 k 个卷积核的权重系数； b_k 第 k 个卷积核的偏置系数； $x_{i,j}$ 为输入数据； f 表示激活函数，本文选择 ReLU 激活函数。

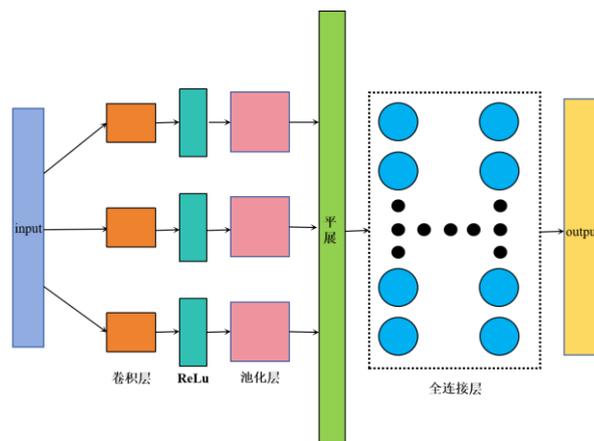


图 4 CNN 网络架构

Fig.4 CNN Network Architecture

1.3.2 BiGRU

门控循环单元（Gated Recurrent Unit, GRU）是对传统循环神经网络（Recurrent Neural Network, RNN）结构的一种优化。它以更紧凑的结构克服了 RNN 梯度消失困境，并增强了对序列长期依赖关系的建模能力^[17]。GRU 只有 2 个门（更新门、重置门），并且可以直接隐藏 h_t 来传递记忆，没有独立的单元状态。GRU 通过更新门和重置门这两个关键机制动态地决定保留多少旧记忆、融入多少新信息，以及计算新信息时参考多少旧记忆。这种设计使模型能够精准捕捉序列数据中的远程关联，其结构更简洁，计算也更快，特别是在数据量或序列长度并非特别大的场景下。GRU 的网络结构如图 5 所示：

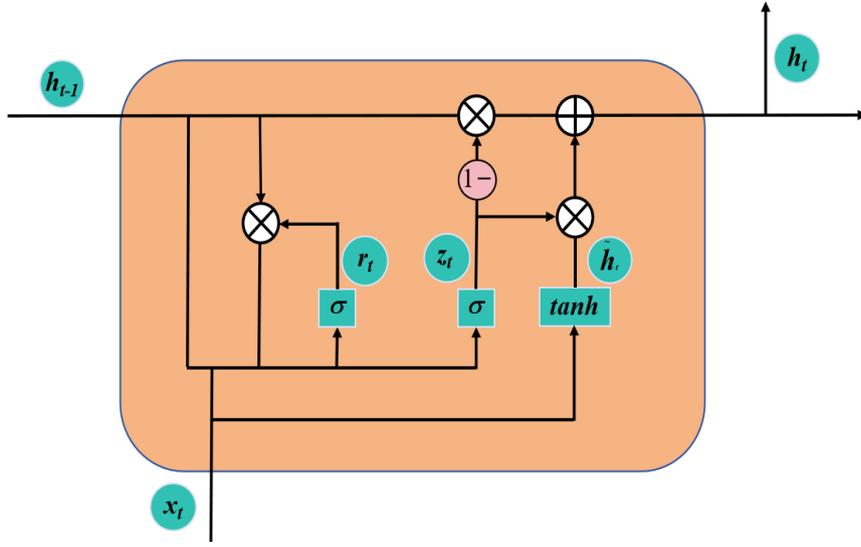


图 5 GRU 网络架构

Fig.5 GRU Network Architecture

GRU 网络参数更新公式如下：

$$\begin{cases} z_t = \sigma(W_z[h_{t-1}, x_t]) \\ r_t = \sigma(W_r[h_{t-1}, x_t]) \\ \tilde{h}_t = \tanh(W[h_t, x_t]) \\ h_t = (1 - z_t)h_{t-1} + z_t \tilde{h}_t \end{cases} \quad (5)$$

其中：\$z_t\$ 和 \$r_t\$ 分别为更新门和重置门；\$\tanh\$ 与 \$\sigma\$ 为激活函数；\$x_t\$ 为输入；\$h_{t-1}\$ 为隐藏状态的输入；\$W\$ 为权重矩阵；\$\tilde{h}_t\$ 为候选隐藏状态；\$h_t\$ 为隐藏层；\$t\$ 为时间步。

BiGRU 是标准 GRU 的一个扩展^[18]。BiGRU 通过其特有的双向编码机制，实现了对序列前后文信息的全局感知，从而更全面地理解序列语境。针对 GRU 单向处理序列数据的局限性，为解决此问题，BiGRU 同时运行两个独立且方向相反的 GRU 层（一个处理正序序列，一个处理逆序序列），都作为输入且一起控制输出，并在运行时将它们每一时刻的隐藏状态合并（通常是拼接），为序列中的每个元素提供了融合完整过去和未来上下文的强大表示。BiGRU 在需要深度理解整个序列上下文的自然语言处理（Natural Language Processing, NLP）任务中表现优异，同时相比 BiLSTM 保持了相对简洁和高效的特点。图 6 为 BiGRU 模型结构图。

BiGRU 数学表达式如下：

$$\vec{h}_t = GRU(x_t, \overleftarrow{h}_{t-1}) \quad (6)$$

$$\overleftarrow{h}_t = GRU(x_t, \overleftarrow{h}_{t+1}) \quad (7)$$

$$h_t = W_t \vec{h}_t + V_t \overleftarrow{h}_t + b_t \quad (8)$$

式中：\$\vec{h}_t\$ 与 \$\overleftarrow{h}_{t-1}\$ 为向前隐藏层状态；\$\overleftarrow{h}_t\$ 与 \$\overleftarrow{h}_{t+1}\$ 为向后隐藏层状态；\$W_t\$ 为前向的权值矩阵；\$V_t\$ 为后向的权值矩阵；\$b_t\$ 为隐藏层的偏置；\$t\$ 为时间步。

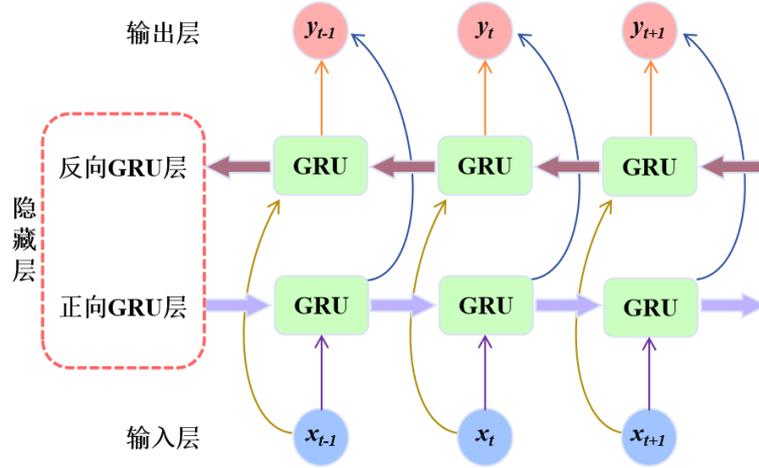


图 6 BiGRU 网络架构

Fig.6 BiGRU Network Architecture

1.3.3 SA

注意力 (Attention) 是深度学习领域中一种模拟人类注意力聚焦特性的重要算法, 其核心是对输入信息中不同部分的重要性进行动态加权, 使模型通过内置的特征筛选机制, 能够自主强化数据中的关键特征, 同时抑制次要信息或噪声的干扰^[19]。SA 是 Attention 机制的一个重要变种, 它的核心特点是 Q(Query, 查询)、K(Key, 键)、V(Value, 值) 都来源于同一序列, 可以捕捉序列内部元素之间的联系。SA 通过让序列中的每一个元素都作为 “Q”, 计算与序列中所有元素的 “K” 的关联度, 从而动态学习元素之间的依赖权重。SA 的计算方式一般分为 3 个步骤^[20]。首先, 通过计算查询 (Q) 与所有键 (K) 的关联度, 生成相应的注意力权重。之后, 利用这些权重系数对输入信息 (即 V) 进行加权整合, 最终得到注意力结果。SA 计算流程图如图 7 所示。其核心公式如下:

$$Self-Attention(Q, K, V) = Soft \max\left(\frac{Q \cdot K^T}{\sqrt{d_k}}\right) \cdot V \quad (9)$$

式中, n 为序列长度; d_k 为 K 的维度; K^T 为 K 的转置; 其中 $\frac{Q \cdot K^T}{\sqrt{d_k}}$ 可以避免维度过大导致内积结果过大, 缓解 Softmax 梯度消失问题。

果过大, 缓解 Softmax 梯度消失问题。

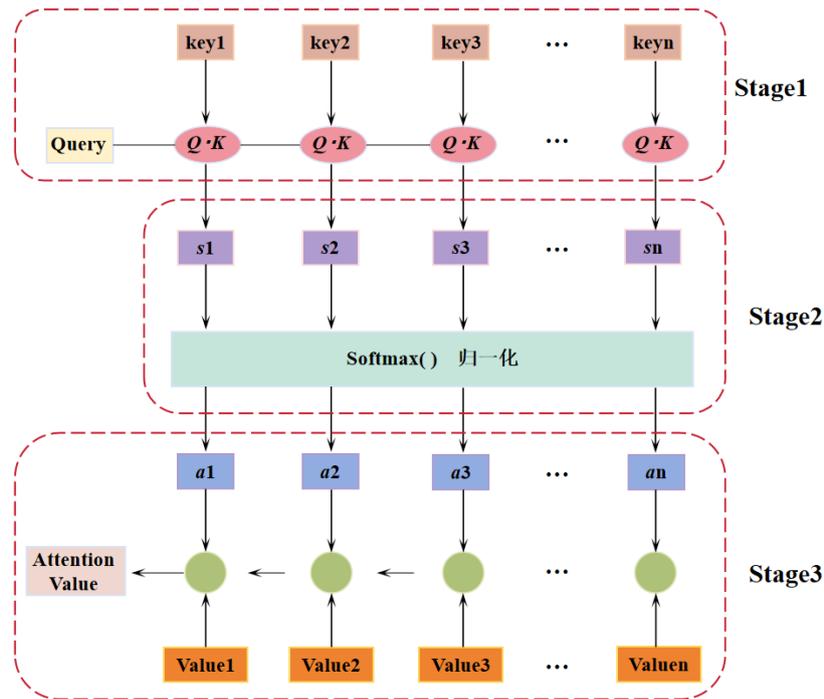


图 7 SA 算法流程图

Fig.7 SA Algorithm Flowchart

1.3.4 CNN-BiGRU-SA

本文构建的 CNN-BiGRU-SA 模型由多分支特征提取层、双向循环层、特征融合层、自注意力机制及回归输出层组成，如图 8 所示。模型工作流程如下：采用[3,1]卷积核实施滑动特征提取，聚焦序列局部依赖模式；批归一化层实现特征分布标准化，ReLU 激活函数注入非线性变换能力，最大池化层进行特征下采样与时序维度压缩，增强模型对局部波动的鲁棒性；BiGRU 分支通过正向 GRU 层处理原始序列，反向 GRU 层（由 FlipLayer 实现序列翻转）处理逆序序列，分别捕捉序列的前向和后向长程依赖关系，BiGRU 通过其门控机制，能够记忆裂纹前期的扩展历史，并动态捕捉当前状态对后续扩展趋势的影响，从而有效建模裂纹扩展过程中的时序动态特性；特征融合层将卷积分支提取的局部特征与 BiGRU 分支提取的时序特征沿特征维度拼接，形成多尺度融合特征表示；SA 对融合特征重新加权，通过 1 个注意力头和 30 个关键通道计算特征重要性分布，增强损伤敏感特征并抑制噪声干扰；回归输出层通过全连接层将加权特征映射到目标维度，输出连续预测值。该模型中，CNN、BiGRU 与 SA 分工协同：CNN 定位局部时空模式，BiGRU 建模裂纹扩展时间差，SA 表示权重，三者通过特征融合层联合优化损伤特征的表达能力。

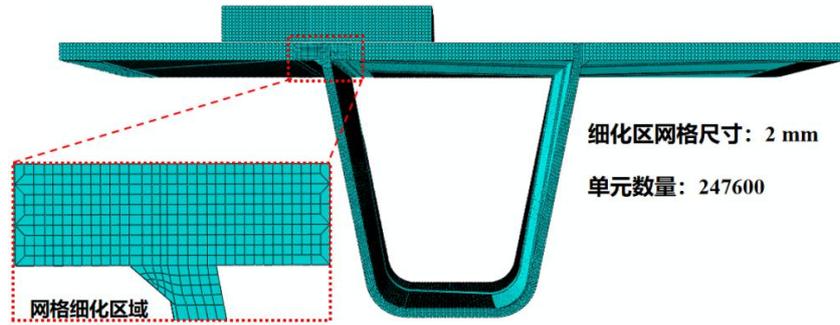


图 10 模型网格划分及加密区

Fig.10 Mesh division and densified area of FE model

2.2 含裂纹 RD 节点子模型

因为裂纹十分微小，为了更详细的观察局部裂纹的扩展行为及节约计算资源，将 RD 节点有限元模型导入 FRANC3D 中分割出子模型并设置裂纹，裂纹类型为角裂纹。部分子裂纹扩展细节模型如图 11 所示。

2.3 数据集构建

由于钢桥面板疲劳裂纹扩展是一个漫长且复杂的过程，本研究通过有限元软件与 FRANC3D 软件构建数据集，通过调整裂纹几何参数、载荷参数，模拟不同工况下钢桥面板的剩余使用寿命。本研究基于 Paris 模型来模拟裂纹的扩展过程，如式(2)所示，其参数^[24]如表 1 所列。完成上述参数配置后，基于 FRANC3D 平台开展裂纹自动扩展仿真。仿真过程中实时记录裂纹长度、深度、外部荷载、应力比、裂纹增长值及裂纹疲劳寿命等关键参数。选取裂纹长度、宽度、外部荷载、应力比和裂纹增长值作为预测模型的 5 个输入特征，以裂纹疲劳寿命作为学习目标。数据集部分样本如表 2 所示。

本研究选取裂纹长度、深度、外部荷载、应力比及裂纹增长值作为输入特征，这一选择具有明确的物理基础：前四个特征完整定义了控制疲劳裂纹扩展的核心力学参量——裂纹尖端的应力强度因子幅值及其循环特性，而裂纹增长值则提供了裂纹演化的动态信息。所有特征均具备良好的工程可测性，确保了模型的实用价值。各参数的取值范围明确（裂纹长度与深度：0.5-2.0 mm；外部荷载：0.32-1.6 MPa；应力比：0-0.1；裂纹增长值：0.06-3.42 mm），该设计充分覆盖了 RD 节点疲劳裂纹的典型工程工况，保证了数据集的有效性和代表性。

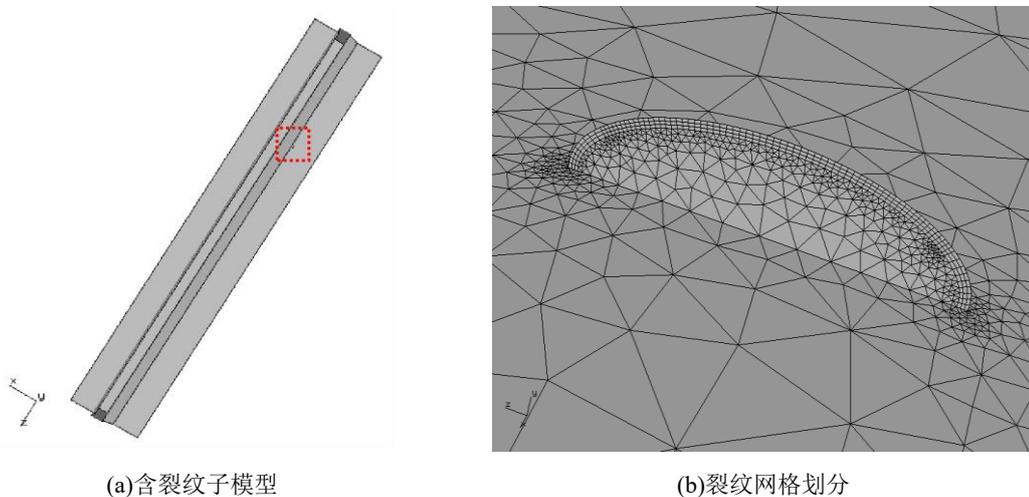


图 11 裂纹扩展细节模型

Fig.11 Crack Propagation Detailed Model

表 1 疲劳裂纹扩展 Paris 参数

Tab.1 Paris parameters for fatigue crack growth

C	m	阈值 $K_{th}/(\text{MPa}\cdot\text{m}^{1/2})$	阈值 $K_c/(\text{MPa}\cdot\text{m}^{1/2})$
4.552×10^{-17}	4.1987	3.16	191.4

表 2 部分训练数据

Tab.2 Partial training data

深度/(mm)	长度/(mm)	应力比	荷载/(MPa)	增长值/(mm)	寿命值/(次)
0.5	0.5	0	0.32	0.061058	3834733
0.5	1.0	0	0.64	2.349916	17365180
0.5	1.0	0.1	0.32	0.688487	6343692
1	1	0	0.32	1.534611	6857223

3 实验结果分析

3.1 模型训练与超参数配置

本模型的搭建与训练过程在 MATLAB 平台上完成，所用 CPU 为 Intel i7-9750HF，显卡采用 NVIDIA GeForce GTX1650，具体网络参数设置如下：

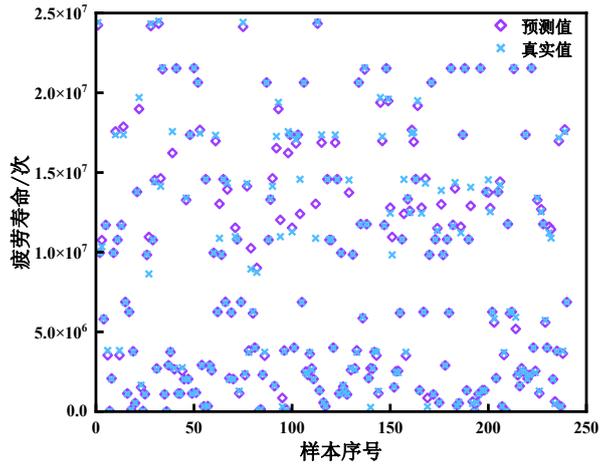
- (1) 数据集：取 80%为训练集，20%为测试集；
- (2) 优化器：采用 Adam 优化算法；
- (3) 学习率：学习率设为 0.01，能够避免初期震荡发散并保证收敛效率批次大小；
- (4) 迭代次数：训练迭代次数设置为 200 次；
- (5) 批大小：批大小设置为 32 能够使显存需求减半，梯度噪声提升泛化。

3.2 模型训练结果

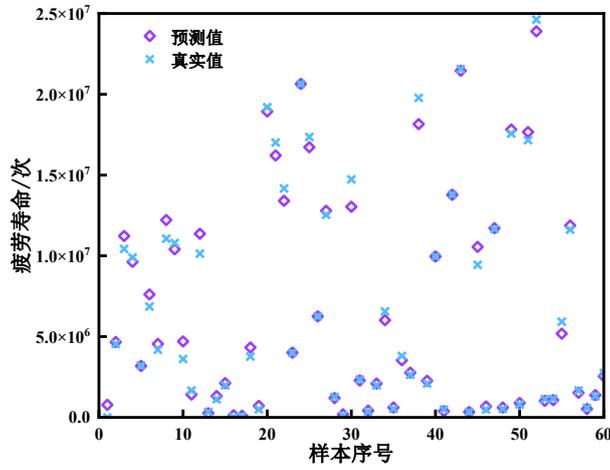
本文所用数据集规模为 300 个样本，经随机化处理后按 4:1 比例划分训练集与验证集。其中 240 个样本驱动 CNN-BiGRU-SA 模型参数学习，60 个样本执行超参数优化与泛化能力验证。为加速收敛过程，采用动态分段学习率机制。终模型的性能可视化结果如图 12 呈现。

为明确后续分析中误差指标的定义，特此说明：本文中“平均误差”与“最大误差”均为疲劳寿命的绝对误差，单位为循环次数。其中，“最大误差”指所有样本中预测值与真实值之差的最大绝对值；“平均误差”为所有样本绝对误差的算术平均值。“误差百分比”为相对误差，其值为预测值与真实值之差的绝对值与真实值之比，以百分比形式表示。

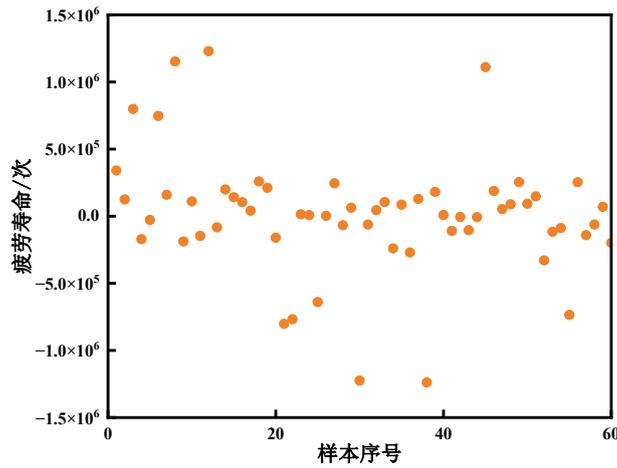
基于图 12 的验证分析，CNN-BiGRU-SA 模型在裂纹疲劳寿命预测任务中表现出卓越性能：验证集预测误差收敛至 25 万次循环左右，峰值误差严格控制在 124 万次循环阈值内。上述结果证实了所提架构在裂纹疲劳寿命预测场景中兼具泛化性与结构鲁棒性。



(a) 训练集预测结果



(b) 验证集预测结果



(c) 验证集误差

图 12 CNN-BiGRU-SA 模型训练结果

Fig.12 CNN-BiGRU-SA model training results

3.3 消融实验结果

本研究通过设计 CNN、CNN-BiGRU 和 CNN-SA 三种架构开展消融实验，旨在解析自注意力机制 SA 与双向门控循环单元 BiGRU 在裂纹疲劳寿命预测中的协同作用机制。同时构建原始信号对照组，基于

未预处理数据训练 CNN-BiGRU-SA 基准模型以验证特征预处理的必要性。各架构的验证性能对比结果详见表 3 与图 13。

由表 3 和图 13 的消融实验结果可知,基础 CNN 模型因难以有效捕捉裂纹扩展过程中的时序动态特性,在验证集上出现较大预测偏差,其最大误差达 421 万次循环。相比之下,通过引入 BiGRU 模块显式建模裂纹扩展的时序依赖关系,再通过结合 SA 机制强化关键特征权重, CNN-BiGRU-SA 模型显著提升了预测精度,将最大误差和平均误差分别降至 124 万次循环和 35 万次循环,充分验证了所提架构在提升预测精度方面的有效性。

表 3 验证集结果

Tab.3 Validation set results

模型	平均误差/(次)	最大误差/(次)
CNN	752922	4214895
CNN-SA	752495	3474150
CNN-BiGRU	572378	3222952
CNN-BiGRU-SA	351324	1238514

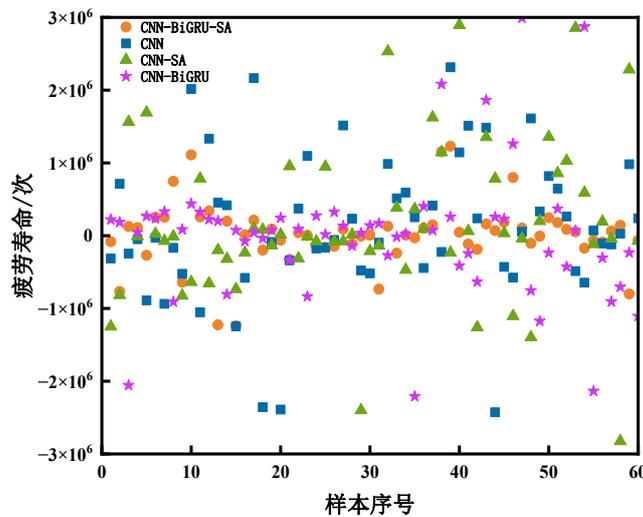


图 13 消融实验对比

Fig.13 Ablation study comparison

3.4 模型预测结果

在上述研究基础上,通过调整正交异性钢桥面板 RD 节点的有限元模型参数(如几何尺寸、荷载条件等)及裂纹参数(如初始长度、深度、裂纹增长值等),重新构建包含 20 组数据的独立测试集。将训练完成的 CNN-BiGRU-SA 数据驱动模型应用于该测试集,开展 RD 节点裂纹疲劳寿命预测,模型的预测结果及部分裂纹的详细信息与对应误差,分别见图 14 与表 4。

从图 14 可见, CNN-BiGRU-SA 模型在测试集上展现出稳定的预测精度:测试集误差收敛于 2 万次循环左右,且峰值误差控制在 4.6 万次循环以内。表 4 中,增长值为裂纹扩展的长度;真实值为仿真模拟裂纹扩展扩展至对应长度时,所需承受的循环载荷次数即疲劳寿命值;预测值则为本研究提出方法所得循环

载荷次数。为更精准地呈现误差程度，表 4 的预测值、仿真值及其误差均精确至小数点后三位，充分验证了该模型对正交异性钢桥面板 RD 节点裂纹疲劳寿命的可靠预测能力。

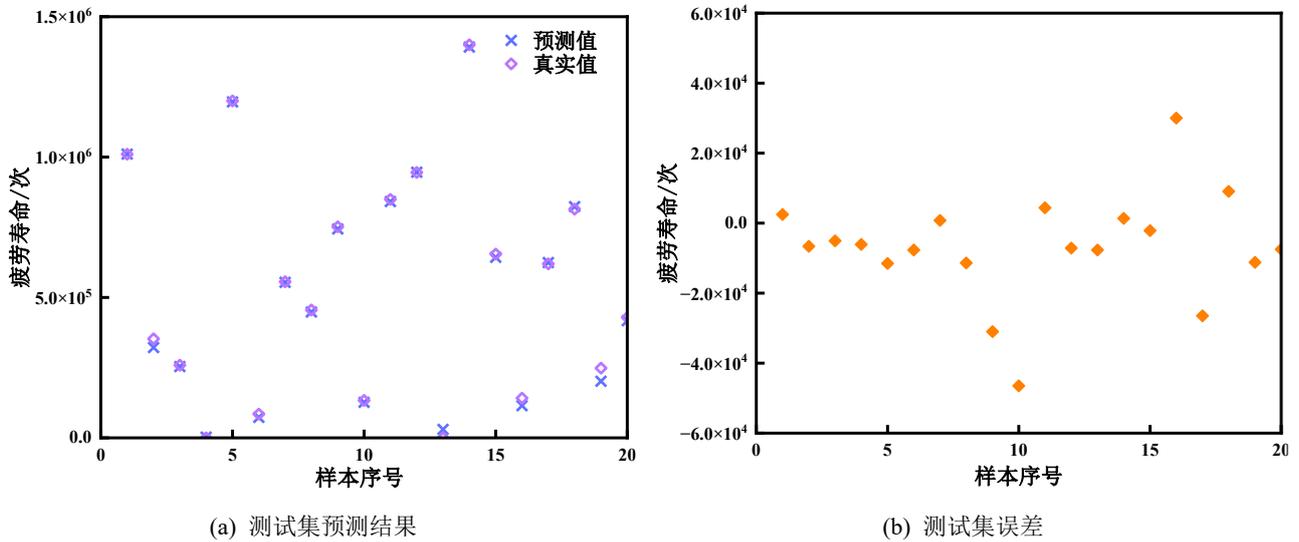


图 14 CNN-BiGRU-SA 模型测试结果

Fig.14 Test results of the CNN-BiGRU-SA model

表 4 预测误差分析

Tab.4 Prediction error analysis

长度/mm	深度/mm	荷载/MPa	应力比	增长值/mm	真实值	预测值	误差/%
1.5	1	0.64	0	3.42	1.009×10^6	1.011×10^6	0.198
0.5	0.5	1.6	0.1	0.60	5.121×10^5	5.106×10^5	0.286
1.5	1.5	0.64	0	1.55	6.544×10^5	6.481×10^5	0.963
2	1.8	0.48	0.1	1.05	2.059×10^6	2.069×10^6	0.523

3.5 模型效率分析

在预测效率方面，本研究提出的数据驱动方法展现出显著优势：CNN-BiGRU-SA 模型虽需约 180 分钟的前期训练投入，但训练完成后可实现秒级（约 0.5 分钟）的单工况预测速度，较传统 ABAQUS/FRANC3D 数值仿真（单工况通常需要 240-1440 分钟）的计算效率有大幅提升。这种从“计算密集型”向“数据驱动型”的范式转变，有效解决了传统方法在工程应用中的效率瓶颈，为钢桥面板疲劳寿命的快速安全筛查与评估决策提供了可靠的技术支撑。

4 结论

本研究围绕正交异性钢桥面板 RD 节点的疲劳裂纹寿命评估展开，提出了一种基于数据驱动的解决方案，主要研究结论如下：

(1) 本研究构建了完整的 RD 节点裂纹寿命评估体系，基于有限元仿真建立了涵盖裂纹关键特征的数据集，并利用 CNN-BiGRU-SA 混合模型实现了对疲劳寿命的高效、精准预测。

(2) 通过消融实验表明, BiGRU 通过建模裂纹扩展过程中的时序依赖关系, 捕捉裂纹演化的动态规律, 降低模型平均误差约 24%, SA 通过聚焦关键特征可进一步降低误差约 39%, 二者协同使 CNN-BiGRU-SA 模型在验证集和测试集上均表现出最优性能(验证集平均误差 35 万次循环, 测试集误差收敛至 2 万次循环左右), 证实了多尺度特征融合对提升预测精度的关键作用。

(3) 本研究创新性地通过物理机理驱动的 CNN-BiGRU-SA 模型, 构建了微观裂纹特征至宏观疲劳寿命的映射关系, 结合多尺度特征融合实现了全链条分析, 跨工况测试验证了其优异泛化能力, 为裂纹扩展机制研究与寿命预测提供了新方法。

参考文献

- [1] 刘朋,陈艺旋,赵健,等. 明珠湾大桥主桥正交异性钢桥面板疲劳性能及寿命评估 [J].桥梁建设, 2023, 53 (06): 41-46.
LIU P, CHEN Y X, ZHAO J, et al. Fatigue Performance and Life Evaluation of Orthotropic Steel Deck of Main Bridge of Mingzhu Bay Bridge[J]. BridgeConstruction, 2023, 53 (06): 41-46.
- [2] 田亮,邢守航,赵健,等.明珠湾大桥钢桥面板易损焊接节点疲劳寿命预测[J].石家庄铁道大学学报(自然科学版),2024,37(02):14-21.
TIAN L, XING S H, ZHAO J, FAN L L, DONG Y X. Fatigue Life Prediction of Vulnerable Welded Joints in Steel Deck of Mingzhuwan Bridge[J]. Journal of Shijiazhuang Tiedao University(Natural Science Edition), 2024,37(02): 14-21.
- [3] 龚代勋,肖虎,李佳,等.正交异性钢桥面板纵肋与顶板焊接细节疲劳性能评估[J].城市道桥与防洪,2025,(05):87-91.
GONG D X, XIAO H, LI J, et, al. Evaluation on Welding Detail Fatigue Performance of Longitudinal Rib and Roof of Orthotropic Steel Bridge Deck[J]. Urban Roads Bridges & Flood Control, 2025, (05): 87-91.
- [4] 张清华,金正凯,刘益铭,等.钢桥面板纵肋与顶板焊接细节疲劳裂纹扩展三维模拟方法[J].中国公路学报,2018,31(01): 57-66
ZHANG Q H, JIN Z K, LIU Y M, BU Y Z. 3-D Simulation Method for Fatigue Crack Propagation in Rib-to-deck Welded Joints of Orthotropic Steel Bridge Deck[J]. China Journal of Highway and Transport, 2018, 31(01): 57-66.
- [5] 张清华,郭亚文,李俊,等.钢桥面板纵肋双面焊构造疲劳裂纹扩展特性研究[J].中国公路学报,2019,32(07):49-56+110.
ZHANG Q H, GUO Y W, LI J, YUAN D Y, BU Y Z. Fatigue Crack Propagation Characteristics of Double-sided Welded Joints Between Steel Bridge Decks and Longitudinal Ribs[J]. China Journal of Highway and Transport, 2019 ,32(07): 49-56+110.
- [6] 田亮,董熠鑫,肖飞知等.基于结构应力法的钢-UHPC 组合桥面板 RD 节点疲劳性能分析[J].华东交通大学学报,2025,42(02):54-65.
TIAN L, DONG Y X, XIAO F Z, et al. Fatigue Performance Analysis of RD Welded Joint in Steel-UHPC Composite Bridge Deck Based on Structure Stress Method[J]. Journal of East China Jiaotong University, 2025,42(02):54-65.
- [7] 伍星臣.基于断裂力学的正交异性钢桥面板疲劳裂纹扩展研究[D].重庆: 重庆交通大学,2019.
WU X C. Fatigue crack propagation of orthotropic steel bridge deck based on fracture mechanics[D]. Chongqing: Chongqing Jiaotong University, 2019
- [8] 白文畅,袁周致远,吉伯海,等.钢桥面板顶板-U 肋焊缝裂纹萌生特征及扩展规律[J].华东交通大学学报,2024,41(01):20-29.
BAI W C, YUAN Z Z Y, JI B H, FU H. Study on Crack Initiation Characteristics and Propagation Laws of U Rib-to-Deck Weld Joint of Orthotropic Steel Bridge Decks[J]. Journal of East China Jiaotong University, 2024, 41(01): 20-29.
- [9] 陈荣峰.基于断裂力学的正交异性钢桥面板疲劳裂纹扩展研究[D]. 南京: 东南大学,2021.
CHEN R F. Research on Fatigue Crack Propagation of Orthotropic Steel Bridge Deck Based on Fracture Mechanics[D]. Nanjing: Southeast University, 2024, 41(01): 20-29.
- [10] MA X R, HE X F, Z.C. Tu. Prediction of fatigue-crack growth with neural network-based increment learning scheme[J]. Engineering Fracture Mechanics, 2020, (prepublish): 107402-.
- [11] ZHANG L, WANG Z C, WANG L, et al. Machine learning-based real-time visible fatigue crack growth detection[J]. Digital Communications and Networks, 2021, 7(4): 551-558.
- [12] 王晓鹏.基于数据驱动模型的航空发动机剩余寿命预测研究[D]. 西安: 陕西理工大学,2024.
WANG X P. Research on Aero-engine Remaining Useful Life Prediction Based on Data-driven Modelling[D]. Xian: Shaanxi

University of Technology, 2024.

- [13] YANG J Y, KANG G Z, LIU Y J, et al. A novel method of multiaxial fatigue life prediction based on deep learning[J]. International Journal of Fatigue, 2021, 151
- [14] WANG H, ZHANG W, SUN F, et al. A Comparison Study of Machine Learning Based Algorithms for Fatigue Crack Growth Calculation[J]. Materials, 2017, 10(5): 543-543.
- [15] 鲁乃唯,余孟南,王凯,等. 考虑轮载横向分布的钢桥面板疲劳裂纹随机扩展路径[J].公路交通科技, 2025,42(03):155-164.
LUN W, YU M N, WANG K, CUI J. Random propagation path of steel bridge deck fatigue crack considering wheel load transverse distribution[J]. Journal of Highway and Transportation Research and Development, 2025,42(03):155-164.
- [16] 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+822.
GUO L, WANG G D, GONG J Y, et al. Crack Life Prediction of Bridge Steel Truss Based on FRANC3D and LSTM[J]. Journal of Vibration, Measurement & Diagnosis, 2024, 44(04): 646-651+822.
- [17] 王儒源,华春莉,欧斌,等.融合注意力机制的 BiGRU 混凝土坝变形预测[J/OL].水力发电,1-9[2025-07-19].
WANG R Y, HUA C L, OU B, et al. Deformation Prediction of Concrete Dam with Bidirectional Gated Recurrent Unit Combined with Attention Mechanism[J/OL]. Water Power, 1-9[2025-07-19].
- [18] 谢逸丰.基于 SCSO-BIGRU 的大坝变形预测[J].北京测绘,2024,38(10):1482-1486.
XIE Y F. Dam deformation prediction based on SCSO-BIGRU[J]. Beijing Surveying and Mapping, 2024, 38(10): 1482-1486.
- [19] 孙建宇,王建敏,孙廷松,等.利用 Attention-LSTM 的 BDS-3 钟差中长期预报[J/OL].导航定位学报,1-11[2025-07-20].
SUN J Y, WANG J M, SUN T S, et al. Medium and long term prediction of BDS-3 clock bias using Attention-LSTM[J/OL]. Journal of Navigation and Positioning, 1-11[2025-07-20].
- [20] 唐尚冲,魏邦旭.基于小波变换及 Self-Attention-CNN 的行星齿轮箱故障诊断方法[J].起重运输机械,2025,(12):38-43+62.
TANG S C, WEI B X. Fault diagnosis method of planetary gearbox based on wavelet transform and Self-Attention-CNN[J]. Hoisting and Conveying Machinery, 2025, (12): 38-43+62.
- [21] 祝志文,李健朋,钟国琛,等.基于现场试验和有限元的纵肋-面板双面焊构造细节应力行为研究[J].中国公路学报,2022,35(06):36-48.
ZHU Z W, LI J P, ZHONG G Z, et al. Stress Behavior of Both-side Welded Rib-to-deck Details Based on Field Tests and Finite Element Analysis[J]. China Journal of Highway and Transport, 2022, 35(06): 36-48.
- [22] 田亮,邢守航,樊立龙,等.移动荷载作用下正交异性桥面板应力响应分析[J].铁道工程学报,2024,41(07):47-55.
TIAN Lg, XING S H, FAN L L, et al. Stress Response Analysis of Orthotropic Steel Bridge Deck under Moving Load[J]. Journal of Railway Engineering Society, 2024, 41(07): 47-55.
- [23] 田亮,邢守航,樊立龙,等.模拟轮载作用下钢桥面板 RD 节点疲劳寿命计算方法对比分析[J].华东交通大学学报,2023,40(04):76-85.
TIAN L, XING S H, Fan L L, et al. Comparative Analysis of Fatigue Life Calculation Methods for Rib-To-Deck Joints in Steel Bridge Decks Under Simulated Wheel Load[J]. Journal of East China Jiaotong University, 2023, 40(04): 76-85.
- [24] 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.
XIONG X, YANG Y, WANG Z, et al. Three-dimensional Fatigue Crack Propagation Analysis and Life Prediction Based on Co-simulation of FRANC3D and ABAQUS[J]. Journal of Wuhan University of Technology(Transportation Science & Engineering), 2020, 44(03): 506-512.