

基于深度学习的结构健康监测方法研究

● 蔡晓宏



[摘要] 本文以特征提取、模型构建、损伤检测及性能评估为核心,系统研究其关键方法和技术。在数据处理中,深度学习通过自动化特征提取和数据增强,提高了输入数据的质量和模型的泛化能力;在模型构建中,采用不同架构优化了训练过程,并提升了检测效率;在损伤检测中,借助分类和回归模型实现了多任务联合学习;在性能评估中,通过分析多种指标验证了模型的可靠性与实用性。研究发现,深度学习在复杂数据处理时具有较高的效率,但实际应用中的鲁棒性和实时性仍有待提升。本文对该领域的研究现状进行了总结,为未来在工程监测领域的实践应用提供了思路。

[关键词] 深度学习;结构健康监测;特征提取;损伤检测;性能评估

大型土木工程建设,如桥梁、大坝和隧道等,具有复杂的结构,运营过程中受各种作用和偶然因素影响不可避免会产生退化或损伤。自20世纪80年代起,结构健康监测(下文简称 SHM)技术可通过传感采集传输手段实现对结构的持续监控,跟踪结构状况并检测早期异常,在超过预警阈值情况下及时发送预警,因此在工程中逐渐被使用。在实时和在线的情况下,SHM 的有效性进一步提高,它可以提供结构的即时状态以避免事故的发生。SHM 是保障土木、航空等领域结构安全与可靠性的关键技术。传统方法在处理复杂数据和实时监测方面存在局限。随着人工智能的发展,深度学习因其强大的数据处理和模式识别能力,逐渐应用于 SHM 领域。本文旨在探讨基于深度学习的 SHM 方法,分析其优势、挑战及未来发展方向。

Q 数据处理与特征提取

(一)数据预处理

在 SHM 中,数据的质量直接决定了分析结果的可靠性,而数据预处理则是保证输入数据一致性和有效性的关键环节。由于监测数据通常受到噪声、传感器误差和采样不完整等问题的干扰,清洗步骤尤为重要。数据清洗过程包括去除异常值、填补缺失数据及平滑信号波动,以消除外部环境或设备故障带来的误差。归一化技术被广泛应用于多源数据融合场景中,将数据缩放到统一范围,确保不同特征之间的量级一致性,提高模型的训练效率和预测准确性。在噪声较为严重的环境中,降噪技术是另一个重要环节,包括低通滤波、小波变换和经验模态分解等方法,通过保留信

号的主要成分提高数据的质量。预处理步骤为深度学习模型提供了高质量的输入数据,提升了模型对复杂结构状态的识别能力。

(二)特征提取方法

特征提取是 SHM 的核心环节,其目标是从海量的传感器数据中提取对结构状态变化敏感的关键特征。传统的人工提取方法依赖于工程经验,通常需要对频域或时域特征进行复杂计算,而深度学习的引入则显著简化了这一过程。卷积神经网络(下文简称 CNN)因其在图像处理中的卓越表现,被广泛应用于振动信号和应力数据的特征提取。CNN 通过逐层卷积操作,将输入数据的局部特征转化为高层次的特征表示,从而捕捉复杂数据中的模式。与传统方法相比,CNN 能够自动识别隐藏在数据中的关键特征,无需依赖预定义规则或特征工程,极大地提升了特征提取的效率和准确性。深度学习模型在处理多维传感器数据时表现出极强的适应能力,可以同时提取空间和时间特征,为后续的分类与回归任务提供了高质量的特征输入。

(三)数据增强技术

数据增强技术通过扩展训练数据集的规模和多样性,提高了模型的泛化能力,尤其在 SHM 中应用广泛。深度学习模型通常需要大量标注数据进行训练,而实际工程中获取高质量标注数据的成本较高。为解决这一问题,可以通过数据增强技术生成新的样本,扩大数据集规模。例如,旋转、翻转和缩放等变换操作被广泛应用于振动信号的频谱图上,以模拟多角度和不同环境下的结构响应。添加高斯噪声或混合信号等方法则可以提高模型对噪声和干扰的鲁棒

性。对于时序数据,随机剪切和插值技术能够在保持数据整体结构的同时增强数据的多样性。

Q 模型构建与训练

(一)模型选择

深度学习模型的选择需要根据 SHM 的具体任务需求进行权衡,不同架构在特定情境下具有独特的优势。CNN 凭借其卓越的特征提取能力,常被应用于振动信号的频谱图和应力分布图分析,通过提取局部特征捕捉结构损伤的微观模式。而循环神经网络(RNN)及其变体(如长短时记忆网络,下文简称 LSTM)则擅长处理时间序列数据,适用于分析多点监测设备的时序信号,揭示结构状态的动态变化。对于需要综合分析空间和时间特征的复杂任务,可以选择混合架构,如结合 CNN 和 LSTM 的模型,以充分挖掘多维数据的信息。Transformer 模型作为一种新兴架构,因其全局感知能力和高效的注意力机制,正在逐渐成为处理 SHM 大规模数据的潜力工具。在模型选择过程中,需要充分考虑数据的特性、计算资源的限制和任务的复杂程度,以确保模型的适用性与高效性。

(二)超参数优化

超参数优化是通过调整模型的学习率、批量大小、网络深度等关键参数,可以改善训练效果。学习率的选择直接影响模型的收敛速度与稳定性,较高的学习率可能导致训练过程不稳定,而较低的学习率则会延长收敛时间。通过动态调整学习率或采用学习率调度器,可以在不同训练阶段实现学习率的自适应优化。批量大小的设置同样影响模型的训练效率和泛化能力,较小的批量可以捕捉数据细节,但会增加训练时间;而较大的批量则有助于提升训练速度,但可能导致模型陷入局部最优。正则化参数的优化在防止过拟合方面具有重要作用,如通过调整 L1 或 L2 正则化系数控制模型复杂度。在实践中,可以结合网格搜索、随机搜索或贝叶斯优化等方法,系统探索最优超参数组合,从而实现性能的最大化。

(三)训练策略

迁移学习是一种有效的手段,使用在大规模数据集上预训练的模型作为初始参数,可以大幅减少对标注数据的需求,并加快训练速度。在 SHM 中,迁移学习特别适用于具有类似特征分布的任务,如从航空结构监测转移到桥梁结构监测。数据并行策略则通过将训练任务分散到多块 GPU 或分布式计算集群中,实现大规模数据的高效处理。在实际操作中,结合分布式数据并行和梯度同步技术,可以确保训练过程的收敛性与一致性。为了避免训练过程中的梯度消失或爆炸问题,还可引入梯度裁剪等技术。另外,在训练后期采用早停策略,通过监控验证集的性能变化,动态终止

训练以防止过拟合,确保模型的实际应用效果达到最佳水平。

Q 损伤检测与定位

(一)分类任务

分类任务在 SHM 中是基础环节,其目标是利用深度学习模型对结构状态进行精确分类,判断结构是否存在损伤。分类模型通过对监测数据的分析,将结构状态划分为正常和异常两种情况,或者进一步细分为轻微损伤、中度损伤和严重损伤等多个等级。CNN 因其在图像和信号处理中的强大表现,广泛应用于这一任务中。通过对频谱图或应力分布图的卷积操作,模型能够从局部细节中提取对损伤敏感的特征。为了提升分类性能,可以在模型中引入注意力机制,使其关注更关键的特征区域。在训练过程中,利用不平衡数据处理策略如样本加权和过采样,模型能够更有效地处理少量损伤样本的问题。

(二)回归任务

在完成损伤检测后,回归任务的重点在于预测损伤的程度或具体位置,实现对结构状态的精确量化。通过深度学习模型对连续变量的回归分析,可以为工程维护提供更具指导性的决策支持。以桥梁健康监测为例,模型可以预测裂缝的宽度或钢筋的腐蚀深度,为维修工作优先级排序提供依据。CNN 与 LSTM 地结合在回归任务中表现出色,CNN 负责提取空间特征,而 LSTM 擅长捕捉时间序列数据的动态变化。结合位置信息的损失函数设计(如加权均方误差)能够进一步提升定位的精度。

(三)多任务学习

多任务学习是一种通过整合多个相关任务的模型训练方法,能够提升模型的综合能力和资源利用效率,同时减少独立训练多个模型带来的冗余计算和时间成本。在 SHM 领域,多任务学习具有广泛的应用潜力。它不仅可以同时实现损伤分类和损伤定位,还能够进一步扩展至预测损伤的发展趋势,为结构安全评估和维护提供更加全面和高效的技术支持。相比传统的单任务学习方法,多任务学习通过任务间的协同优化,充分挖掘了任务之间的潜在关联性,显著提升了模型的泛化能力和预测精度。

多任务学习的核心在于共享深度学习模型的部分特征提取层。让多个任务共享底层网络的特征表示,可以有效减少冗余计算,同时增强不同任务之间的特征关联性。例如,在 SHM 的应用中,可以构建一个统一的深度学习框架,将损伤分类任务与损伤定位任务整合在一起。在这种框架中,模型的底层网络用于提取通用的特征表示,而顶层的任务专用网络则分别优化分类和定位任务的目标函数。具体来说,分类任务通常使用交叉熵损失函数来优化模型的

分类准确率,而定位任务则采用均方误差损失函数来最小化预测位置与真实位置之间的误差。除了提升性能外,多任务学习的另一个优势在于对稀缺数据的高效利用。在 SHM 实际场景中,某些任务(如损伤分类)可能有较为丰富的标注数据,而其他任务(如损伤定位或趋势预测)则可能面临数据不足的问题。多任务学习通过共享任务信息,能够在一定程度上弥补因单一任务数据量不足而带来的局限性。

性能评估与挑战

(一)评估指标

在 SHM 中,全面评估深度学习模型的性能是确保其可靠性的关键。准确率作为基本指标,衡量了模型对整体样本分类的正确程度,适用于数据分布较为均衡的场景。而召回率则反映了模型在检测损伤样本时的敏感性,尤其在损伤样本数量较少的情况下具有重要意义。为了兼顾准确率和召回率,F1 值通过其调和平均提供了综合性能的评价方法,能够更好地衡量模型在损伤检测任务中的均衡能力。特异性和 ROC-AUC 曲线等指标被引入,用以评估模型区分正常样本与异常样本的能力。在应用场景中,这些指标的选择和组合应依据具体需求进行调整,以突出模型在关键任务中的表现。

(二)模型鲁棒性

深度学习模型的鲁棒性在复杂条件下的表现直接影响其在 SHM 中的应用效果。在噪声干扰的情况下,监测数据可能出现频谱失真或波形异常,对模型的特征提取能力形成挑战。通过在训练阶段引入高斯噪声数据增强或采用对抗训练策略,可以提高模型在噪声环境下的稳定性。缺失数据是另一个常见问题,传感器故障或数据传输不完整可能导致输入信息的不完整性。为应对此类问题,可以结合数据插值方法或采用鲁棒性更强的 CNN 结构,通过空间上下文信息填补数据空白。对多源异构数据的融合场景,模型需要在面对数据尺度差异和非对齐信息时表现出足够的适应能力。

(三)实际应用挑战

目前,深度学习模型面临多重挑战,包括可行性、实时性和可解释性等问题。一方面,实际环境中的数据采集往往受限于传感器部署密度和信号传输条件,这对模型的输入质量提出了更高要求;另一方面,实时性是确保结构监测系统及时响应的关键,深度学习模型在推理阶段的计算效率直

接决定了其能否满足工程需求。通过模型量化或蒸馏技术,可以有效压缩模型规模,提高实时推理速度。可解释性问题限制了深度学习模型在高风险场景中的应用,工程师难以直观理解模型的预测依据。为此,可以引入可视化技术(如类激活图)或注意力机制,揭示模型对特征的关注区域,增强模型输出的可解释性。针对这些实际应用挑战,需要持续优化模型架构和部署方案,以确保深度学习技术能够在复杂多变的工程环境中高效可靠运行。

结束语

本文对深度学习在 SHM 中的应用进行了系统研究,重点分析了数据处理、模型构建、损伤检测和性能评估四个方面。结果表明,深度学习在自动特征提取和数据增强方面展现了显著优势,能够有效提高监测数据的质量与多样性。在模型构建中,通过优化网络架构与训练策略,显著提升了模型的检测效率与精度。在损伤检测任务中,深度学习模型能够兼顾分类与定位的多任务需求,为复杂结构的健康状态提供了更为全面的诊断手段。在性能评估方面,通过对模型可靠性和泛化能力的深入分析,进一步验证了深度学习技术的实际应用潜力。尽管在理论研究和技术开发中取得了较大的进展,实际工程中的数据采集不完善和模型解释能力不足仍然是主要瓶颈。为更好地推动深度学习在 SHM 领域的实践应用,应集中研究数据融合、多任务协同优化及模型轻量化等问题。同时,加强深度学习模型的解释性研究,构建具有工程适应性的智能监测系统,这对提升 SHM 的效率和精度具有重要意义。

参考文献

- [1]胡玉柳.基于模型与数据驱动的结构健康监测异常检测[J].公路,2023,68(03):278-281.
- [2]陈旺桥.基于深度迁移学习的结构损伤检测研究[D].重庆:重庆交通大学,2022.
- [3]吴迪.基于深度学习的结构健康监测异常数据识别方法研究[J].智能城市,2020,6(20):10-13.
- [4]陈亚州.基于无线传感器网络的大跨度钢结构建筑健康监测系统设计及应用[D].西安:西安建筑科技大学,2021.

作者简介:

蔡晓宏(1972—),男,汉族,安徽合肥人,本科,高级工程师,厦门合立道工程设计集团股份有限公司合肥分公司,研究方向:建筑结构。