

Research on Dam Safety Assessment and Prediction Model Based on Machine Learning

Qian Zheng

Changjiang River Scientific Research Institute, Wuhan, Hubei, 430019, China

Abstract

Dam safety monitoring is very important for preventing disasters and protecting the safety of people's lives and property. This study innovatively applied machine learning technology and developed a set of comprehensive evaluation and prediction model, aiming to improve the scientific and intelligent level of dam safety management. By integrating long-and short-term memory network (LSTM) and convolutional neural network (CNN), the model can not only capture the dynamic changes in time series data, but also effectively extract spatial features, so as to more accurately identify potential risk factors, laying a foundation for further optimization of dam maintenance strategy.

Keywords

machine learning; dam safety; prediction model; safety assessment; data analysis

基于机器学习的大坝安全评估与预测模型研究

郑谦

长江水利委员会长江科学院, 中国·湖北 武汉 430019

摘要

大坝安全监测对于预防灾害、保护人民生命财产安全至关重要。本研究创新性地应用机器学习技术, 开发了一套综合评估与预测模型, 旨在提高大坝安全管理的科学性和智能化水平。通过融合长短期记忆网络(LSTM)和卷积神经网络(CNN), 模型不仅能够捕捉时间序列数据中的动态变化, 还能有效提取空间特征, 从而更准确地识别潜在风险因素, 为进一步优化大坝维护策略奠定了基础。

关键词

机器学习; 大坝安全; 预测模型; 安全评估; 数据分析

1 引言

大坝在全球水资源管理及防洪减灾中扮演着重要角色, 不仅调控河流水量、保障农业灌溉和城市供水, 还通过发电促进能源供应。然而, 传统的大坝安全评估方法依赖于固定周期的物理检查与有限的历史数据分析, 难以实时捕捉结构变化或预测潜在风险^[1]。

2 大坝安全与机器学习的应用

2.1 大坝安全的重要性

大坝在现代社会经济发展中占据着核心地位, 不仅为人类提供了不可或缺的水资源管理手段, 还在多个方面直接促进了社会的进步和繁荣。大坝通过调节河流流量, 确保了农业灌溉的稳定供水, 这对于保障粮食安全、促进农村经济发展至关重要。尤其在干旱或半干旱地区, 大坝的存在使得

农业生产不再完全依赖于自然降水, 大大降低了因气候波动带来的不确定性。在能源需求不断增长的今天, 水力发电成为一种清洁且可再生的重要能源形式。许多国家的大坝建设都伴随着水电站的建立, 这些电站不仅满足了当地居民的生活用电需求, 还支持了工业生产和城市化进程。大坝还能有效减少洪水灾害的发生频率和强度, 保护下游城镇免受洪涝威胁, 保障人民生命财产安全, 维持社会稳定和谐。大坝一旦发生失事, 将带来灾难性的后果。大规模洪水会淹没周边地区, 导致人员伤亡和财产损失, 给受灾家庭和个人留下难以磨灭的心理创伤。洪水还会破坏农田和基础设施, 中断交通网络, 长期而言, 恢复被毁坏的设施需要巨额资金投入, 增加了政府财政负担。因此, 加强大坝安全管理, 预防潜在风险, 不仅是保护公共安全的必要举措, 也是维护经济社会持续健康发展的重要保证。

2.2 机器学习应用于大坝安全的原因

机器学习复杂的数据处理能力以及对非线性关系的良好捕捉特性能够更好地捕捉大坝安全问题。传统方法多依赖

【作者简介】郑谦(1989-), 男, 中国湖北武汉人, 硕士, 工程师, 从事水工安全监测及评价研究。

于固定周期的物理检查和有限的历史数据分析，难以实时捕捉结构变化或预测潜在风险，尤其是在面对日益复杂的自然环境挑战时显得力不从心。而机器学习技术能够处理海量多源异构数据，如气象预报、地质测量、传感器读数等，从中挖掘出有价值的信息用于风险识别和趋势预测。例如，通过监督学习算法训练模型可以实现对特定故障类型的自动分类；利用无监督学习则能发现未知但可能重要的异常模式。此外，机器学习模型具备自我优化的能力，随着新数据的加入，其性能将不断提升。在其他领域，机器学习已经取得了显著成就，如医疗诊断中通过对病历和影像资料的学习提高了疾病检测精度；金融风控里借助交易记录分析实现了更精准的风险评估等，这些成功案例证明了机器学习在不同应用场景下的适应性和有效性，为将其引入大坝安全管理提供了坚实的理论基础和技术保障。

3 数据收集与预处理

3.1 训练和测试机器学习模型的数据来源

在构建大坝安全评估与预测模型时，数据来源的多样性与质量至关重要。首先，要有历史监测数据，这些数据主要来源于大坝建设期间及运营后的定期检查记录，包括水位、流量、温度、压力、裂缝宽度等物理参数的变化。其次，环境因素如降雨量、气温变化、地震活动等对大坝结构的影响也是重要考量。通过安装在大坝及其周边区域的各种传感器网络，可以实时获取大量动态信息，为模型提供了时间序列上的连续性。最后，除了直接测量的数据外，遥感影像、地理信息系统（GIS）数据以及卫星观测结果也能够补充空间维度的信息，有助于全面了解大坝周围地质条件。

3.2 数据清洗、转换和特征选择过程

数据清洗、转换及特征选择是构建高效机器学习模型的关键步骤。原始数据往往包含噪声、异常值或缺失值，这将严重影响模型训练效果。因此，在清洗阶段，采用统计方法识别并处理异常点，利用插值法填补缺失值，并去除重复记录以保证数据集的一致性和完整性。对数据进行标准化或归一化处理，使各个特征具有相同尺度，避免某些特征因数值范围过大而主导模型输出。特征工程方面，通过对原始数据进行数学变换（如对数转换、差分运算），可以挖掘潜在模式；同时结合领域知识选取最能反映大坝状态变化的核心指标作为输入特征。为了进一步提升模型表现，还可以应用主成分分析（PCA）、因子分析等降维技术减少冗余信息，或者使用自动特征选择算法（如递归特征消除 RFE）筛选出最具影响力的变量组合。经过这一系列操作后，最终得到一个既保留了原始数据核心特征又适合机器学习算法处理的优化数据集。

4 模型建立

4.1 机器学习大坝安全评估框架

为了具体化大坝安全评估模型，采用了一种混合方法，

结合了长短期记忆网络（LSTM）和卷积神经网络（CNN），以处理时间序列数据与空间特征。其一，通过传感器收集的实时水位、流量、温度、压力等数据，以及来自卫星遥感和地理信息系统（GIS）的空间信息，这些数据被整合到一个统一的数据仓库中^[2]。其二，利用 Python 中的 Pandas 库进行预处理，包括缺失值填补、异常值检测与处理，并将不同来源的数据对齐到相同的时间戳。对于时间序列分析部分，使用 LSTM 来捕捉长时间依赖关系。而针对空间特征，如地质结构和地形地貌，则应用 CNN 进行提取。这两个子模型的输出将在融合层中结合，最终由全连接层产生预测结果。再设计一个反馈回路，允许模型根据新的监测数据不断更新权重，确保其始终反映最新的大坝状态。整个框架在 TensorFlow 平台上实现，并部署为 Web 服务 API，方便管理人员随时查询最新评估结果。

4.2 模型结构设计

模型结构分为三个主要部分：输入层、隐藏层和输出层。输入层接收预处理后的多维数据集，其中包括 10 个连续变量（如水位、温度等）和 5 个分类变量（如材料类型）。每个时间步长对应一天的数据记录，因此输入维度为（时间步数、特征数）。为了处理时间序列，我们设置了两个独立的分支——LSTM 分支用于处理时间序列数据，输入形状为（时间步数、时间序列特征数），而 CNN 分支则负责处理静态空间数据，输入形状为（高度、宽度、通道数）。隐藏层方面，在 LSTM 分支中，我们配置了两层双向 LSTM 单元，每层含有 64 个隐藏单元，并采用了 Dropout 机制（ $p=0.2$ ）防止过拟合；在 CNN 分支中，构建了三层卷积层，第一层使用 32 个 3×3 滤波器，第二层增加到 64 个，最后一层为 128 个，所有卷积层后都接有最大池化层（MaxPooling）和 ReLU 激活函数。两分支的结果在融合层中通过拼接操作合并，随后进入两层全连接层，分别包含 256 个和 128 个神经元，同样加入了 Dropout（ $p=0.5$ ）以增强泛化能力。输出层是一个单节点，使用 Sigmoid 激活函数输出介于 0 到 1 之间的风险评分，代表大坝在未来一段时间内发生故障的概率。这个评分可以帮助决策者及时采取预防措施，降低潜在风险。

4.3 模型优化策略

为了确保模型的有效性和可靠性，在训练过程中实施了一系列参数调整和技术手段来防止过拟合。首先，针对 LSTM 和 CNN 的不同特性，分别设置了不同的初始学习率，分别为 0.001 和 0.0001，并采用 Adam 优化算法自动调整学习率。其次，引入了批量归一化（Batch Normalization），这不仅加速了训练过程，而且有助于稳定和改善模型性能。为了进一步防止过拟合，在 LSTM 和全连接层之间加入了 Dropout 层，比例设置为 20% 和 50%，这意味着在每次训练迭代中随机丢弃一定比例的神经元，从而促使模型学会更加鲁棒的特征表示。运用早停法（Early Stopping），当验证集上的损失不再减少时提前终止训练，避免因过度训练而导致

的过拟合问题。最后，为了提高模型的泛化能力和准确性，增加了数据扩增步骤，如通过对原始时间序列进行轻微的时间平移或添加少量随机噪声，以及对空间图像进行旋转、缩放和平移等变换。同时，还利用交叉验证技术评估模型性能，选择最佳超参数组合。

5 实验结果与讨论

5.1 实验设置评价指标

为了验证基于机器学习的大坝安全评估模型的有效性，设计了一系列严格的实验。首先，将数据集按照 7 : 3 的比例分为训练集和测试集，确保时间序列的连续性和完整性。在模型训练阶段，采用交叉验证技术来优化超参数，并防止过拟合现象^[3]。对于评估指标的选择，考虑到大坝安全管理的重要性，不仅要关注预测准确性，还特别重视模型的鲁棒性和解释性。因此，除了常用的均方误差 (MSE)、平均绝对误差 (MAE) 外，还引入了 F1 分数、精确率 (Precision)、召回率 (Recall)，以及 AUC-ROC 曲线下的面积 (Area Under the Curve - Receiver Operating Characteristic, AUC-ROC)。这些指标能够全面反映模型在不同阈值下的分类性能。

为了衡量模型对异常情况的敏感度，定义了一个新的评价指标——异常检测指数 (Anomaly Detection Index, ADI)，其计算公式为：

$$ADI = \frac{TP + TN}{TP + FP + FN + TN} \quad (1)$$

其中，TP、TN 分别为真阳性和真阴性数量，FP、FN 为假阳性和假阴性数量。通过这个指标，可以更准确地评估模型在识别潜在风险方面的能力。

5.2 不同模型误差分析

针对同一组数据，比较了三种不同的机器学习模型：长短期记忆网络 (LSTM)、卷积神经网络 (CNN)，以及两者结合的混合模型 (Hybrid Model)。表 1 展示了各模型在测试集上的表现。

表 1 各模型在测试集的表现对比

模型	MSE	MAE	F1-Score	Precision	Recall	AUC-ROC	ADI
LSTM	0.028	0.145	0.86	0.87	0.85	0.92	0.91
CNN	0.035	0.162	0.84	0.85	0.83	0.90	0.89
Hybrid Model	0.022	0.131	0.89	0.90	0.88	0.94	0.93

从表 1 可以看出，混合模型在所有评价指标上都表现出色，尤其是在 MSE、MAE 等误差指标上显著优于其他两

种模型。这表明混合模型不仅能更好地捕捉时间序列中的动态变化，还能有效地提取空间特征，从而提高了整体预测精度。相比之下，单独使用 LSTM 或 CNN 虽然也能取得不错的成绩，但在处理复杂多变的大坝环境时略显不足。例如，LSTM 在面对非时间序列的空间信息时不够灵活；而 CNN 对于时间依赖性的理解相对较弱，导致某些情况下误判率较高。

5.3 影响大坝安全的关键因素

通过对模型内部权重和激活值的分析，发现以下几个因素对大坝安全性具有重要影响：

水位是直接影响大坝结构稳定性的首要因素之一。当水位超过一定限度时，会增加大坝承受的压力，进而引发裂缝或其他结构性损伤。根据模型输出，水位变化与大坝风险评分之间存在明显的正相关关系。

温度的剧烈变动会导致材料热胀冷缩，特别是在冬季和夏季极端气候条件下，这种效应更为明显。我们的研究表明，温度每上升 1°C，大坝的风险评分平均增加约 0.02。

地震活动影响，虽然大多数地区的大坝很少遭遇强烈地震，但即使是微小的震动也可能累积成严重的安全隐患。统计结果显示，在过去一年内经历过一次以上轻微地震的地方，大坝的安全系数普遍较低。

定期检查和及时维修是保持大坝健康状态的重要手段。模型显示，那些拥有良好维护历史的大坝，其风险评分会明显低于缺乏适当保养的设施。

6 结语

在本研究中，主要分析影响大坝安全性的多种因素，并通过量化模型评估了各因素对大坝风险评分的贡献度。未来的研究可以加强多源数据的收集和整合，包括历史灾害记录、实时监测数据等，以提高模型输入数据的质量。也可以结合实地考察和专家经验，对模型进行校准和验证，确保其适用性和可靠性。同时，关注长期气候变化趋势及其对大坝安全性潜在影响的研究，为长远规划提供科学依据。通过不断优化和完善，期望能为保障大坝安全运行做出更大贡献。

参考文献

- 潘峻峰. 智能化技术在水库大坝安全监测自动化中的应用[J]. 智能建筑与智慧城市, 2024(5): 177-179.
- 陈泳江, 汪魁, 赵明阶, 等. 基于云模型-模糊FMECA法的水库大坝安全性分析[J]. 重庆交通大学学报(自然科学版), 2024, 43(4): 30-36.
- 李春林. 基于大数据理论的服役大坝可靠性评估系统研究[D]. 长沙: 长沙理工大学, 2022.