

基于深度学习的堆石料级配智能识别与压实质量预测模型

任俊

中国水利水电第十二工程局有限公司, 浙江 杭州 310030

[摘要]堆石料级配以及压实质量是决定高堆石坝填筑施工安全及长期变形稳定的最重要因素, 在西南最大的坝高为 303m, 总填筑量约为 $4.315 \times 10^6 \text{m}^3$ 的某大型水电站砾石土心墙堆石坝建设过程中为解决传统的级配检测方法及其压实质量评判滞后、代表性差的问题而建立基于深度学习算法下的堆石料级配智能辨识及压实质量预测模型。利用施工现场拍摄照片以及 SAM 图像分割功能建立堆石料粒径智能识别模型, 并能对颗粒进行分割处理并得到相应的特征值以及计算出其相应级别的级配比例。然后, 利用混合级配特性、碾压参数和施工环境等多个来源的数据建立一种以改进型的卷积神经网络 (CNN) 加长短时记忆网络 (LSTM) 为基础的压实质量预测模型; 最后用实测值来校核这两种模型。

[关键词]堆石坝; 深度学习; 级配识别; 压实质量; 智能建造

DOI: 10.33142/hst.v9i3.19331

中图分类号: TV641.4

文献标识码: A

Intelligent Recognition of Grading and Compaction Quality Prediction Model for Rockfill Materials Based on Deep Learning

REN Jun

Sinohydro Bureau 12 Co., Ltd., Hangzhou, Zhejiang, 310030, China

Abstract: The grading and compaction quality of rock fill materials are the most important factors determining the safety and long-term deformation stability of high rock fill dam construction. In the construction process of a large hydropower station gravel soil core wall rock fill dam with a maximum dam height of 303 meters and a total filling amount of about $4.315 \times 10^6 \text{m}^3$ in southwest China, a deep learning algorithm based intelligent identification and compaction quality prediction model for rock fill material grading was established to solve the problems of lagging and poor representativeness of traditional grading detection methods and compaction quality evaluation. Establish an intelligent recognition model for the particle size of rockfill materials using photos taken at the construction site and SAM image segmentation function, and be able to segment and process the particles to obtain corresponding feature values and calculate their corresponding grading ratios. Then, a compaction quality prediction model based on an improved convolutional neural network (CNN) and an extended short-term memory network (LSTM) is established using data from multiple sources such as mixed grading characteristics, compaction parameters, and construction environment; Finally, use the measured values to verify these two models.

Keywords: rock fill dam; deep learning; grading identification; compaction quality; intelligent construction

引言

近年来, 随着深度学习技术的发展给堆石坝工程建设质量管控带来了新的解决思路, 鲁洋等人利用 SAM 图像方法对堆石料颗粒分析进行了实验, 并证明采用图像分割法进行级配检验具有一定的实用性, 王放等人提出了一种针对堆石料级配识别的考虑堆叠遮挡情况下的视觉智能推理方法, 并建立起了相应的视觉轮廓感知模型, 用于恢复被遮挡住石子的部分轮廓信息^[1]。对于压实过程的质量监测, 张庆龙等人由于土石坝压实过程中出现的数据滞后以及缺乏大量样本

的问题, 从而设计出了一个二进制多群体遗传算法改进 BP 神经网络作为实时性的压实质量评价体系等。在智能施工上, 西南某大水电站是我国第一座运用“施工全过程智能化技术”, 修建起一座 300m 级超高的土石坝, 在世界上首次实现无人驾驶碾压以及整个大坝施工全过程的智能监测, 为今后深度学习技术应用于类似的工程项目提供了良好的先例。

1 堆石料压实质量智能监控研究现状

1.1 传统压实质量检测方法

传统对堆石坝体压实质量进行检验的方法主要包括

挖坑灌水法、沉降量法以及压实计法等方式。挖坑灌水法是在现场进行开挖试坑然后计算其体积和重量得出干密度值，是现行规范所采用的标准检验方法之一，但是操作复杂、耗时较长并且受抽检的数量限制不能全面体现出整个作业面上的压实状况。而沉降量法则通过对碾压前后的填筑层厚度变化来评价压实效果，虽然简单但其精确度会受到摊铺厚度的影响。压实计法则基于振动碾激振系统中的振动响应参数以表征压实情况，可以做到实时监测但是无法得出干密度这样的具体数值。以上方法都存在时效性差、覆盖面小、人为因素干扰大的共同缺点，在对高堆石坝大范围连续施工的质量管理方面难以满足要求。

1.2 基于机器视觉的压实状态识别技术

随着人工智能算法的发展，计算机视觉技术也有了很大的发展，基于图像分析的堆石料压实状态判定也有了一定的研究成果。王放等人提出了具有堆叠遮挡处理能力的堆石料级配视觉智能推理框架，建立了自然状态下堆积的状态下石料颗粒视觉轮廓感知模型，重建了被相邻颗粒遮挡的石子轮廓并提取特征参数，在压实质量评定上，武汉大学的研究小组提出一种结合影像及电磁波检测法的“表面级配+深部压实度”的堆体压实质量评判方案，集成了GNSS 以及工业摄像机、探地雷达与运载平台研制出一套完整的智能检测设备。

1.3 深度学习在岩土工程中的应用

深度学习的应用已从图像分割、目标检测扩展到了参数估计及状态评价等领域。对于堆石料级配分析方面，张振伟等人使用 SAM (Segment Anything Model) 巨模型进行堆石料图像分割及级配参数估算的研究工作证明了巨模型适用于复杂堆石图像分析中；郇宝乾等人提出一种基于 TAUNet 分割模型对爆堆块度的空间分布进行分析的方法，在卷积神经网络 UNet 基础上，把 Transformer 自注意力机制加入其中，得到了块体分割骰子系数为 97.12%。针对压实质量预测方面的问题，王海峰等人采用二进制多群体遗传算法与 BP 神经网络相结合的方法建立 BP 神经网络压实质量判别模型。结合认知不确定性和随机不确定性构造出损失函数，克服了小样本容量不足问题。这些研究成果给本文建立堆石料级配分析及压实质量预测模型提供了有力的支持与参考依据。

2 堆石料级配智能识别模型构建

2.1 现场图像采集与预处理

基于西南一个巨型水电站砾石土心墙堆石坝项目，在坝体堆石料填充地段设置固定的高清工业相机及移动式的图像获取装置^[2]。获取的方式如下：在坝体重要部位搭

建固定点，在每个堆石料堆置层完成后自动拍摄照片；另外在碾前碾后对料面进行拍照以做比较研究颗粒的粉碎和压实效果，每一幅图片都有定标尺便于像素到物理距离的换算。对原图进行了灰度化、直方图均衡化提高亮度、中值滤波去噪声以及使用 CLAHE 算法加强颗粒边界的信息。详细的过程示意图如图 1 所示：

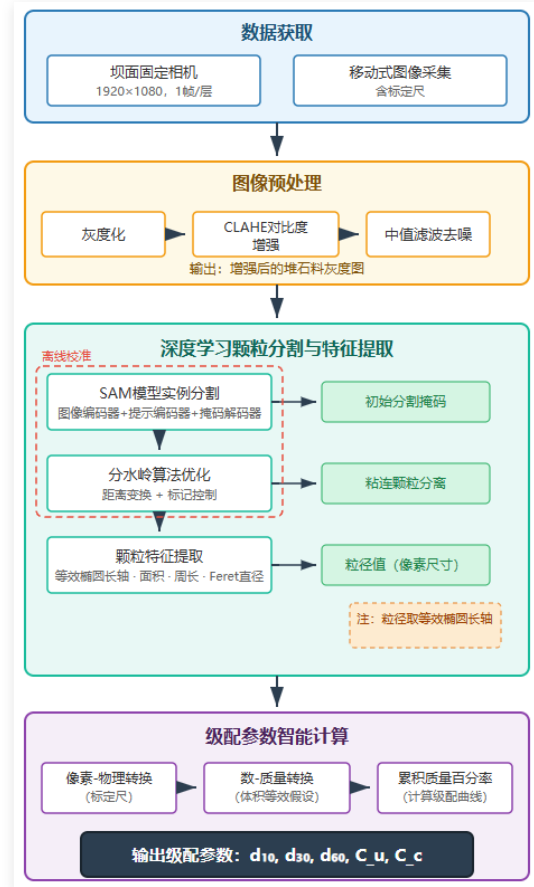


图 1 堆石料级配智能识别模型技术路线图

2.2 基于深度学习的颗粒分割与特征提取

使用改进的 SAM 大型模型来对待处理的堆石料图像进行实例分割，SAM 模型包含图像编码器、提示编码器以及掩码解码器三层结构，可以做到在不用额外训练的情况下完成零样本分割；针对堆石料颗粒间粘接较为紧密的情况，在 SAM 分割的基础上结合分水岭算法进行后期处理改进，运用了距离变换和标记法把粘连在一起的颗粒分开；分割完之后从每颗颗粒中抽取如下一些几何特征指标：等效椭圆长短轴、周长、面积、Feret 直径、最小外接矩形边长，取等效椭圆形的最长轴来代表颗粒粒度大小，用标定尺在图上的像素到实际长度的比例关系把像素长度转换成真实的粒径，如图 2 所示。




图2 SAM模型颗粒分割效果对比

2.3 级配参数智能计算模型

由所抽取的各种颗粒粒径数值来求得比某粒径小的颗粒的质量累计百分比。由于图像处理只可得到二维面上的粒径大小，利用体积等效的思想把二维的粒径转化为三维的粒径分布，再由数-质量转换模型将颗粒数量分布转变为质量分布。把所有的颗粒从小到大依次排列起来，进行逐次累加和得出小于某种粒径的质量累计百分比。级配指标有特征粒径 d_{10} 、 d_{30} 、 d_{60} 以及不均匀系数 C_u 与曲率系数 C_c ，计算公式为：

$$C_u = d_{60}/d_{10}, \quad C_c = (d_{30})^2 / (d_{10} \times d_{60}) \quad (1)$$

本研究可以完成单张图像层面配参任务并及时给后文的压实质量预测模型以动态输入。

3 堆石料压实质量预测模型构建

3.1 压实质量影响因素分析

堆石料压实质量的高低是由料源性因素、施工工艺的因素以及环境因素共同决定的。料源性的因素主要是指堆石料的粒径分布特性、颗粒形态、母岩岩性和含水率等方面；关于级配不良的堆石料，在相同碾压功的条件下其干密度可以减少5%~8%，而当不均匀系数 C_u 小于5时，则会使压实效果明显变差。施工工艺因素主要包括碾压设备种类及其吨位大小、碾压速率、碾压遍数、铺层厚度以及振动强度、频率、振幅大小等^[3]。而碾压速率与压实程度之间不是线性关系，速率过高会造成振动能量传递不足的问题，速率过低会使得施工效率降低；环境因素主要有环境温度、湿度以及坝体表面高程的不同部位差异等。利用工程位于高寒地带，极低气温达到-15.9℃，冬季施工过程中堆石料表面存在冰膜产生“坚硬外壳现象”，使得对压实结果造成更大的影响，在此基础上选择级配指标(d_{10} 、 d_{60} 、 C_u 等)以及碾压速率、碾压次数、层厚、振幅、环境温度作为压实质量预测模型的输入特征变量，并以压实干密度为预测输出变量。

3.2 多源数据融合与特征工程

大数据来源有粒度识别模型得到的粒度指标、智能压实设备采集到的摊铺施工参数还有现场环境监测的数据，

在此基础上研发智能化大坝在线监测平台，其定位误差小于1cm，可以对碾压机行驶路径、速度、碾压次数、压实层厚等相关信息进行即时运算分析。对于遗漏信息通过均值填充，利用Z-Score统计量寻找并剔除异常点，用min-max规范化方法把每个属性映射到[0,1]之间。在特征构建上创建碾压动能 $E=F \times v \times n \times h$ 等综合特性。

表1 模型输入特征变量统计表

特征变量	符号	单位	取值范围
特征粒径 d_{10}	d_{10}	mm	1.2~5.6
特征粒径 d_{60}	d_{60}	mm	45.3~128.7
不均匀系数	C_u	-	8.2~42.5
碾压速度	v	km/h	1.5~3.8
碾压遍数	n	遍	4~10
铺层厚度	h	cm	60~100
振动频率	f	Hz	26~32
环境温度	T	℃	-12.5~28.0

3.3 深度学习预测模型结构设计

建立CNN-LSTM混合预测模型，通过CNN获取来自多种数据的不同变量间的局部相关性，而用LSTM获得压实强度随着时间及位置上的变化的序列依存特性。其网络结构如下：由输入层、卷积层、池化层、LSTM层以及全连接输出层构成。输入层输入的是融合起来的特征向量，经历两次卷积层后得到特征表示，再经过一次最大池化降维到LSTM中去。其LSTM包含64个隐含节点，用来观察碾压过程中的质量发展脉络。输出层是一个神经元，输出所预测的压实干密度值。引入Dropout防止过学习。




图3 CNN-LSTM压实质量预测模型网络结构图

3.4 模型训练与优化方法

数据集依照7:2:1进行分成了训练集、验证集以及测试集。选择均方误差(MSE)作为损失函数，它的公式是：

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

其中，N是样本数量， y_i 是第i个样本的压实干密度实际值， \hat{y}_i 是模型预测值。Adam优化器对参数进行迭代更新，初始学习率为0.001，一阶矩估计指数衰减率为

$\beta_1=0.9$, 二阶矩估计指数衰减率为 $\beta_2=0.999$ 。使用早停法监测验证集损失, 当连续 10 个 epoch 无降临时停止训练以防止过拟合。批次大小设为 32, 最大训练轮数为 200。

超参选择使用了贝叶斯搜索, 搜索空间定义为: 卷积核数量[16,32,64,128], LSTM 隐藏单元数[32,64,128,256], Dropout 率[0.2,0.3,0.4,0.5], 学习率[0.0001,0.0005,0.001,0.005], 寻优目标是验证集中均方根误差最小化, 在进行了 50 轮寻优之后得到了最优秀的超参数组合: 卷积核数量, 第一层 32、第二层 64、LSTM 隐藏单元数 64、Dropout 率 0.3、学习率 0.001。模型训练中, 训练集损失从 0.025 逐渐降到约 0.008, 而验证集损失在最初的 50 个 epoch 急剧减少, 后缓慢降低, 没有过拟合现象, 模型训练结束后存入最优权重参数用以对测试集中进行预测。

4 模型验证与应用分析

4.1 试验设计及数据获取

基于西南某巨型水力发电站堆石料碾压施工, 共收集堆石料坝面照片 2000 余张, 涵盖堆石区与过渡区不同高程以及不同时期。与此同时开展现场挖坑蓄水实验 150 个组, 得到压实干密度实测值。同时从中提取相应的碾压参数信息, 如碾压速率、碾压遍数、铺砂厚度、振幅、环境温度等, 建立包含 1500 个样本的压实质量数据集。

4.2 级配识别模型精度验证

比较级配识别模型计算值与实测现场筛析结果之间的准确性, 表 2 给出了不同尺寸特征值以及不均匀系数的标准偏差结果。粒径 d_{60} 的相对绝对误差是 7.2%, d_{30} 相对绝对误差为 6.8%, d_{10} 相对绝对误差为 8.4%, 不均匀系数 C_u 的相对绝对误差为 9.1%, 如图 4 所示。误差主要产生自颗粒堆积遮挡造成的分割缺失, 以及二维图像对三维粒度分布无法准确表达还有些小颗粒无法检测出来等问题。总的来说建立起来的级配识别模型适用于工程现场的及时测量。

表 2 堆石料级配识别模型粒径检测误差统计

参数	平均相对误差 (%)	最大相对误差 (%)	标准差 (%)
d_{10}	8.4	14.2	3.1
d_{30}	6.8	12.5	2.7
d_{60}	7.2	13.8	2.9
C_u	9.1	16.5	3.8
C_c	8.2	15.0	3.3




图 4 级配识别模型预测粒径与筛分实测值对比散点图

4.3 压实质量预测模型性能评估

CNN-LSTM 模型在测试集上得到的判定系数 R 值是 0.936, 均方根误差 (RMSE) 为 0.031g/cm^3 , 平均绝对百分比误差 (MAPE) 为 2.14%, 表 3 比较了几种不同的模型对预测的效果, 消融实验得出级配参数增加约提高 R^2 0.043 左右, CNN 特征提取层增加 R 约为 0.027; 如图 5 所示。模型对于堆石区的预测效果好于过渡区, 在温度相对合适的季节的预测准确性好于冬季低温期。

表 3 不同压实质量预测模型性能对比

模型	R^2	RMSE (g/cm^3)	MAPE (%)	训练时间 (s)
BP 神经网络	0.873	0.052	3.85	45
LSTM	0.904	0.041	2.96	128
CNN-LSTM (本文)	0.936	0.031	2.14	186




图 5 不同模型压实干密度预测值与实测值对比

4.4 模型工程适用性分析

两种模型均能够达到工程实际需求的时效性能要求: 单张图片级别配比辨识耗时约为 3.5s, 压实成果单一位置推算耗时小于 0.1s。模型对于不同料源适用度的研究显示, 在堆石料料源母岩种类有所变更的情况下, 准确率有轻微降低^[4]。建议在工程现场建立模型自动更新制度, 使用新获得的施工信息使模型进行增量或者定期回炉式更新。两种模型可以很好地融入智能大坝在线监测平台, 实现级配识别-压实参数调整-压实质量评估-碾压过程反演等的智能化闭环循环。

5 结束语

本文以西南地区某大型水电站砾石土心墙堆石坝为例,在此基础上建立了基于深度学习的堆石料级配自动识别模型以及压实质量预测模型,通过 SAM 图像分割及改进的颗粒特征获取方式所建立的级配识别模型可对堆石料颗粒进行有效自动识别并得到其粒径特征参数 d_{60} 平均相对误差为 7.2%, 满足工程现场即时检测要求; 结合级配指标、碾压工艺参数以及影响因素, 采用 CNN-LSTM 网络结构所建立的压实质量预测模型在测试样本上的 R 值是 0.936, RMSE=0.031g/cm³, 其预测效果好于 BP 网络和普通的 LSTM 模型。基于模型与智能大坝实时监测系统联合应用可以做到“级配判定-压实参数调整-压实效果预报-碾压过程反传”的智能化回路调节, 对于高堆石坝施工质量智能化控制具有一定的参考作用以及技术帮助。今后的研究可以从融合多种类型的数据来源、提高模型透明度以及应用跨工程转移

学习等方面进行进一步探讨。

[参考文献]

- [1]黄娟,吴世勇,刘辰耕,等.基于筑坝仓面图像特征的堆石料级配智能评判方法[J].水力发电,2025,51(8):77-83.
- [2]王放,赵春菊,喻葭临,等.考虑堆叠遮挡的堆石料级配视觉智能推理方法[J].水利学报,2025,56(10):1292-1303.
- [3]王仁超,连嘉欣,邱阔.结合深度学习和 NCFS 算法的堆石料粒度分布智能检测方法[J].水利学报,2021,052(9):1103-1115.
- [4]佟大威,孙楷翔,张君,等.堆石坝施工仿真参数 HHO-RDSOGM 在线更新模型研究[J].天津大学学报(自然科学与工程技术版),2025,58(12):1272-1287.

作者简介:任俊(1984年12—),男,毕业院校:中国石油大学,所学专业:安全工程,当前就职单位:中国水利水电第十二工程局有限公司,职务:施工管理部主任,职称级别:中级工程师。