

DOI: 10.20040/j.cnki.1000-7709.2023.20221152

# 基于深度学习的 SCC 工作性能预测技术

何世钦<sup>1</sup>,高鹏飞<sup>1</sup>,王纯月<sup>2</sup>,王 辉<sup>1</sup>

(1. 北方工业大学土木工程学院, 北京 100144; 2. 北京中拓新源科技有限公司研发部门, 北京 102206)

**摘要:** 基于深度学习技术研究了一种在自密实混凝土(SCC)出机前根据拌合物图像信息预测其工作性能的方法。录制了25组不同工作性能的SCC搅拌过程视频,按坍落扩展度、 $T_{500}$ 实测值并结合目测将其划分为合格、流动性不足及离析三种工作性能,通过将视频分帧处理为图像集,采用图像分类和目标检测两种方法建立深度学习模型,通过模型对拌和物图像特征的学习及训练,完成对SCC工作性能的预测。结果表明,图像分类和目标检测两种方法在验证集上均可达到98%以上的准确率,可为实时调整配合比进而实现SCC智能化提供参考。

**关键词:** 自密实混凝土;工作性能;深度学习;目标检测;图像分类

**中图分类号:** TV431<sup>+</sup>.9;TP391.9

**文献标志码:** A

**文章编号:** 1000-7709(2023)04-0155-04

## 1 引言

自密实混凝土(SCC)优良的工作性能是其在工程上表现良好的基础<sup>[1]</sup>。但目前对SCC工作性能的测试都是事后性的,不合格的只能被废弃。因此,在拌和过程提前预测拌和物的工作性能,并实时调整配合比可以节省材料,减少工作量,实现SCC制备质量的智能控制。已有研究利用计算机技术研究混凝土的拌和过程。如 DAUMANN B等<sup>[2]</sup>对骨料颗粒标注不同颜色,通过计算样本中各颜色颗粒含量的方差衡量搅拌均匀程度;JAIME J M等<sup>[3]</sup>利用图像分析监控拌和过程,即利用拌和物图像的纹理变化反映拌和程度;李书阳等<sup>[4]</sup>利用Vuforia开发包,通过预置标识图像的空间位置坐标计算扩展度,但需要人为选定边界点;LIU Y等<sup>[5]</sup>利用深度学习预测不同拌和条件下SCC的扩展度及V漏斗时间,但需要对每张图像进行预处理,且模型在V漏斗时间的预测上准确度较低。相关混凝土拌和过程研究均是提取拌和物的图像特征,图像处理技术则依靠人为选取特定场景下的图像特征。深度学习技术可以自动进行特征学习,更能挖掘图像原始数据。因此,本文将SCC拌和物划分为三种工作性能,选

取不同的深度学习模型进行训练,通过对不同工作性能拌和物图像特征的学习,建立图像信息与工作性能之间的联系,实现对SCC工作性能的预测。

## 2 SCC工作性能划分

SCC工作性能检测常采用坍落扩展度试验、V型漏斗试验和U型箱试验等方法,根据相应指标划分性能等级<sup>[6]</sup>。其中坍落扩展度试验和V漏斗试验(或 $T_{500}$ )可以评价SCC的流动性与抗离析性,是简便易行的检测方法。对搅拌机中SCC拌和物性能进行预测时,根据拌和后试验指标及人为观测将其工作性能划分为3种:①合格。满足坍落扩展度及 $T_{500}$ 指标;②流动性不足。坍落扩展度小于550 mm;③离析。目测骨料与浆体发生分离。三种工作性能及对应搅拌机内拌和物图像特征见图1。由图1可看出,流动性不足的SCC拌和物图像中颗粒感较强,而离析的SCC拌和物图像中颗粒感最弱,但图像特征差异细小。利用深度学习技术捕捉图像特征差异,可以在拌和完成前预测SCC工作性能。

## 3 拌合试验与图像采集

**收稿日期:** 2022-05-30, **修回日期:** 2022-06-28

**基金项目:** 河北省重点研发计划项目(19217617D)

**作者简介:** 何世钦(1969-),女,博士、副教授、硕导,研究方向为高性能混凝土材料及混凝土结构耐久性,E-mail:hes-hiqin@ncut.edu.cn




图 1 SCC 拌和物的三种工作性能与对应的搅拌机内 SCC 拌和物图像

Fig. 1 Three performances of SCC mixes and corresponding images in mixer

### 3.1 试验概况

试验采用 HJW-60 型单卧轴式混凝土搅拌机,利用智能手机拍摄搅拌视频。智能手机固定在三角支架上,无需固定三脚架位置及拍摄角度,但应清晰拍摄到搅拌机内的拌和物。为保证拍摄效果,应尽量在室外或有光线照射进搅拌机内部的条件下进行拍摄。

共进行了 25 组 SCC 拌和试验,以水粉比和减水剂掺量为变量,水粉比参数分别为 1.0、1.05、1.10、1.15、1.17、1.175、1.19、1.195、1.20;减水剂掺量分别为 0.80%、0.85%、0.875%、0.90%、0.95%、1.0%。其中水粉比是指水与粉体的体积比;减水剂掺量为减水剂与胶凝材料的质量比。每组拌和试验均拍摄搅拌视频并测试记录其扩展度  $S_{SF}$  和流动时间  $T_{500}$ ,具体的试验记录见表 1。其中 1.00+1.00% 代表水粉比为 1.00,减水剂掺量为 1.00% 的 SCC 拌和物组。

表 1 SCC 拌和物工作性能试验记录

Tab. 1 SCC mixes performances test record

序号	配合比	$S_{SF}/mm$	$T_{500}/s$	工作性能
1	1.00+1.00%	453		流动性不足
2	1.05+1.00%	455		流动性不足
3	1.10+0.80%	401		流动性不足
4	1.10+0.90%	557	10.39	合格
5	1.10+1.00%	583	10.87	合格
6	1.11+0.85%	552	10.71	合格
7	1.11+0.90%	693	3.06	合格
8	1.13+0.85%	617	8.21	合格
9	1.13+0.90%	689	6.29	合格
10	1.13+1.00%	69	6.28	合格
11	1.15+0.85%	604	6.60	合格
12	1.15+0.875%	688	7.49	离析
13	1.15+0.90%	658	4.27	合格
14	1.15+0.90%	400		流动性不足
15	1.15+0.95%	662	5.64	合格
16	1.15+1.00%	658	9.83	合格
17	1.17+0.85%	685	4.67	合格
18	1.17+0.90%	662	6.77	合格
19	1.175+0.85%	669	5.33	合格
20	1.19+0.85%	581	6.04	合格
21	1.19+0.90%	707	4.66	离析
22	1.195+0.90%	697	4.50	离析
23	1.20+0.80%	588	8.93	合格
24	1.20+0.90%	689	4.91	离析
25	1.20+1.00%	687	7.41	离析

### 3.2 图像采集

深度学习模型的输入是搅拌图像,故需将搅拌视频分帧为图像序列。已有研究表明<sup>[7]</sup>,对于每次搅拌过程,SCC 拌和物在最后 1 min 内会被搅拌均匀。在未搅拌均匀前,拌和物的物理状态和工作性能逐渐变化,故只将视频最后 40 s 搅拌均匀时的拌和物图像作为深度学习的训练数据。视频分帧处理时帧长设为 100 ms,则每组试验可以提供的图像张数  $k$  为:

$$k = (40 \times 1\,000) / 100 = 400 \quad (1)$$

根据试验记录统计不同工作性能的 SCC 所对应的组数及图像数,见表 2。

表 2 SCC 三种工作性能所对应的图像数

Tab. 2 The number of images corresponding to the three SCC performances

SCC 工作性能	组数	图像数/张
合格	16	6 400
流动性不足	4	1 600
离析	5	2 000

## 4 深度学习模型的建立

基于 Pytorch 框架,利用图像分类与目标检测两种方法分别建立深度学习模型,评价模型的预测能力。

(1) 基于图像分类任务的预测模型。图像分类是基于色彩、纹理等特征对图像进行区分。采用 AlexNet 模型进行 SCC 工作性能的三分类训练,其网络结构及训练参数量见表 3。

表 3 AlexNet 模型网络结构及训练参数量

Tab. 3 Network structure and training parameters

of AlexNet model		
网络层	输出尺寸	参数量
Conv2d-1	$[-1, 64, 55, 55]$	23 296
Relu-2	$[-1, 64, 55, 55]$	0
MaxPool2d-3	$[-1, 64, 27, 27]$	0
Conv2d-4	$[-1, 192, 27, 27]$	307 392
Relu-5	$[-1, 192, 27, 27]$	0
MaxPool2d-6	$[-1, 192, 13, 13]$	0
Conv2d-7	$[-1, 384, 13, 13]$	663 936
Relu-8	$[-1, 384, 13, 13]$	0
Conv2d-9	$[-1, 256, 13, 13]$	884 992
Relu-10	$[-1, 256, 13, 13]$	0
Conv2d-11	$[-1, 256, 13, 13]$	590 080
Relu-12	$[-1, 256, 13, 13]$	0
MaxPool2d-13	$[-1, 256, 6, 6]$	0
AdaptiveAvgPool2d-14	$[-1, 256, 6, 6]$	0
Dropout-15	$[-1, 9, 216]$	0
Linear-16	$[-1, 4, 096]$	37 752 832
Relu-17	$[-1, 4, 096]$	0
Dropout-18	$[-1, 4, 096]$	0
Linear-19	$[-1, 4, 096]$	16 781 342
Relu-20	$[-1, 4, 096]$	0
Linear-21	$[-1, 1, 000]$	409 700

为了更好地理解模型学习到的图像信息,利用可视化工具 tensorboard 输出搅拌图像的特征

图(图 2)。在模型训练前,需将图像数据对应的 SCC 工作性能作为样本的标签。为了方便模型进行迭代计算,使用数字标签 0、1、2 分别代表合格、流动性不足和离析。




图 2 图像特征

Fig. 2 Image feature

(2)基于目标检测任务的预测模型。目标检测更关注图像的特定区域,根据搅拌图像及其标签特点,任务可转化为检测流动性不足或离析的图像。常用的目标检测算法有 RCNN 系列、YOLO 系列,相比于 RCNN 模型,YOLO 模型无需提取候选区域<sup>[8]</sup>。速度快、模型小的 Yolov4 模型主干网络采用的是 Darknet-53,结构见图 3。

数量	网络层	过滤器尺寸	输出尺寸
2	Convolutional	3×3×32	256×256
1	Convolutional	3×3/2×64	128×128
1	Convolutional	1×1×32	128×128
	Convolutional	3×3×64	
	Residual		
1	Convolutional	3×3/2×128	64×64
2	Convolutional	1×1×64	64×64
	Convolutional	3×3×128	
	Residual		
1	Convolutional	3×3/2×256	32×32
8	Convolutional	1×1×128	32×32
	Convolutional	3×3×256	
	Residual		
1	Convolutional	3×3/2×512	16×16
8	Convolutional	1×1×256	16×16
	Convolutional	3×3×512	
	Residual		
1	Convolutional	3×3/2×1 024	8×8
4	Convolutional	1×1×512	8×8
	Convolutional	3×3×1 024	
	Residual		
1	Avgpool	Global	
1	Connected	1 000	

图 3 Darknet-53 网络结构

Fig. 3 Darknet-53 network structure

在模型训练前,先采用 labelImg 工具对数据进行标记,为减少搅拌机内壁、叶片及外界环境的干扰,只标记特定部分 SCC 拌合物的图像。为使目标检测模型有更好的鲁棒性,将 SCC 工作性能合格的图像划为负样本,将流动性不足或离析的图像划为正样本,因此可将目标检测任务看作一个二分类问题,使用数字标签 0、1 分别代表流动性不足和离析。

## 5 深度学习模型训练结果分析

### 5.1 数据集的划分

图像采集完成后,按照 8 : 1 : 1 的比例对 SCC 图像序列进行训练集、验证集及测试集的随机划分,见表 4。训练集给予模型数据,使模型进行初步学习;验证集初步评估模型能力,协助模型进行训练;测试集评估模型的泛化能力。

表 4 不同工作性能的 SCC 数据集划分

Tab. 4 Data set partitioning for different performances

SCC 工作性能	训练集/张	测试集/张	验证集/张
合格	5 120	640	640
流动性不足	1 280	160	160
离析	1 600	200	200

### 5.2 训练算法的设置

(1)损失函数。损失函数可以评价预测值与真实值的差异,通过最小化损失函数,可以使模型的预测能力更强。因此,选取合适的损失函数有利于模型训练。在图像分类任务中,多采用交叉熵损失函数(CrossEntropy),即:

$$C_{\text{CrossEntropy}} = - \sum_{i=1}^n p(x_i) \ln q(x_i) \quad (2)$$

式中,  $p(x)$  为真实概率分布;  $q(x)$  为预测概率分布。

在目标检测任务中,多采用 IOU 损失函数,即:

$$L_{\text{LossIOU}} = - \ln I_{\text{IOU}} \quad (3)$$

式中,  $I_{\text{IOU}}$  为交并比,代表预测框与标记框的交叠率。

(2)优化器。优化器的作用是在模型训练过程中不断调整更新参数,使损失函数最小。深度学习领域常选用梯度下降法为损失函数寻找最小解,即:

$$w = w - \alpha dy/dw \quad (4)$$

式中,  $\alpha$  为学习率,是一个常数,决定了梯度下降的快慢;  $dy/dw$  为  $w$  点的梯度。

### 5.3 训练结果分析

(1)图像分类法结果。采用交叉熵损失函数的下降曲线观察模型的训练过程(图 4)。曲线 1 代表模型在训练集的损失,衡量模型在训练集上的拟合能力;曲线 2 代表模型在验证集上的损失,衡量模型在新数据上的泛化能力。随着迭代次数




图 4 交叉熵损失函数下降曲线

Fig. 4 Cross-entropy loss function descent curve

的增加,模型的损失值呈下降趋势。

训练模型的迭代过程见表 5。经过 10 次迭代,模型在验证集上的准确率达到 100%。

表 5 训练模型的迭代过程

Tab. 5 Iterative process of training model

训练时间	迭代次数	损失	准确率/%
Training;Epoch[000/003]	[001/003]	0.708 2	51.56
Training;Epoch[000/003]	[002/003]	0.550 2	62.50
Training;Epoch[000/003]	[003/003]	0.458 9	66.67
Valid;Epoch[000/003]	[010/010]	0.295 5	100.00
Training;Epoch[001/003]	[001/003]	0.236 1	98.44
Training;Epoch[001/003]	[002/003]	0.249 8	98.44
Training;Epoch[001/003]	[003/003]	0.235 6	97.68
Valid;Epoch[001/003]	[010/010]	0.250 3	100.00
Training;Epoch[002/003]	[002/003]	0.206 9	98.44
Training;Epoch[002/003]	[002/003]	0.216 6	98.44
Training;Epoch[002/003]	[003/003]	0.227 3	98.26
Valid;Epoch[002/003]	[010/010]	0.246 2	100.00

(2)目标检测法结果。采用 IOU 损失函数的下降曲线观察模型的训练过程见图 5。其中曲线 A 为损失函数的下降曲线,曲线 B 为目标检测中独有的评价指标平均准确率,代表所有验证集准确率的平均值。模型在经过 10 000 次迭代后,其准确率可达到 99%。

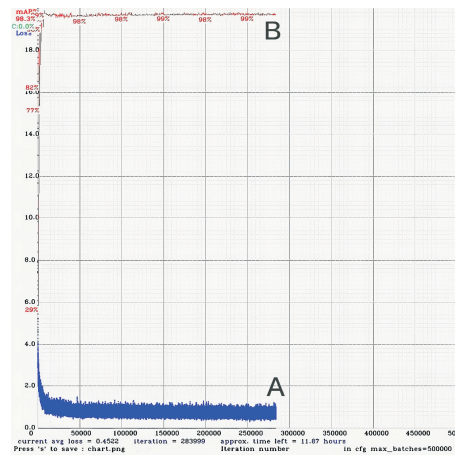


图 5 IOU 损失函数下降曲线与平均准确率曲线

Fig. 5 IOU loss function decline curve and MAP curve

## 6 结论

基于深度学习在 SCC 拌和阶段提前预测拌和物合格、流动性不足、离析三种工作性能,结果表明搅拌机内 SCC 拌和物图像信息完全包含了其工作性能信息;目标检测方法采用的 Yolov4 模型可通过较少的计算量达到 98%的准确率;SCC 流动特性及图像特征与搅拌机规格相关,研究结果移植到大型搅拌站需对图像集重新学习。

### 参考文献:

- [1] 王辉,马嘉均,吕森,等. 珠江三角洲水资源配置工程自密实混凝土配合比优化设计试验研究[J]. 水电能源科学,2021,39(4):125-128.
- [2] DAUMANN B,NIRSCHL H. Assessment of the mixing efficiency of solid mixtures by means of image analysis[J]. Powder technology,2008,182(3):415-423.
- [3] JUEZ J M,ARTONI R,CAZACLIU B. Monitoring of concrete mixing evolution using image analysis [J]. Powder technology,2017,305:477-487.
- [4] 李书阳,沈乔楠,安雪晖,等. 基于增强现实的混凝土坍落扩展度测量[J]. 清华大学学报(自然科学版),2012,52(6):809-813.
- [5] LIU Y,XUEHUI A. Estimating the workability of self-compacting concrete in different mixing conditions based on deep learning[J]. Computers an concrete,2020,25(5):433-445.
- [6] 张淑云,王恩,周杰,等. 骨料对自密实混凝土工作性能和力学性能的影响[J]. 中国科技论文,2022,17(4):437-443.
- [7] 丁仲聪,安雪晖. 基于双轴图像的自密实混凝土工作性能分析[J]. 清华大学学报(自然科学版),2018,58(11):979-985.
- [8] 岳明哲,陈旭东,李俊杰. 基于 CNN-LSTM 的混凝土坝渗流预测[J]. 水电能源科学,2020,38(9):75-78.

## SCC Performance Prediction Technology Based on Deep Learning

HE Shi-qin<sup>1</sup>,GAO Peng-fei<sup>1</sup>,WANG Chun-yue<sup>2</sup>,WANG Hui<sup>1</sup>

(1. School of Civil Engineering, North China University of Technology, Beijing 100144,China;

2. R & D Department, Beijing Zhongtuo Xinyuan Technology Co., Ltd., Beijing 102206,China)

**Abstract:** The deep learning technology was used to study a method of predicting the performance of SCC based on the mixture image information during the mixing process. Twenty-five sets of videos of the SCC mixing process with different performances were recorded. According to the slump flow and  $T_{500}$  measured values and combined with the visual inspection, the SCC mixes were classified into three performances: qualified, insufficient fluidity and segregation. By processing the videos into image sets, the deep learning models were built using image classification and target detection respectively. The models learn and train the image features of the mixes to realize the prediction of SCC performance. The results show that both image classification and target detection methods can achieve more than 98% accuracy on the validation set, which provides a reference for adjusting the mix proportion in real-time and realizing the smart production of SCC.

**Key words:** self-compacting concrete; performance; deep learning; target detection; image classification