

DOI:10.11784/tdxbz202502009

堆石坝施工仿真参数 HHO-RDSOGM 在线更新模型研究

佟大威, 孙楷翔, 张 君, 胡亦宁

(天津大学水利工程智能建设与运维全国重点实验室, 天津 300350)

摘要: 基于施工过程中产生的海量数据流驱动堆石坝施工仿真参数更新是确保施工仿真准确性的关键。现有仿真参数更新研究主要采用贝叶斯及其衍生方法, 难以准确模拟异常值多、多峰和时变的仿真参数, 存在数据量大时更新效率低的问题。针对上述问题, 提出基于实时感知数据流处理的堆石坝仿真参数哈里斯鹰优化算法-堆石坝自组织高斯方法(HHO-RDSOGM)在线更新模型。首先, 应用异常数据检测和处理方法提升数据质量。其次, 将实时获取的施工感知数据流建模为动态高斯成分构成的仿真参数分布, 通过类间节点插入和网络去噪的操作来动态地增添或者减少高斯成分的数量, 并通过节点更新权值的操作来实时地改变每个局部高斯成分中的参数来改变参数局部分布形态, 以实现仿真参数分布的实时更新, 其中采用 HHO 算法优化自组织增量学习神经网络的 C_1 和 C_2 等超参数, 以提升参数更新精度。案例分析表明: HHO-RDSOGM 方法相较于 KDE、GMM、Dirichlet、oKDE 和 RDSOGM 等方法, 能够实现复杂施工环境下仿真参数自组织在线学习, 方法精度平均分别提高了 30.71%、31.87%、18.91%、11.50%和 8.34%, 表明方法的有效性。

关键词: 堆石坝仿真; 仿真参数在线更新; 异常值检测与处理; 优化算法

中图分类号: TV512

文献标志码: A

文章编号: 0493-2137(2025)12-1272-16

Study on HHO-RDSOGM Online Updating Model of Rockfill Dam Construction Simulation Parameters

Tong Dawei, Sun Kaixiang, Zhang Jun, Hu Yining

(State Key Laboratory of Hydraulic Engineering Intelligent Construction and Operation, Tianjin University, Tianjin 300350, China)

Abstract: Driving the update of rockfill dam construction simulation parameters based on the massive data stream generated during the construction process is a key to ensuring the accuracy of construction simulation. The existing researches on simulation parameter update mainly use Bayesian and its derivative methods, which are difficult to accurately simulate the simulation parameters with many outliers, multiple peaks and time-varying characteristics, and there is a problem of low update efficiency when the data volume is large. In view of the above problems, a Harris hawk optimization algorithm-rockfill dam self-organized Gaussian model (HHO-RDSOGM) online updating model of rockfill dam simulation parameters based on real-time perception data stream processing is proposed. First, the abnormal data detection and processing methods are applied to improve the data quality. Second, the construction perception data stream obtained in real time is modeled as a simulation parameter distribution composed of dynamic Gaussian components, the number of Gaussian components is dynamically increased or reduced through the operations of inter-class node insertion and network denoising, and the parameters in each local Gaussian component are changed in real time through the operation of node update weights to change the local distribution of parameters, so as to realize the real-time update of simulation parameter distribution. Specifically, the HHO algorithm is used to

收稿日期: 2025-02-12; 修回日期: 2025-06-24.

作者简介: 佟大威(1982—), 男, 博士, 副教授, tongdw@tju.edu.cn.

通信作者: 张 君, zhangdajun@tju.edu.cn.

基金项目: 国家自然科学基金青年科学基金资助项目(52309165).

Supported by the Youth Science Fund Project of the National Natural Science Foundation of China (No. 52309165).

optimize the hyperparameters such as C_1 and C_2 of the self-organized incremental learning neural network, thus improving the parameter update accuracy. Case analysis shows that the HHO-RDSOGM method can realize self-organized online learning of simulation parameters in complex construction environments compared with methods such as KDE, GMM, Dirichlet, oKDE and RDSOGM. The average accuracy of the proposed method is improved by 30.71%, 31.87%, 18.91%, 11.50% and 8.34%, respectively, indicating its effectiveness.

Keywords: rockfill dam simulation; online update of simulation parameters; outlier detection and processing; optimization algorithm

堆石坝施工过程受到众多动态因素干扰和多种施工条件约束,存在强烈不确定性与随机性,常与既定施工组织进度安排存在较大偏差.如何有效地从现有堆石坝施工过程产生的数据流中感知提取出施工仿真信息,进而指导堆石坝施工组织进度安排,是堆石坝施工仿真领域的难题.在智能时代与大坝智能建设的背景下^[1-4],钟登华等^[5-7]把系统仿真、可视化、实时监控和增强现实等技术引入水利工程施工仿真中,进行了高堆石坝施工仿真与优化研究,提出了基于实时监控的高堆石坝施工进度影响因素实时分析方法和基于增强现实的心墙堆石坝施工过程可视化仿真方法.王佳俊^[8]基于心墙堆石坝智能感知、智能分析与智能控制等,研发了心墙堆石坝坝面碾压施工智能监控系统.

施工现场所感知的数据能否反映实际特征以及其数量的多寡将直接影响仿真参数分布建模和更新的有效性.施工过程中复杂环境条件影响会造成异常值的出现,降低感知数据的质量.异常值的存在不仅会影响感知数据的质量,而且也会影响堆石坝施工仿真模型的精度. Shao 等^[9]基于高斯模糊和 Otsu 二值化识别,使用布谷鸟搜索算法彻底检测出异常值,为大坝安全监测领域提供了新方法.郑磊等^[10]基于孤立森林算法,提出了1种高拱坝施工期变形异常值检测模型,应用工程实际对比验证异常值检测的有效性.张瑜等^[11]基于平滑阈值和孤立森林算法,提出了1种大坝监测数据异常检测方法.叶斌^[12]以某高拱坝的实际监测数据为样本,利用 LSTM 模型对监测数据进行异常值检测. Song 等^[13]基于多变量面板数据和 K 均值聚类理论,建立了大坝变形数据异常值监测分析方法. Rong 等^[14]提出了1种结合改进 LOF 和考虑时空相关性的多点异常值检测模型,结合工程实际验证了其精度和鲁棒性.乔天诚等^[15]基于 Kmeans-EMD 算法,实现了对异常值的定性和精细定量检测,提高了碾压速度数据的完整性与可靠性. Li 等^[16]基于异常值检测中的距离思想,结合重力坝变形规律,提出了多重局部异常数据方法.

许多学者使用施工现场感知数据对大坝施工进

行仿真建模.张隽等^[17-18]进行考虑降雨影响的高心墙堆石坝施工进度仿真研究,提出了基于贝叶斯场论的仓面碾压仿真参数分布建模方法,通过采用标量场定义仿真参数的先验分布.吕菲^[19]开展了基于机器学习的高心墙堆石坝开挖-运输-填筑全过程施工仿真与施工方案优化研究.张君等^[20-21]提出了考虑高寒低温影响的高心墙堆石坝仓面施工仿真模型和基于数据驱动的堆石坝施工阶段及区域优化模型,推进了堆石坝施工仿真研究.

大坝施工仿真参数模型更新的研究方兴未艾.张念木^[22]提出了基于施工实时监控系统的面板堆石坝施工动态仿真模型,实现了对施工组织进度安排的动态仿真和预测.钟登华等^[23]提出了以 CATIA 为基础的堆石坝施工动态仿真构架,实现了堆石坝施工过程的三维模型的快速修改更新.张元坤^[24]构建了碾压混凝土仓面施工过程的精细化仿真模型,通过分析实时监控数据实时更新仿真参数,提高了仿真的实时性.钟登华等^[25]把耦合改进重抽样和贝叶斯方法应用到高拱坝施工参数更新里,提升了数据样本集的代表性. Wang 等^[26]以动态感知获取到的施工和气象数据,利用贝叶斯方法来对碾压混凝土坝的施工仿真参数进行更新. Guan 等^[27]把模糊理论和贝叶斯更新相结合,用施工现场的实时感知数据来进行高拱坝施工仿真参数更新.王国浩等^[28]提出了高拱坝施工仿真参数 EMD-P-ILSTM 动态更新模型,用于更新具有时序非线性特性的缆机单循环运行时间参数.张君^[29]采用基于非参数在线核密度估计的施工仿真参数分布实时更新方法,进行高心墙堆石坝仿真参数的生成和更新.

基于监控系统采集数据进行施工仿真参数建模及更新的大部分研究采用指定形式的贝叶斯方法来对施工仿真参数分布进行更新,需要提前假设施工参数的分布形式,如高斯分布、泊松分布等.然而,大坝施工过程受多种因素复杂影响,假设大坝施工参数的分布类型服从高斯分布、泊松分布等经典分布会导致其取值范围远远偏离实际施工过程产生的真实数据.一些研究采用了非参数统计推断,但其仍存在需

要依靠人工经验来手动设置超参数的问题,而且其计算效率低、实时性差,不能很好地应用于堆石坝施工仿真参数分布在线建模及实时更新.

堆石坝施工现场海量的实时感知数据流呈现出异常值多、多峰和时变等特点,难以进行准确的密度估计. 具体而言,施工感知数据因为现场人员、环境和系统等因素导致数据流中存在离群点、突变点、极不合理数据等异常值,因此进行仿真参数分布建模更新时需要先行清洗数据以排除上述因素影响. 仿真参数的分布形态体现出明显的多峰,这是由于现场设备不同的工作场景和施工要求不同的工作状态导致的. 多峰性要求密度估计的方法能够精准地拟合实际数据流情况以更好地输入到仿真模型数据中,进而获得更精细精准的仿真结果. 时变性不仅要求密度估计的方法要拟合准确,同时也要求其随着时间变化而变化,体现出增量性. 现有仿真参数更新的方法多是以全局更新而存在,难以体现短时间内小样本的变化,这也同样是仿真参数更新效率低的原因. 面对实时传输而来的数据,频繁的全局更新表现出效率不足.

如何快速准确地更新仿真参数,同时在保留过去已拟合的分布和增添将来未拟合的分布之间保持平

衡,对于堆石坝施工期实时仿真结果具有重要意义.

针对上述异常值多、多峰和时变等特点,本文提出了 1 种实时感知数据流处理的堆石坝施工仿真参数哈里斯鹰优化算法-堆石坝自组织高斯方法(Harris hawk optimization algorithm-rockfill dam self-organized Gaussian model, HHO-RDSOGM)在线更新模型,开展了不同方法的对比,证实了所用算法原理的效率与精度,为堆石坝施工仿真参数更新提供了有效方法.

1 研究框架

基于 HHO-RDSOGM 的堆石坝施工仿真参数在线更新模型的研究框架如图 1 所示,研究内容主要包括:堆石坝施工实时数据流的获取,异常值的检测和处理;堆石坝施工仿真参数 HHO-RDSOGM 在线更新模型进行仿真参数分布建模及更新,哈里斯鹰优化算法对 T_i 、 C_1 和 C_2 等超参数进行寻优;模型在线输出仿真参数分布状态,并将其输入仿真模型,获得仿真结果;对比分析,使用直方图、KDE、GMM、Dirichlet、oKDE 等基准方法建模并与 HHO-RDSOGM 比较精度.

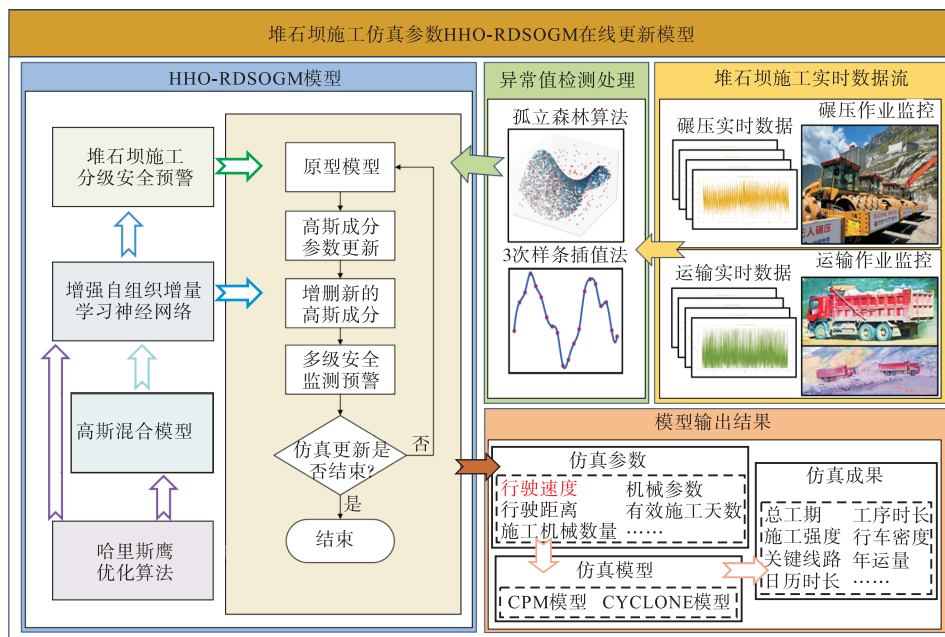


图 1 研究框架

Fig.1 Research framework

2 实时数据流处理的堆石坝施工仿真参数 HHO-RDSOGM 在线更新模型

2.1 实时数据流的获取和处理

堆石坝施工仿真实时数据流对仿真参数在线更

新的精准度和可信度有着直接的影响,是堆石坝动态仿真系统的重要环节. 受高心墙堆石坝施工现场环境的复杂因素影响,实时监控系统中获取的实时数据流需要进行异常值的检测和处理,以便于后续的仿真参数分布在线更新.

仓面碾压仿真参数和坝料运输仿真参数是堆石

坝施工动态仿真模型的重要输入仿真参数^[30-31]. 关于仓面碾压仿真参数, 选用碾压机行驶速度作为代表性参数; 关于坝料运输仿真参数, 选用运输车行驶速度作为代表性参数. 研究数据来源依托天津大学水利工程智能建设与运维全国重点实验室自主研发的堆石坝施工实时监控系系统^[32]来采集施工建设期间产生的施工仿真实时数据流. 实时监控系统中的GNSS-RTK 高精度位姿感知模块^[33]可以实现对仓面碾压机和坝料运输车位置的实时自动监控记录, 以固定时间间隔采集仓面碾压机和坝料运输车的动态物理坐标. 根据两个相邻采样时刻点的碾压位置或运输位置来获取碾压机瞬时行进速度或坝料运输车行驶速度的样本数据集, 同时通过坝上搭建设立的通信网络将数据传输并存储至业主营地的数据库, 如图 2 所示. 从数据库中提取数据获取实时数据流, 采用孤立森林 (isolation forest, IF) 算法^[34]和 3 次样条插值法^[35]对其进行处理.



图 2 堆石坝施工实时监控系系统

Fig.2 Real-time monitoring system of rockfill dam construction

IF 算法是 1 种基于树结构的无监督异常检测方法, 其核心思想在于通过随机划分特征空间来“孤立”数据点. 相较于正常样本, 异常样本在数据分布中往往更加稀疏, 更容易被隔离. 在构建孤立树过程中, 每次对某个特征维度 x_j , 在其取值范围 $[x_j^{\min}, x_j^{\max}]$ 内随机选取一个切分值 $q \in [x_j^{\min}, x_j^{\max}]$, 并将数据划分为左、右子树, 不断递归直到当前节点只包含一个样本或达到最大树深.

孤立森林由多棵独立的孤立树组成, 其总体检测得分依赖于样本在各棵树中的平均路径长度. 具体而言, 对于样本 x , 其平均路径长度定义为

$$E(h(x)) = \frac{1}{t} \sum_{i=1}^t h_i(x) \quad (1)$$

式中: $h_i(x)$ 为样本 x 在第 i 棵树中的路径长度; t 为森林中树的总数. 为标准化不同样本的路径长度, 定义异常分数函数为

$$s(x, n) = 2 \frac{E(h(x))}{c(n)} \quad (2)$$

式中 $c(n)$ 是样本数为 n 的数据集在完全随机切分下的平均路径长度的期望, 可近似表示为

$$c(n) = 2H(n-1) - \frac{2(n-1)}{n} \quad (3)$$

式中 $H(i)$ 是第 i 项调和数, 并且满足 $H(i) = \ln i + \gamma$, γ 为欧拉常数.

当 $s(x) \rightarrow 1$ 时, 说明样本 x 可能为异常点; 当 $s(x) \rightarrow 0$ 时, 说明其可能为正常点.

3 次样条插值是 1 种常用的平滑插值方法, 目标是在 1 组已知数据 $(x_0, y_0), (x_1, y_1), \dots, (x_n, y_n)$ 之间构造 1 组分段 3 次多项式函数 $S_i(x)$, 使其整体光滑连续. 在每个子区间 $x \in [x_i, x_{i+1}]$ 上定义 1 个 3 次多项式为

$$S_i(x) = a_i + b_i(x - x_i) + c_i(x - x_i)^2 + d_i(x - x_i)^3 \quad (4)$$

为保证整体函数的光滑性和插值精度, 需满足以下条件.

插值条件可表示为

$$S_i(x_i) = y_i, S_i(x_{i+1}) = y_{i+1} \quad (5)$$

1 阶导数连续性条件可表示为

$$S_i'(x_{i+1}) = S_{(i+1)}'(x_{i+1}) \quad (6)$$

2 阶导数连续性条件可表示为

$$S_i''(x_{i+1}) = S_{(i+1)}''(x_{i+1}) \quad (7)$$

自然边界条件可表示为

$$S''(x_0) = 0, S''(x_n) = 0 \quad (8)$$

通过上述条件, 3 次样条插值可构造线性方程组求解所有未知系数 a_i 、 b_i 、 c_i 和 d_i , 保证插值具有良好的数值稳定性和平滑特性. 当 $i=1$, 仅满足式 (5) 和 (8) 即可.

2.2 堆石坝施工仿真参数 HHO-RDSOGM 在线更新模型

2.2.1 RDSOGM

堆石坝施工仿真日新月异的发展要求仿真参数分布实现在线更新. ESOINN^[36-37]是 1 种增量式自组织的竞争学习神经网络. 相较于 LSTM、RNN 和 CNN 等常见模型, ESOINN 具备增量学习的机制, 能够在不依赖历史数据重训的情况下动态更新其结构以适应新样本分布, 这种特性使得其适合堆石坝施工现场实时感知流的流式数据环境. 同时, ESOINN 的自组织特性能够根据数据分布的复杂性自适应调整其神经拓扑结构. 在训练过程中, 其会自动根据输入样本的相似性与密度特征添加或删除神经元节点及其连接关系, 从而形成反映原始数据拓扑特征的拓扑结构. 这一机制无需预先定义网络的规模参数, 显著减少了模型超参数选择, 提升了对数据的建模和更新能力. 此外, 与依赖梯度反向传播机制的深度神经网络不同, ESOINN 的训练过程不涉及复杂的参数优化

过程,而是基于样本之间的距离与节点连接关系进行局部更新,显著降低了计算资源消耗与时间开销,其核心步骤有分布神经元、动态调整、表示拓扑结构、网络去噪和分离聚类重叠区域等。

原型分布是以在线学习的方式,用具有代表性的原型来拟合代表原始输入的样本集,然后把这些原型表示为分布神经元。原型分布示意过程见图 3(a)。

神经元动态调整是 ESOINN 实现在线更新学习的关键,它使神经元自身空间参数和神经元之间的联系能够随着数据输入而动态变化和自组织学习。其动态调整分为类间节点插入和节点权值更新两个部分。动态调整中定义了 1 个名为类间节点插入的概念,其含义为:当新输入数据所形成的原型与已经形成的学习成果之间的差异达到一定程度时,就在该原型所在的空间位置上生成 1 个新的神经元节点。为了反映这个差异程度,为第 i 个神经元引入了 1 个相似度阈值的属性参数 T_i 。当新数据点 ξ 被输入时,会首先判断出其距离最近的两个神经元 s_1 和 s_2 ,若 $d(s_1, \xi) > T_{s_1}$ 或 $d(s_2, \xi) > T_{s_2}$, 则判定其差异过大,然后生成新的神经元节点,否则将不会生成。此处 $d(\cdot)$ 为马氏距离函数。类间节点插入示意过程见图 3(b)。

ESOINN 的神经元节点更新权值的条件为新的数据样本不满足类间节点插入,此时会更新神经元节点 s_1 和 s_2 的属性参数权值,其计算式分别为

$$\begin{aligned} w_{s_1, \text{new}} &= w_{s_1} + \varepsilon(t)(\xi - w_{s_1}) \\ w_{s_2, \text{new}} &= w_{s_2} + \varepsilon'(t)(\xi - w_{s_2}) \end{aligned} \quad (9)$$

式中: w_{s_1} 和 w_{s_2} 分别为更新前 s_1 和 s_2 的属性参数权值; $w_{s_1, \text{new}}$ 和 $w_{s_2, \text{new}}$ 分别为更新后 s_1 和 s_2 的属性参数权值; $\varepsilon(t) = \frac{1}{t}$; $\varepsilon'(t) = \frac{1}{100t}$ 。事实上,神经元权值更新调整过程就是传统意义上的矢量量化过程,其中的示意过程见图 3(c)。

在神经元节点完成动态调整后,ESOINN 会建立神经元节点之间的连接,最终形成节点集在空间中的三角拓扑结构。其示意过程如图 3(d) 所示。

ESOINN 会将那些参与更新过程次数较少的神经元作为噪声进行遗忘,即每更新 C_2 个数据就删除参与次数小于 C_1 的神经元。神经元节点的删除操作使得可以在大数据高噪声的数据集中仍然保持鲁棒性。通过设置的超参数的 C_1 和 C_2 来控制神经元节点遗忘的频率,来使其适应不同的输入环境。为了更好地显示出聚类效果,ESOINN 还会周期性地监测各类别间的重叠区域,并且删除该区域的节点和边来达到凸显其聚类效果的目的。

ESOINN 具有在线增量学习的特点,但为了更好地将其适用于堆石坝施工仿真参数分布研究,还需要对其进行改进。高斯混合模型(Gaussian mixture model, GMM)^[38]是 1 种典型的对样本数据进行密度估计的概率模型。1 个高斯分布只能估计简单的概率密度函数,拟合较为理想情况下的数据样本。相比之下,使用多个形状参数独立的高斯分布则可估计更为复杂的概率密度函数,拟合更加真实情况下的数据样本,在理论上可以估计出任意情况的概率密度分布状态。

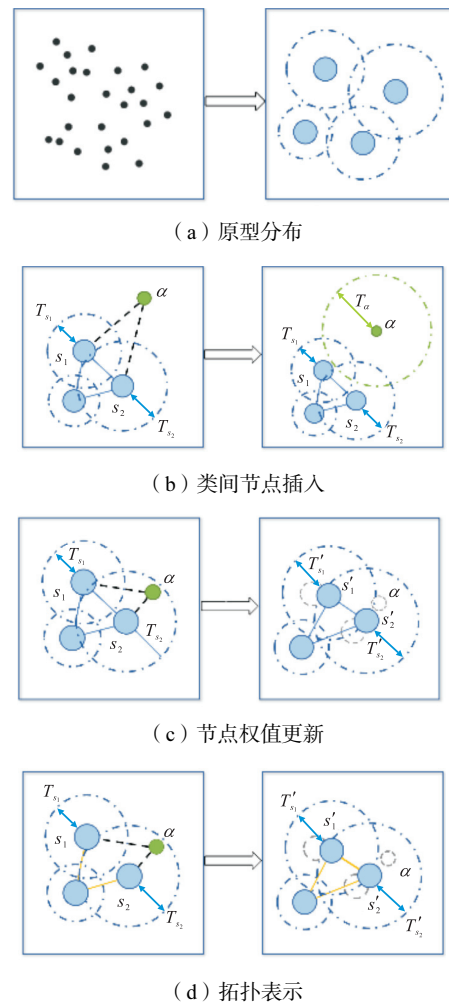


图 3 ESOINN 原理示意

Fig.3 Schematic of ESOINN principle

以下为 1 个多元高斯分布(也即多元高斯成分)的概率密度估计函数的定义。假设有 1 个 n 维的数据集,其中有一任意向量 x ,如果向量 x 服从多元高斯分布,则该向量 x 的概率密度估计函数为

$$p(x) = \frac{1}{(2\pi)^{\frac{n}{2}} |\Sigma|^{\frac{1}{2}}} \exp\left(-\frac{1}{2}(x - \mu)^T \Sigma^{-1}(x - \mu)\right) \quad (10)$$

式中: μ 为 n 维的均值向量; Σ 为 1 个 n 维的协方差

矩阵. 二者可合计为 $\phi(\mathbf{x}|\boldsymbol{\mu}, \boldsymbol{\Sigma})$. 当存在多个多元高斯成分时, 它们彼此独立又相互叠加, 其组成的凸函数即被定义为高斯混合分布.

高斯混合分布的概率密度估计函数为

$$p_M(\mathbf{x}) = \sum_{i=1}^k \alpha_i \phi(\mathbf{x}|\boldsymbol{\mu}_i, \boldsymbol{\Sigma}_i) \quad (11)$$

式中: k 为高斯混合成分的数量; $\boldsymbol{\mu}_i$ 为第 i 个高斯成分的均值向量; $\boldsymbol{\Sigma}_i$ 为第 i 个高斯成分的协方差矩阵; α_i 为第 i 个高斯成分的权重, 其满足当 $\alpha_i > 0$ 时 $\sum_i \alpha_i = 1$.

为满足堆石坝施工仿真参数在线更新需求, 在 ESOINN 基础上进行改进, 引入堆石坝施工组织规范, 使用原型分布、动态调整和网络去噪等神经网络框架, 移除拓扑结构生成和聚类重叠区域删除等操作, 结合高斯混合模型, 提出了 RDSOGM.

由于方法中各高斯成分并无实际工程含义, 可解释性不高, 因此有必要引入堆石坝施工组织规范来更好地指导堆石坝施工仿真参数更新. 根据中国西南某心墙堆石坝施工组织设计, 以 10 个采样点为 1 个批次举例, 当碾压机的运行速度处于 [2.2 km/h, 2.8 km/h] 时, 为正常状态; 当新增均值大于 2.8 km/h 或小于 2.2 km/h 的高斯成分时, 会向指挥中心监控人员发出 3 级报警信息; 当 60 个批次内超过 2 次出现 3 级警报时, 会向现场监理人员发出 2 级警报; 当 360 个批次内超过 2 次出现 2 级警报时, 会向建设管理单位人员发出 1 级警报. 类似地, 当运输车的运行速度小于 40 km/h 时, 为正常状态; 当新增均值大于 40 km/h 的高斯成分时, 会向指挥中心监控人员发出 3 级报警信息; 当 60 个批次内超过 2 次出现 3 级警报时, 会向现场监理人员发出 2 级警报; 当 360 个批次内超过 2 次出现 2 级警报时, 会向建设管理单位人员发出 1 级警报.

基于 ESOINN, 堆石坝施工仿真参数中如碾压机瞬时行进速度和坝料运输车运输速度输入后得到的原型节点产生的联系进而形成的拓扑结构并无实际意义, 因此为了更好地适应并提高堆石坝仿真参数更新的速度, 把拓扑结构这部分操作进行移除. 同样地, ESOINN 所删去的聚类重叠区域较大的部分会使聚类效果更好, 但会影响堆石坝仿真参数的分布, 因此把聚类重叠区域的操作移除以更加真实地实现仿真参数实时更新.

RDSOGM 通过类间节点插入和网络去噪的操作来动态地增添或者减少高斯成分的数量, 通过节点更新权值的操作来实时地改变每个局部高斯成分中的

参数来改变参数局部分布形态, 进而改变其对整体和局部数据样本的学习效果.

2.2.2 HHO-RDSOGM 模型

RDSOGM 可以实现自组织在线学习, 但仍存在的超参数如神经元遗忘所需要的 C_1 和 C_2 参数等需要手动输入和设置. HHO 算法^[39]是 1 种基于生物优化的启发式算法, 其模拟了鹰群觅食行为时鹰之间的协作和竞争关系, 用于解决优化问题. 鹰群觅食时, 协作的一方会向其他鹰提供搜索方向和信息, 而竞争的一方则根据自身的经验选择更好的搜索路径, 这种协作与竞争的机制能够使整个鹰群更快地找到食物. 图 4 为 HHO 算法示意.

HHO 算法首先设定鹰的数量(种群规模), 确定搜索空间的边界, 并设置最大迭代次数. 初始化时, 随机生成每只鹰的位置和速度. 随后, 算法根据当前位置和速度更新鹰的位置, 并根据一定规则调整速度. 然后, 更新最佳解, 通过比较当前的位置和速度的适应度值来更新最佳解.

在每次迭代中, 根据一定概率选择协作鹰和竞争鹰, 协作鹰和竞争鹰分工协作. 重复上述步骤, 直到达到最大迭代次数, 输出最佳解.

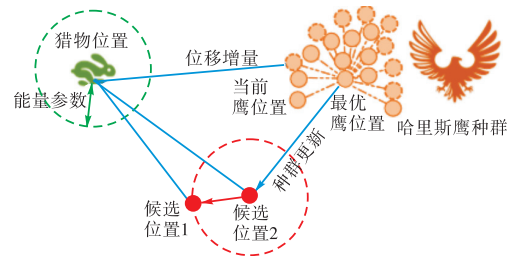


图 4 哈里斯鹰优化算法示意

Fig.4 Schematic of HHO algorithm

HHO 算法通过模拟鹰群觅食行为中的协作和竞争关系, 实现了高效的优化搜索. 基于 HHO 算法优化 RDSOGM 中的超参数, 提出了基于 HHO-RDSOGM 的堆石坝施工仿真参数在线更新模型, 其流程如图 5 所示.

使用堆石坝实时监控数据流, 并将其存入监控中心数据库中. 通过异常值检测和处理对数据流进行预处理, 并将其输入至模型中, 通过原型分布形成初始原型模型.

以初始原型模型为基础, 把新输入原型和其最近两个高斯成分的距离与其相似度阈值 T_i 进行比较, 进而决定动态增加高斯成分抑或是进行属性参数实时更新. 当原型与高斯成分的距离大于 T_i 时, 其即可成为 1 个新的高斯成分被添加到模型中. 否则, 该原型将被用来对这两个高斯成分的参数进行更新.

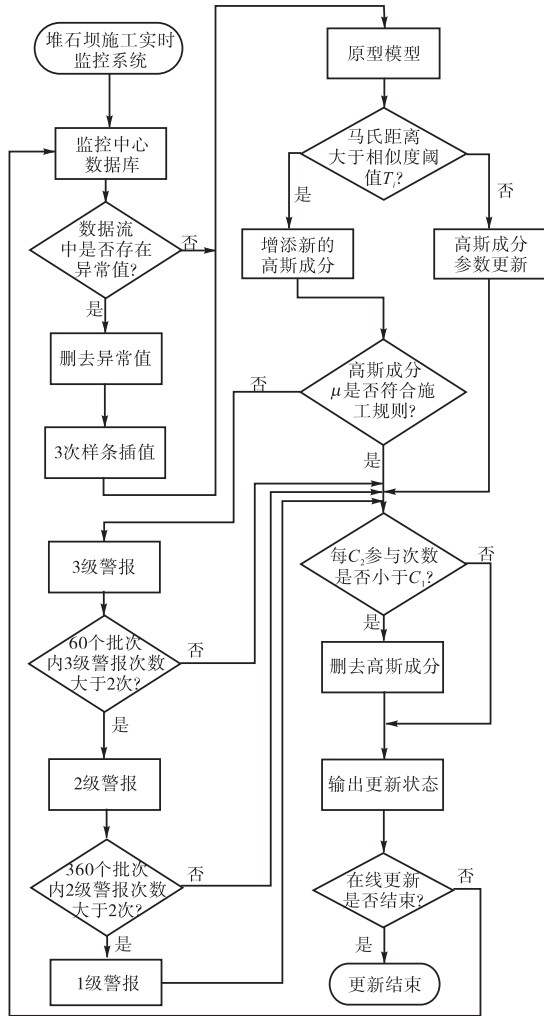


图 5 HHO-RDSOGM 模型流程
Fig.5 Flow chart of HHO-RDSOGM model

当增添 1 个新的高斯成分时,要进行施工规则检验,根据高斯成分均值 μ 分别发出 3 级、2 级和 1 级警报。

使用 HHO 算法对 C_1 和 C_2 进行超参数寻优,经过迭代后获得具体参数设置.每 C_2 次对高斯成分参与次数进行筛选,对小于 C_1 的高斯成分进行删除,输出更新状态.如果更新没结束,将继续循环更新。

通过以上自组织建模、在线增减高斯成分、属性参数实时更新和原型动态遗忘等步骤,HHO-RDSOGM 进行自组织在线学习,实现堆石坝施工仿真参数分布在线更新。

3 案例研究

3.1 工程背景

以中国西南部的某个大型水电站大坝工程为例(与第 2.2.1 节中案例相同),进行施工仿真参数在线更新研究.大坝为砾石土心墙堆石坝,是域梯级电站

开发的关键项目,最高坝高为 315 m,装机容量为 2×10^6 kW·h,坝址控制流域面积为 39 330 km².大坝正处于建设高峰期,图 6 为现场施工建设情况,现场共有 23 台碾压机(其中凸块碾 6 台,平碾 17 台),自卸汽车 156 辆。



(a) 心墙区上方俯视图



(b) 下游堆石区侧视图

图 6 大坝现场施工

Fig.6 Construction at dam site

3.2 模型建模与在线更新

以数据库中选取的现场工程 2024-08-01—2024-08-04 的 10 446 条现场碾压机碾压作业运行数据和 2017 年 9 月的 19 916 条现场自卸汽车运输作业运行数据为例.图 7 为所采集的碾压机瞬时行进速度样本,表明碾压机瞬时行进速度取值并非固定值,其不完全等于基于碾压试验的设计碾压速度.同时,大多数速度样本总体上处于 2.5 km/h 的附近区间.为了方便进行数据分析,采用的碾压数据样本速度单位均为 1×10^{-2} km/h,后同。




图 7 碾压机瞬时行进速度样本散点图

Fig.7 Scatter plot of instantaneous speed samples of dam rollers

图 8 为所采集的坝料运输车行驶速度样本,表明坝料运输车行驶速度变化幅度较大,实际工程环境下的坝料运输车行驶速度样本异常大值较多.同时,散点图有相当部分样本速度接近于 0,反映了其路口等待时间较长.




图 8 坝料运输车瞬时行进速度样本散点图

Fig.8 Scatter plot of instantaneous speed samples of dam material transport vehicles

将碾压和运输的样本数据进行异常值检测和处理,可以得到图 9~图 12.经过多次试验,设置 IF 算法阈值为 0.06.图 9 显示碾压机瞬时行进速度数据样本集大部分数据落在[2.0 km/h, 3.0 km/h].同时,数据样本集中存在离群较远的异常大值和异常小值,如图红点所标示,其代表工程实际施工情况中数据采集异常的情况,这里将其删去.




图 9 异常值检测后的碾压机行驶速度数据折线图

Fig.9 Line chart of dam roller speed data after outlier detection

如图 10 所示,坝料运输车行驶速度数据样本集大部分数据落在[0 km/h, 60 km/h],其中 30 km/h 的数据样本最多.同时,坝料运输车行驶瞬时速度样本数据集存在相当数量的异常大值,反映现场运输车司机驾驶行为的不规范或样本采集异常等施工过程中的特殊情况,这里将其删去.

如图 11 所示,经过插值处理后的碾压机速度数据折线图形态良好,反映了实际碾压作业运行情况.

如图 12 所示,经过插值处理后的坝料运输车速度数据折线图符合工程实际,其中速度大小接近为

0 km/h 时反映了施工现场路段拥挤导致运输车需要在道路中等待的情况,具有统计学意义.




图 10 异常值检测后的坝料运输车行驶速度数据折线图

Fig.10 Line chart of dam material transport vehicle speed data after outlier detection




图 11 插值后的碾压机行驶速度数据折线图

Fig.11 Interpolated line chart of dam roller speed data




图 12 插值后的坝料运输车行驶速度数据折线图

Fig.12 Interpolated line chart of dam material transport vehicle speed data

通过上述操作,获取经过数据清洗的仿真参数实时数据流.随后,进行 C_1 和 C_2 的超参数寻优,使用 HHO 算法,epoch 设置为 200, pop_size 设置为 50,随机初始化. HHO 算法通过模拟哈里斯鹰在捕食过程中的多种包围与追击策略,在全局探索与局部开发之间动态切换.迭代结果如图 13 所示,得到超参数 $C_1 = 0.2598$, $C_2 = 2.990$.

将碾压数据流以 2 000 样本数为 1 批次输入到 HHO-RDSOGM 施工仿真参数在线更新模型中,动态地输出仿真参数分布曲线,结果如图 14 所示,图中

颜色各异的线型表示各个高斯成分,而所有的高斯成分叠加成为蓝色包络线,形成总概率密度曲线。





图 13 HHO算法迭代曲线
Fig.13 Iteration curve of HHO algorithm


图 15 为碾压机瞬时行进速度数据样本集在 HHO-RDSOGM 中更新完成后呈现出的结束状态,图中的轮廓曲线表示所输入碾压机瞬时行进速度样本集所估计的概率密度函数曲线,其围成的面积定义为 1。

将运输实时数据流以 2000 样本数为 1 批次输入到 HHO-RDSOGM 施工仿真参数在线更新模型中,动态地输出仿真参数分布曲线,结果如图 16 所示,图中颜色各异的线型表示各个高斯成分,而所有的高斯成分叠加成为蓝色包络线,形成总概率密度曲线。


图 17 为坝料运输车瞬时行进速度数据样本集在 HHO-RDSOGM 中更新完成后呈现出的结束状态,图中的轮廓曲线表示所输入坝料运输车瞬时行进速度




(a) 批次 1 更新的中间状态




(b) 批次 2 更新的中间状态




(c) 批次 3 更新的中间状态



(d) 批次 4 更新的中间状态



(e) 批次 5 更新的中间状态



(f) 批次 6 更新的中间状态

图 14 碾压速度数据流在 HHO-RDSOGM 在线更新的中间状态

Fig.14 Intermediate state of rolling speed data stream during HHO-RDSOGM online update




图 15 碾压速度数据流在 HHO-RDSOGM 在线更新结束状态

Fig.15 End state of rolling speed data stream in HHO-RDSOGM online update

样本集所估计的概率密度函数曲线,其围成的面积定义为 1. 偏蓝区域表示坝料运输车瞬时行进速度相对于正常状态较小时的情况,偏红区域表示坝料运输车瞬时行进速度相对于正常状态较大时的情况.

图 18 为 HHO-RDSOGM 模型识别碾压速度运行状态:绿色区域表示碾压机行驶速度处于正常状态,概率为 0.839 5;红色区域表示碾压机行驶速度超过施工组织规范所规定的速度上限,概率为 0.114 5;黄色区域表示碾压机行驶速度低于施工组织规范所规定的速度下限,概率为 0.046 0.

图 19 为 HHO-RDSOGM 模型识别运输速度运行状态:绿色区域表示坝料运输车行驶速度处于正常

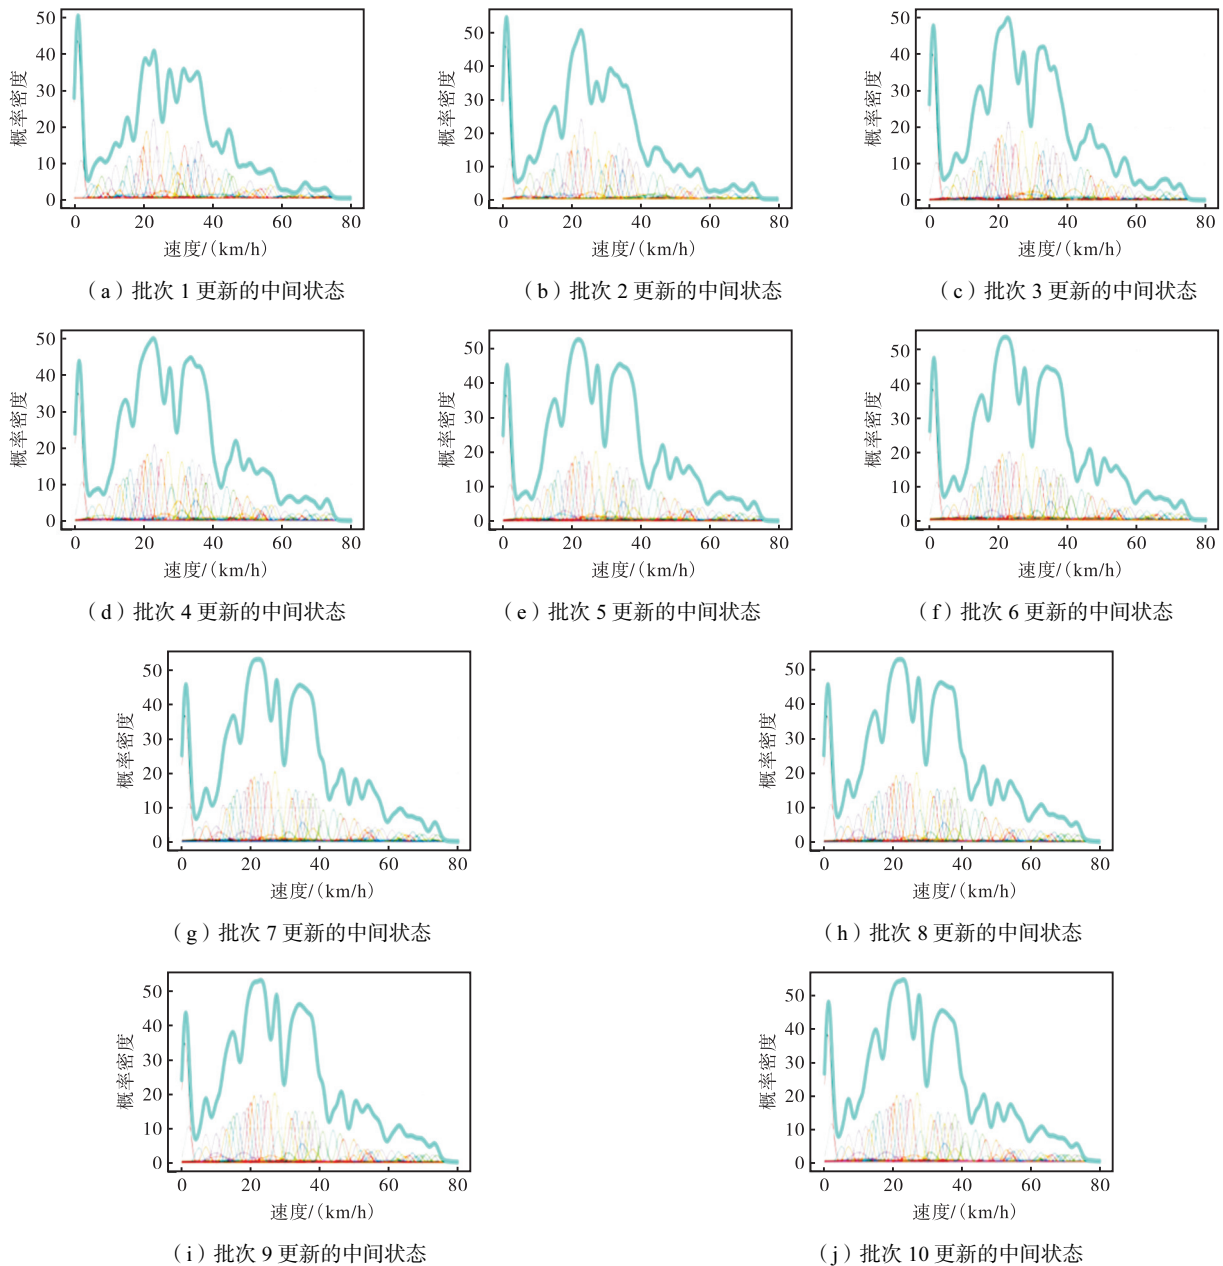


图 16 运输速度数据流在 HHO-RDSOGM 在线更新的中间状态

Fig.16 Intermediate state of transport speed data stream during HHO-RDSOGM online update




图 17 运输速度数据流在 HHO-RDSOGM 在线更新的结果状态

Fig.17 End state of transport speed data stream in HHO-RDSOGM online update




图 19 HHO-RDSOGM 模型识别运输速度运行状态

Fig.19 Transport speed operating state identified by HHO-RDSOGM model

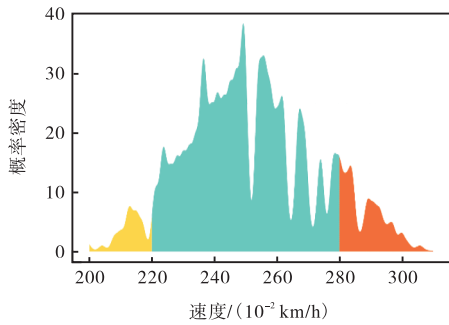


图 18 HHO-RDSOGM 模型识别碾压速度运行状态

Fig.18 Rolling speed operating state identified by HHO-RDSOGM model

状态, 概率为 0.765 1; 黄色区域表示坝料运输车行驶速度超过施工组织规范所规定的速度上限, 概率为 0.234 9.

上述结果显示, HHO-RDSOGM 模型可以根据堆石坝施工组织规范, 根据所输入的实时数据流在线识

别仿真参数状态. 同时, 根据所显示的结果分级报警, 及时向相应监管人员进行反馈, 实现施工现场安全高效智能管理.

3.3 对比分析

以获取的碾压和运输速度实时数据流为基础, 使用直方图、KDE^[40]、GMM、Dirichlet^[41]、oKDE^[42]和 HHO-RDSOGM 等方法进行参数分布建模, 结果如图 20 和图 21 所示.

本文采用詹森-香农 (Jensen-Shannon, JS) 散度^[43]的方法实现对 KDE、GMM、Dirichlet、oKDE、RDSOGM 和 HHO-RDSOGM 等方法的精度评估. JS 散度是 1 种用于衡量概率分布之间差异的度量方法, 它基于信息论中的库尔贝克-莱布勒 (Kullback-Leibler, KL) 散度和对称性的概念, 具有对称性和连续性的特点. 其基本思想是通过计算两个概率分布的中间分布来衡量二者之间的差异. 它考虑了 KL 散

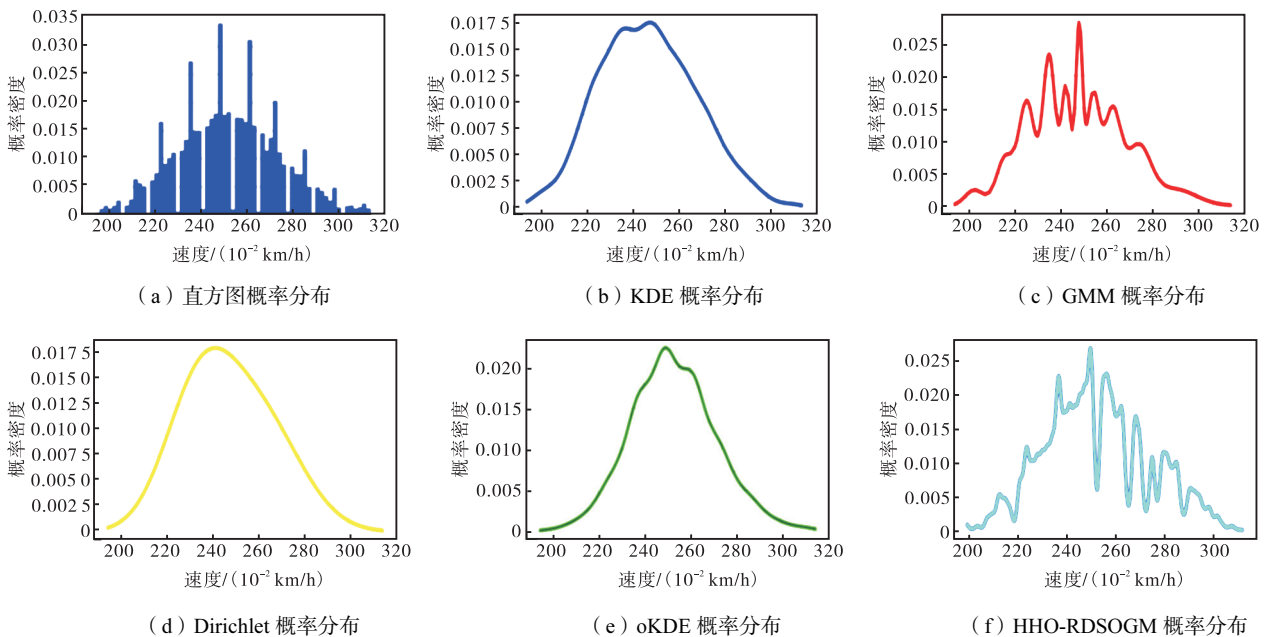


图 20 碾压速度数据流在各方法上的概率密度分布

Fig.20 Probability density distribution of rolling speed data stream for various methods

度的不对称性问题, 并通过对称性的方式解决了这个问题. JS 散度量化了两个概率分布之间的相似程度, 取值范围为[0, 1]. 其数值越小, 表示两个分布越相

似; 其数值越大, 表示两个分布差异越大; 当且仅当两个分布完全相同时, 取得最小值 0.

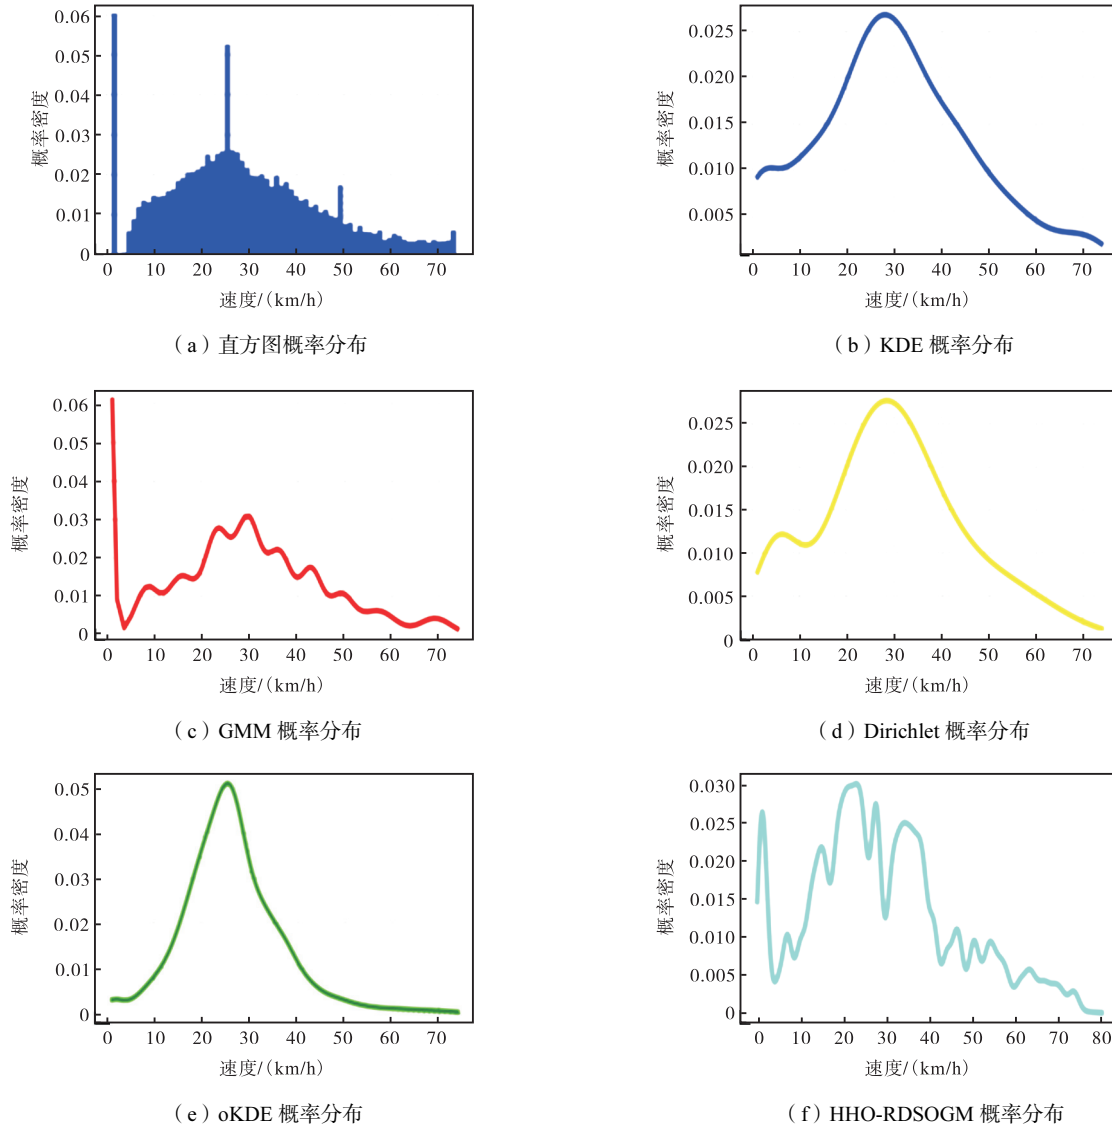


图 21 运输速度数据流在各方法上的概率密度分布

Fig.21 Probability density distribution of transport speed data stream for various methods

计算 JS 散度时, 首先定义两个概率分布 P 和 Q , 如式 (12) 和 (13) 所示, 其中 p_1, p_2, \dots, p_n 和 q_1, q_2, \dots, q_n 分别代表概率分布 P 和 Q 在相应事件上的概率值, 且 $\sum_{i=1}^n p_i = 1, \sum_{i=1}^n q_i = 1$.

$$P = \{p_1, p_2, \dots, p_n\} \tag{12}$$

$$Q = \{q_1, q_2, \dots, q_n\} \tag{13}$$

其次, 计算 P 和 Q 的均值分布 M 为

$$M = \frac{1}{2}(P+Q) = \left\{ \frac{p_1+q_1}{2}, \frac{p_2+q_2}{2}, \dots, \frac{p_n+q_n}{2} \right\} \tag{14}$$

再次, 分别计算 KL 散度.

$d_{KL(P||M)}$ 是分布 P 相对于 M 的 KL 散度, 其计算

式为

$$d_{KL(P||M)} = \sum_i p_i \ln \frac{p_i}{m_i} \tag{15}$$

$d_{KL(Q||M)}$ 是分布 Q 相对于 M 的 KL 散度, 其计算式为

$$d_{KL(Q||M)} = \sum_i q_i \ln \frac{q_i}{m_i} \tag{16}$$

最后, 计算 JS 散度, 该值是上述两个 KL 散度的平均值, 即

$$d_{JS(P||Q)} = \frac{1}{2}(d_{KL(P||M)} + d_{KL(Q||M)}) \tag{17}$$

本文以直方图为分布 P , 以 KDE、GMM、

Dirichlet、oKDE、RDSOGM 和 HHO-RDSOGM 等方法分别作为分布 Q . 在碾压和运输两种数据集下, 将上述方法进行编号(见表 1), 并分别以 100、200、500、1 000、2 000、5 000、10 000、20 000 和 50 000 的数据量计算相应的 JS 散度.

表 1 对比方法在不同样本集下 JS 散度计算编号

Tab.1 JS divergence calculation numbers of comparative methods under different sample sets

| 对比方法 | 碾压速度数据集上的编号 | 运输速度数据集上的编号 |
|------------------|-------------|-------------|
| KDE 对比直方图 | A1 | B1 |
| GMM 对比直方图 | A2 | B2 |
| Dirichlet 对比直方图 | A3 | B3 |
| oKDE 对比直方图 | A4 | B4 |
| RDSOGM 对比直方图 | A5 | B5 |
| HHO-RDSOGM 对比直方图 | A6 | B6 |

在碾压速度数据集中计算各方法的 JS 散度结果如图 22 所示. 相较于 KDE、GMM、Dirichlet、oKDE 和 RDSOGM, HHO-RDSOGM 在精度上平均分别提升了 33.65%、31.84%、22.99%、13.04% 和 6.79%. 在运输速度数据集中计算各方法的 JS 散度结果如图 23 所示. 相较于 KDE、GMM、Dirichlet、oKDE 和 RDSOGM, HHO-RDSOGM 在精度上平均分别提升




图 22 对比方法在碾压速度数据集下 JS 散度热力图
Fig.22 JS divergence heat map of comparative methods under dataset of rolling speed data

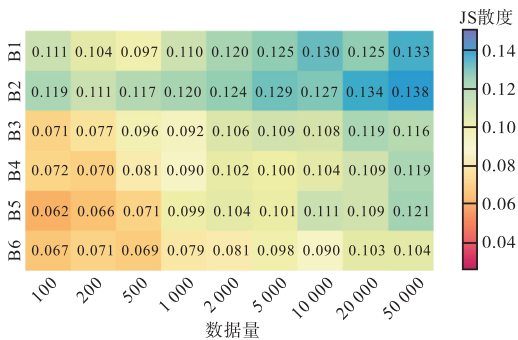


图 23 对比方法在运输速度数据集下 JS 散度热力图
Fig.23 JS divergence heat map of comparative methods under dataset of transport speed data

了 27.77%、31.90%、14.77%、10.04% 和 9.72%. 总体来看, 相较于 KDE、GMM、Dirichlet、oKDE 和 RDSOGM, HHO-RDSOGM 在精度上平均分别提升了 30.71%、31.87%、18.91%、11.50% 和 8.34%, 证明所提方法的有效性.

4 结 论

感知数据驱动的堆石坝仿真参数更新对于确保施工仿真结果的准确具有重要意义. 面对堆石坝施工现场获取的海量实时数据流, 现有方法难以准确高效地模拟异常值多、多峰和时变的仿真参数分布. 针对上述问题, 提出了 1 种实时感知数据流处理的堆石坝施工仿真参数在线更新模型, 得到了如下结论.

(1) 针对数据中的离群点、突变点和极不合理数据等异常值, 使用 IF 算法和 Spline 插值进行异常值检测和插值, 实现数据的清洗, 提高了数据的质量.

(2) 相较于传统参数分布更新的方法, 本文充分考虑了数据的多峰和时变的特点, 在考虑堆石坝施工组织设计的基础上, 保留 ESOINN 原型分布、动态调整和网络去噪等网络框架, 移除拓扑结构生成和聚类重叠区域删除等框架, 结合 GMM, 采用 HHO 进行超参数寻优, 实现堆石坝施工仿真参数在线更新.

(3) 将所提方法应用于中国西南某心墙堆石坝中, 实现了施工仿真参数建模和更新. 使用 JS 散度将 HHO-RDSOGM 与 KDE、GMM、oKDE、Dirichlet 和 RDSOGM 等方法进行评估对比, 结果表明: 相比于上述方法, HHO-RDSOGM 方法精度平均分别提升了 30.71%、31.87%、18.91%、11.50% 和 8.34%, 证明其有效性和优越性.

笔者课题组今后有两个研究方向: 一方面, 应充分考虑不同类型的数据流作为仿真参数更新的对象, 进一步提高模型的泛化能力; 另一方面, 应继续开展堆石坝施工活动状态分析, 结合施工现场的视频监控等条件, 阐明施工机械施工状态和不同的施工场景特点.

参 考 文 献:

[1] 钟登华, 张天鸿, 余红玲, 等. 智能时代与大坝工程建设智能化研究进展[J]. 水利学报, 2025, 56(1): 1-19.
Zhong Denghua, Zhang Tianhong, Yu Hongling, et al. Advancements in intelligent dam engineering construction in the intelligence era[J]. Journal of Hydraulic Engineering, 2025, 56(1): 1-19(in Chinese).

- [2] 李庆斌, 马睿, 胡昱, 等. 大坝智能建造理论[J]. 水力发电学报, 2022, 41(1): 1-13.
Li Qingbin, Ma Rui, Hu Yu, et al. Theory of intelligent dam construction[J]. Journal of Hydroelectric Engineering, 2022, 41(1): 1-13(in Chinese).
- [3] 钟登华, 时梦楠, 崔博, 等. 大坝智能建设研究进展[J]. 水利学报, 2019, 50(1): 38-52, 61.
Zhong Denghua, Shi Mengnan, Cui Bo, et al. Research progress of the intelligent construction of dams[J]. Journal of Hydraulic Engineering, 2019, 50(1): 38-52, 61(in Chinese).
- [4] 李庆斌, 林鹏. 论智能大坝[J]. 水力发电学报, 2014, 33(1): 139-146.
Li Qingbin, Lin Peng. Demonstration on intelligent dam[J]. Journal of Hydroelectric Engineering, 2014, 33(1): 139-146(in Chinese).
- [5] 钟登华, 常昊天, 刘宁, 等. 高堆石坝施工过程的仿真与优化[J]. 水利学报, 2013, 44(7): 863-872.
Zhong Denghua, Chang Haotian, Liu Ning, et al. Simulation and optimization of high rock-filled dam construction operations[J]. Journal of Hydraulic Engineering, 2013, 44(7): 863-872(in Chinese).
- [6] 钟登华, 常峻, 任炳昱, 等. 基于实时监控的高堆石坝施工进度影响因素研究[J]. 水力发电学报, 2014, 33(3): 239-245, 252.
Zhong Denghua, Chang Jun, Ren Bingyu, et al. Study on influencing factors of construction progress of high rock-fill dam based on real-time monitoring[J]. Journal of Hydroelectric Engineering, 2014, 33(3): 239-245(in Chinese).
- [7] 钟登华, 王志宁, 关涛, 等. 基于增强现实的心墙堆石坝施工进度可视化仿真[J]. 天津大学学报(自然科学与工程技术版), 2018, 51(10): 1072-1085.
Zhong Denghua, Wang Zhining, Guan Tao, et al. Visual simulation of construction schedule for core rock-fill dam based on augmented reality[J]. Journal of Tianjin University(Science and Technology), 2018, 51(10): 1072-1085(in Chinese).
- [8] 王佳俊. 心墙堆石坝坝面碾压智能监控方法与应用研究[D]. 天津: 天津大学建筑工程学院, 2019.
Wang Jiajun. Research on Intelligent Monitoring Method and Application of the Surface Compaction of Core-Wall Rock-Fill Dams[D]. Tianjin: School of Civil Engineering, Tianjin University, 2019(in Chinese).
- [9] Shao C F, Zheng S, Gu C S, et al. A novel outlier detection method for monitoring data in dam engineering[J]. Expert Systems with Applications, 2022, 193: 116476.
- [10] 郑磊, 纪新帅, 齐问坛, 等. 基于孤立森林算法的高拱坝施工期变形异常值检测模型[J]. 水利水电技术(中英文), 2023, 54(9): 127-136.
Zheng Lei, Ji Xinshuai, Qi Wentan, et al. A model for detecting deformation outliers during construction of high arch dams based on isolated forest algorithm[J]. Water Resources and Hydropower Engineering, 2023, 54(9): 127-136(in Chinese).
- [11] 张瑜, 秦学, 彭浩. 基于平滑阈值与孤立森林的大坝监测数据异常检测[J]. 人民黄河, 2025, 47(3): 141-145.
Zhang Yu, Qin Xue, Peng Hao. Anomaly detection of dam monitoring data based on smoothing threshold and isolated forest[J]. Yellow River, 2025, 47(3): 141-145(in Chinese).
- [12] 叶斌. 基于 LSTM 模型的大坝安全监测数据异常值检测[D]. 武汉: 长江科学院, 2020.
Ye Bin. Outlier Detection of Dam Safety Monitoring Data Based on LSTM Model[D]. Wuhan: Changjiang River Scientific Research Institute, 2020(in Chinese).
- [13] Song J T, Zhang S F, Tong F, et al. Outlier detection based on multivariable panel data and K-means clustering for dam deformation monitoring data[J]. Advances in Civil Engineering, 2021, 2021(1): 3739551.
- [14] Rong Z, Pang R, Xu B, et al. Dam safety monitoring data anomaly recognition using multiple-point model with local outlier factor[J]. Automation in Construction, 2024, 159: 105290.
- [15] 乔天诚, 佟大威, 王佳俊, 等. 基于 Kmeans-EMD 与 IWOA-Elman 的碾压速度异常值检测与修正[J]. 水资源与水工程学报, 2022, 33(3): 124-131.
Qiao Tiancheng, Tong Dawei, Wang Jiajun, et al. Outlier detection and correction for rolling speed based on Kmeans-EMD and IWOA-Elman[J]. Journal of Water Resources & Water Engineering, 2022, 33(3): 124-131(in Chinese).
- [16] Li B, Bai X P, Li J, et al. Outlier detection of gravity dam deformation monitoring data based on the multiple local outlier coefficient method[J]. Mathematical Problems in Engineering, 2022, 2022(1): 7157844.
- [17] Zhang J, Zhong D H, Wu B P, et al. Earth dam construction simulation considering stochastic rainfall impact[J]. Computer Aided Civil and Infrastructure Engineering, 2018, 33(6): 459-480.

- [18] 张 隽. 考虑降雨影响的高心墙堆石坝施工进度仿真研究[D]. 天津: 天津大学建筑工程学院, 2021.
Zhang Jun. Research on Construction Schedule Simulation of High Rockfill Dam Considering Rainfall Impact[D]. Tianjin: School of Civil Engineering, Tianjin University, 2021 (in Chinese).
- [19] 吕 菲. 基于机器学习的高心墙堆石坝施工全过程仿真优化研究[D]. 天津: 天津大学建筑工程学院, 2024.
Lü Fei. Research on Whole-Process Construction Simulation and Optimization for High Rockfill Dam Based on Machine Learning[D]. Tianjin: School of Civil Engineering, Tianjin University, 2024 (in Chinese).
- [20] 张 君, 余 佳, 任炳昱, 等. 考虑高寒低温影响的高心墙堆石坝仓面施工仿真模型研究[J]. 水利学报, 2022, 53(2): 200-211.
Zhang Jun, Yu Jia, Ren Bingyu, et al. Study on the simulation model of high-core rockfill dam construction in alpine region considering the influence of low temperature[J]. Journal of Hydraulic Engineering, 2022, 53(2): 200-211 (in Chinese).
- [21] Zhang J, Zhong D H, Zhao M Q, et al. An optimization model for construction stage and zone plans of rockfill dams based on the enhanced whale optimization algorithm[J]. Energies, 2019, 12(3): 466.
- [22] 张念木. 基于实时监控的面板堆石坝施工工期-质量-成本综合优化研究[D]. 天津: 天津大学建筑工程学院, 2014.
Zhang Nianmu. Research on Concrete Facing Rockfill Dam Construction Time-Quality-Cost Comprehensive Optimization Based on Real-Time Monitoring[D]. Tianjin: School of Civil Engineering, Tianjin University, 2014 (in Chinese).
- [23] 钟登华, 张琴娅, 杜荣祥, 等. 基于 CATIA 的心墙堆石坝施工动态仿真[J]. 天津大学学报(自然科学与工程技术版), 2015, 48(12): 1118-1125.
Zhong Denghua, Zhang Qinya, Du Rongxiang, et al. Dynamic construction simulation of core rock-fill dam based on CATIA platform[J]. Journal of Tianjin University (Science and Technology), 2015, 48(12): 1118-1125 (in Chinese).
- [24] 张元坤. 基于实时监控的碾压混凝土坝仓面施工仿真可视化分析研究[D]. 天津: 天津大学建筑工程学院, 2016.
Zhang Yuankun. Study on Construction Simulation and Visual Analysis for Storehouse Surface Construction of RCC Dam Based on Real-Time Monitoring[D]. Tianjin: School of Civil Engineering, Tianjin University, 2016 (in Chinese).
- [25] 钟登华, 关 涛, 任炳昱, 等. 基于改进重抽样法的高拱坝施工进度仿真研究[J]. 水利学报, 2016, 47(4): 473-482.
Zhong Denghua, Guan Tao, Ren Bingyu, et al. Construction simulation for high arch dams based on modified Bootstrap[J]. Journal of Hydraulic Engineering, 2016, 47(4): 473-482 (in Chinese).
- [26] Wang Q W, Zhong D H, Wu B P, et al. Construction simulation approach of roller-compacted concrete dam based on real-time monitoring[J]. Journal of Zhejiang University-Science A, 2018, 19(5): 367-383.
- [27] Guan T, Zhong D H, Ren B Y, et al. Construction simulation of high arch dams based on fuzzy Bayesian updating algorithm[J]. Journal of Zhejiang University-Science A, 2018, 19(7): 505-520.
- [28] 王国浩, 余 佳, 王晓玲, 等. 高拱坝施工仿真参数 EMD-P-ILSTM 动态更新模型研究[J]. 水力发电学报, 2021, 40(12): 106-118.
Wang Guohao, Yu Jia, Wang Xiaoling, et al. EMD-P-ILSTM dynamic updating model for simulation parameters of high arch dam construction[J]. Journal of Hydroelectric Engineering, 2021, 40(12): 106-118 (in Chinese).
- [29] 张 君. 多模态感知下高心墙堆石坝施工智能仿真理论与应用研究[D]. 天津: 天津大学建筑工程学院, 2022.
Zhang Jun. Research on Intelligent Simulation Theory and Application of High Core Rockfill Dam Construction Under Multimodal Perception[D]. Tianjin: School of Civil Engineering, Tianjin University, 2022 (in Chinese).
- [30] 吕 菲, 钟登华, 余 佳, 等. 迁移学习框架下高心墙堆石坝施工仿真参数 IGOA-MLP 动态预测模型[J]. 水利学报, 2023, 54(10): 1151-1162.
Lü Fei, Zhong Denghua, Yu Jia, et al. IGOA-MLP dynamic prediction model for simulation parameters of high core rockfill dam construction under transfer learning framework[J]. Journal of Hydraulic Engineering, 2023, 54(10): 1151-1162 (in Chinese).
- [31] Zhang Y N, Wang X L, Yu J, et al. Adaboosting graph attention recurrent network: A deep learning framework for traffic speed forecasting in dynamic transportation networks with spatial-temporal dependencies[J]. Engi-

- neering Applications of Artificial Intelligence, 2024, 127: 107297.
- [32] 钟登华, 刘磊, 刘东海, 等. 心墙堆石坝碾压过程信息自动采集装置: CN, 101577043B[P]. 2010-10-06.
Zhong Denghua, Liu Lei, Liu Donghai, et al. Automatic Data Collection Device for Rolling Process of Core Rockfill Dam: CN, 101577043B[P]. 2010-10-06 (in Chinese).
- [33] 王佳俊, 祁宁春, 钟登华, 等. 高心墙堆石坝原生集成式智能无人碾压系统研发及应用[J]. 水利学报, 2022, 53(12): 1421-1432.
Wang Jiajun, Qi Ningchun, Zhong Denghua, et al. Development and application of native-integrated intelligent unmanned compaction system for high core rockfill dam[J]. Journal of Hydraulic Engineering, 2022, 53(12): 1421-1432 (in Chinese).
- [34] Liu F T, Ting K M, Zhou Z H. Isolation forest[C]// 2008 Eighth IEEE International Conference on Data Mining. Pisa, Italy: IEEE, 2008.
- [35] McKinley S, Levine M. Cubic Spline Interpolation[R]. Eureka, USA: College of the Redwoods, 1998.
- [36] 邱天宇, 申富饶, 赵金熙. 自组织增量学习神经网络综述[J]. 软件学报, 2016, 27(9): 2230-2247.
Qiu Tianyu, Shen Furao, Zhao Jinxi. Review of self-organizing incremental neural network[J]. Journal of Software, 2016, 27(9): 2230-2247 (in Chinese).
- [37] 邱天宇. 基于增量高斯混合模型的在线密度估计研究[D]. 南京: 南京大学计算机科学与技术系, 2016.
Qiu Tianyu. Research of Online Density Estimation Based on Incremental Gaussian Mixtures[D]. Nanjing: Department of Computer Science and Technology, Nanjing University, 2016 (in Chinese).
- [38] Reynolds D. Gaussian mixture models[G]. Encyclopedia of Biometrics. New York: Springer, 2009: 659-663.
- [39] Heidari A A, Mirjalili S, Faris H, et al. Harris hawks optimization: Algorithm and applications[J]. Future Generation Computer Systems, 2019, 97: 849-872.
- [40] Węglarczyk S. Kernel density estimation and its application[J]. ITM Web of Conferences, 2018, 23: 00037.
- [41] Shen W N, Tokdar S T, Ghosal S. Adaptive Bayesian multivariate density estimation with Dirichlet mixtures[J]. Biometrika, 2013, 100(3): 623-640.
- [42] Kristan M, Skočaj D, Leonardis A. Online kernel density estimation for interactive learning[J]. Image and Vision Computing, 2010, 28(7): 1106-1116.
- [43] Menéndez M L, Pardo J A, Pardo L, et al. The Jensen-Shannon divergence[J]. Journal of the Franklin Institute, 1997, 334(2): 307-318.

(责任编辑:武立有)