

文章编号: 0559-9350(2023)03-0291-11

基于 IPSO-BP 神经网络的高含沙水体对鱼类影响预测方法

李晓晨¹, 白音包力皋¹, 李向东², 许凤冉¹, 穆祥鹏¹, 董志强¹

(1. 中国水利水电科学研究院 流域水循环模拟与调控国家重点实验室, 北京 100038;

2. 青海省水利水电勘测规划设计研究院有限公司, 青海 西宁 810001)

摘要: 水库进行水力排沙时, 高含沙水流过程可能会对鱼类等水生动物产生负面影响, 其量化评估方法研究较为薄弱。为了预测和评估水库排沙过程对下游鱼类的影响, 本文利用黄河花斑裸鲤和鲤鱼在高含沙水体中生存特性研究的实验数据, 综合考虑含沙量和粒径、溶解氧、暴露时间、水温等因子对鱼类生存的影响, 建立了基于 IPSO-BP 神经网络的高含沙水体对鱼类致死影响预测方法, 对目标鱼类死亡率的预测误差小于 6%。本文使用了与 BP 神经网络紧密耦合并引入动态参数和变异扰动的 IPSO 算法, 较 BP 和 PSO-BP 神经网络预测能力更佳, 相比国内外已有的 Stress Index(SI)、Severity of Ill Effect (SEV)和多元拟合方法预测精度得到显著提升。分析表明, 本文提出的预测方法能够考虑高含沙水体中鱼类生存受多环境因子联合制约, 且多因子之间存在复杂关联的情况, 可为评估高含沙水流过程对水生态的影响提供新的方法。

关键词: IPSO-BP 神经网络; 高含沙水流; 鱼类; 致死率; 预测方法

中图分类号: TV145; TP183

文献标识码: A

doi: 10.13243/j.cnki.slxb.20220533

1 研究背景

水库进行水力排沙时, 下游河道水体的含沙量和溶解氧短时间内剧烈波动, 排沙形成的高含沙水流过程会导致鱼类等水生动植物大量死亡^[1]。目前国内对于水库排沙给下游河流生态环境带来的负面影响重视程度仍然不足^[2-3], 且缺乏相应量化和预测水生动物受影响程度的手段^[4]。分析和预测高含沙水流过程对鱼类的影响, 对制定基于水生态保护的水库排沙方案有重要参考价值^[5]。

高含沙水流过程对鱼类的影响取决于悬移质泥沙浓度(Suspended Sediment Concentration, SSC)及其粒径、鱼类种类、暴露时间(Exposure Duration, ED)等很多因素, 为此, 国内外学者通过室内水槽实验和野外调查的方法进行了研究^[6-7]。悬浮泥沙浓度较高会伤害鱼类的呼吸系统, 泥沙会刺激口腔和呼吸道上皮组织, 引起鳃的损伤、堵塞和分泌黏液^[8]。鳃的损伤会导致鱼类暂时性缺氧, 在极端条件下会引起鱼类死亡。此外, 吸附在泥沙颗粒表面的有机质和还原性物质与水中溶解氧发生反应, 导致高含沙水体溶解氧含量快速下降, 这也是鱼类死亡的原因之一^[7]。不同河流的不同鱼种对泥沙的耐受能力存在明显差异^[9-10], 对于特定的水库实施排沙时应考虑流域内优势物种的耐受能力。

目前, 评估高含沙水流过程对鱼类影响的方法主要有两种: 一种是依据水库排沙可能的平均或最高含沙量预估鱼类死亡率。然而以恒定的含沙量阈值来判别鱼类受影响程度显然存在很多不确定性^[9]。另一种是统计分析的方法, 通过样本数据建立预测因子与目标因子的相关关系。Newcombe C P等^[11-12]先后基于水生动物的观察数据提出了 Stress Index (SI)和 Severity of Ill Effect (SEV)评估方法,

收稿日期: 2022-07-07; 网络首发日期: 2023-03-03

网络首发地址: <https://kns.cnki.net/kcms/detail/11.1882.TV.20230301.1559.002.html>

基金项目: 青海省基础 Research 计划项目(2021-ZJ-759)

作者简介: 李晓晨(1995-), 博士生, 主要从事水力学及河流动力学研究。E-mail: xiaochenli1995@foxmail.com

通讯作者: 白音包力皋(1972-), 博士, 教授级高级工程师, 主要从事生态水力学研究。E-mail: baiyin@iwahr.com

这两种方法将悬浮泥沙浓度及鱼类暴露时间作为输入因子，比单一采用泥沙浓度更能准确预测对鱼类影响程度。但该类方法未能考虑多个因子之间的复杂非线性问题，使用时受到诸多限制，预测精度有待提高。

人工神经网络通过对样本数据的学习，可具有逼近任意连续函数和非线性映射的能力，能够模拟多个因子之间的相互作用和对目标因子的影响^[13]。本文利用研究黄河花斑裸鲤和鲤鱼在高含沙水体中生存特性的实验数据，考虑含沙量、溶解氧、暴露时间、水温等因子的作用，建立了基于改进粒子群算法—反向传播神经网络(Improved Particle Swarm Optimization-Back Propagation, IPSO-BP)的高含沙水体对鱼类致死影响的预测方法，并与传统方法的评估效果进行比较分析，为高含沙水流过程对鱼类影响的评估和预测提供新的手段。

2 材料与方法

2.1 高含沙水体对鱼类致死影响的实验数据

(1)实验目的和设计。为了定量评估高含沙水体对鱼类的影响，课题组进行过两组分别研究黄河上游花斑裸鲤(*Gymnocypris Eckloni*)^[14]和中下游鲤鱼(*Cyprinus Carpio*)两种代表性鱼类在高含沙水体中生存特性的室内实验，两种鱼类在黄河干流的分布如图1所示。



图1 两种实验鱼栖息地在黄河干流的分布示意

对于鲤鱼的实验在2011年7月完成^[1]。对于花斑裸鲤的实验在2021年6月完成，主要评估黄河上游玛多县的黄河源水电站拆坝对下游河道鱼类影响。两组实验均在1 m×1 m×0.8 m(长×宽×高)的有机玻璃实验水槽进行，水槽底部安装有调速电机带动的螺旋桨以保证泥沙悬浮。实验用沙取自相应鱼类的捕获地点，颗粒级配曲线如图2所示。两种实验鱼共计16组，实验选用的实验鱼体重0.5~1 kg，每次实验使用10条，实验工况设置见表1。实验时每15~30 min测量一次水温和溶解氧，当鱼类死亡时加测一次。考虑水库排沙峰值和鱼类对高含沙胁迫的急性反应时间，本文对实验时长在10 h内的数据进行分析。




图2 实验用沙颗粒级配

(2)高含沙水体中主要环境因子变化情况。实验过程中鱼类的死亡与暴露时间、含沙量、溶解氧、水温等多种环境因子有关,环境因子相互作用机理较为复杂。实验过程中溶解氧浓度随含沙量增加和实验进行而递减,花斑裸鲤和鲤鱼实验时 10 h 内溶解氧浓度分别下降了 1.6 ± 0.8 mg/L 和 1.7 ± 0.8 mg/L(平均值 $\pm$ 标准差)。鱼类耗氧、泥沙颗粒表面吸附的有机质和还原性物质在水体中不断耗氧是造成溶解氧减少的主要原因。溶解氧和含沙量的 Pearson 相关系数为-0.56,实验测量结果与天然水体中的溶解氧-含沙量负相关的规律相吻合^[1]。同时发现溶解氧浓度随水温的增加而减小,本文 16 组工况的水温分布在 7.4~29.2 ℃ 区间,10 h 实验期水温升高 2.2 ± 1.9 ℃,采用单一水温变量拟合溶解氧时,其线性回归方程为 $y = -0.292x + 9.959$, $R^2 = 0.954$ (x 为水温,℃; y 为溶解氧,mg/L)。与胡鹏等^[15]在清水流速 0.3 m/s,水温 13.0~21.0 ℃ 时得出的回归方程 ($y = -0.327x + 14.784$, $R^2 = 0.902$) 基本一致。

对鱼类死亡率和环境因子计算其 Pearson 相关系数如表 2 所示,两种鱼类的死亡率均与含沙量、水温、暴露时间呈正相关关系,和溶解氧浓度呈负相关关系。死亡率和环境因子的相关性分析说明,死亡率与溶解氧、含沙量两因子有强相关性,与水温、暴露时间两因子存在中等相关性。表 2 中暴露时间与鲤鱼死亡率相关性较弱,是因鲤鱼实验时 7 组工况中的 4 组含沙量大于 80 kg/m³,超过了鲤鱼的泥沙耐受极限,导致鲤鱼在短时间内迅速死亡,从而减弱了时间和鲤鱼死亡率的相关性。以上分析说明低溶解氧环境的胁迫、悬浮泥沙的直接威胁和水温的变化均对鱼类生存产生了影响。

表 2 死亡率与实验环境因子的 Pearson 相关系数

鱼类死亡率/%	暴露时间/h	含沙量/(kg/m ³)	溶解氧/(mg/L)	水温/℃
鲤鱼	0.07	0.39 ¹⁾	-0.65 ¹⁾	0.38 ¹⁾
花斑裸鲤	0.34 ¹⁾	0.50 ¹⁾	-0.49 ¹⁾	0.32 ¹⁾

注：1) 在 0.01 水平上极其相关。

(3)实验鱼的死亡情况。在鲤鱼实验中,含沙量为 16 kg/m³时实验鱼在 10 h 内未出现死亡。含沙量为 38 和 60 kg/m³时,在 10 h 内实验鱼死亡率分别为 50%和 70%。含沙量大于 89 kg/m³的 4 组实验,实验鱼在 2 h 内全部昏迷或死亡。对花斑裸鲤进行实验时,含沙量低于 40 kg/m³时实验鱼在实验期内未死亡。含沙量为 40~60 kg/m³的两组实验,实验鱼均在实验开始的 7 h 之后死亡,且死亡率均为 20%。含沙量大于 80 kg/m³时在 5 h 内 90%的实验鱼死亡。两种实验鱼死亡率随时间的变化过程如图 3 所示,高含沙量和较长暴露时间均会对鱼类造成影响,累计死亡率随含沙量和实验历时增加而升高。

实验结束时两种实验鱼死亡率与含沙量关系如图 4 所示。鲤鱼在含沙量由 38 kg/m³升高至 80 kg/m³时,死亡率由 50%升高至 100%。花斑裸鲤在含沙量从 60 kg/m³增加到 80 kg/m³时,死亡率由 20%升高至 100%。两种鱼类泥沙耐受的差异主要体现在鲤鱼死亡的含沙量阈值要小于花斑裸鲤,即鲤鱼在含沙量不足 40 kg/m³时已经发生死亡。这一现象的原因除了不同种类鱼固有的泥沙耐受差异,主要是为了确保实验条件与实验鱼栖息地自然条件保持一致,两次鱼类实验的水温、溶解氧初始状态以及实验用沙存在差异,使得鲤鱼实验时受到泥沙和低溶解氧威胁程度更大,具体为：1) 鲤鱼实验时水槽水温较高、溶解氧仅为 1.5~3.5 mg/L,低于花斑裸鲤实验时的最低溶解氧浓度 4.5 mg/L。2) 鲤鱼实验使用的泥沙粒径颗粒较细,加剧了鳃被堵塞和破坏的程度。

表 1 实验工况设置

序号	实验鱼种类	含沙量/(kg/m ³)	初始水温/℃	初始溶解氧/(mg/L)
1	花斑裸鲤	3.3	9.4	8.0
2		9.6	9.3	7.8
3		21.7	7.5	8.3
4		39.4	13.7	6.9
5		58.9	7.4	8.5
6		59.7	8.2	7.5
7		62.8	8.3	8.4
8		64.2	15.4	6.3
9		80.8	12.9	7.2
10	鲤鱼	16.0	23.1	3.8
11		38.0	26.6	2.3
12		60.0	26.7	2.9
13		89.0	27.2	3.2
14		118.0	28.4	3.1
15		151.0	26.3	3.8
16		182.0	26.0	2.7




图3 不同含沙量时实验鱼死亡率随时间变化过程




图4 鲤鱼和花斑裸鲤的死亡率和含沙量关系
(暴露时间为 10 h)

由实验数据可得到实验鱼死亡率与环境因子的线性相关方程,如表3所示。使用各环境因子进行二元拟合得出的方程其 R^2 均小于0.5,使用4个环境因子得出的四元拟合方程其 R^2 也仅为0.55。表明环境因子的线性组合对死亡率解释性较差,不能充分考虑死亡率受多个环境因子联合制约的机理,不宜采用线性拟合方程推算鱼类的死亡率。因此,本文采用人工神经网络对鱼类所受的致死影响进行预测,根据16组实验数据确定了439条用于训练、验证和测试神经网络的样本数据,每条测量数据包括实验鱼种类、暴露时间、含沙量、泥沙中值粒径、溶解氧、水温 and 实验鱼死亡率等7个变量。

表3 实验环境因子和鱼类死亡率的拟合方程

因变量 Z	自变量 x	自变量 y	自变量 w	自变量 p	拟合方程	R^2
鱼类	含沙量/(kg/m ³)	暴露时间/h			$Z = -0.195 + 0.0045x + 0.0257y$	0.393
	含沙量/(kg/m ³)	溶解氧/(mg/L)			$Z = -0.162 + 0.0030x + 0.0106y$	0.373
死亡率/%	含沙量/(kg/m ³)	水温/℃			$Z = 0.315 + 0.0024x - 0.0514y$	0.420
	溶解氧/(mg/L)	水温/℃			$Z = 2.950 - 0.0710x - 0.3087y$	0.476
	暴露时间/h	含沙量/(kg/m ³)	溶解氧/(mg/L)	水温/℃	$Z = 2.057 + 0.0003x + 0.0024y - 0.2297w - 0.0541p$	0.550

2.2 基于 IPSO 算法优化的 BP 神经网络

(1)BP 神经网络。作为一种基于误差逆传播算法训练的多层前馈网络,反向传播神经网络(Back Propagation, BP)广泛用于洪涝、冰情和生物死亡率等领域的预测^[16-17]。它由输入层、隐含层和输出层组成,通过不断计算输出层的预测结果和期望值的误差,使用梯度下降法对误差进行反向传播以修正各层神经元的权值和阈值^[18]。BP 神经网络可以解决模糊、非线性的复杂问题,但 BP 神经网络具有较强的随机性和不确定性,存在学习收敛速度慢、不能保证收敛到全局最小点等缺陷。目前对于 BP 神经网络预测精度提升的方法主要有两种^[19]:一是改进权重和阈值的计算方法;二是改善权重和阈值的初始化方法。本文主要使用方法二提高网络输出精度。

(2)改进粒子群算法(IPSO)。粒子群算法(Particle Swarm Optimization, PSO)是优化计算中常用的迭代方法^[20],其通过种群中个体的协作和信息共享寻找最优解,本文使用改进的 PSO 算法优化 BP 神经网络的初始权重和阈值。IPSO 算法运行时首先随机地初始化由 m 个粒子组成的种群,每个粒子包

含一组优化问题的潜在解。在迭代过程中，根据优化函数计算每个解的适宜度，以个体和全体适宜度极值为基准，不断更新全体粒子信息，进而搜索整个状态空间，最终使得适应度值最小，即找到优化问题的全局最优解。

在传统 PSO 算法的基础上，本文从粒子速度更新公式和变异扰动两个方面进行了改进：

1) 粒子速度更新公式的改进。传统 PSO 算法粒子速度更新公式如式(1)所示，本文在粒子速度更新过程中保留了原本的搜索方法，同时引入了与全体最优粒子对应的 BP 神经网络权值和阈值，将 IPSO 算法和 BP 神经网络的梯度下降法相结合，如式(2)所示。本文以 BP 神经网络的输出误差作为适宜度函数，在粒子速度计算过程中，将适宜度最优(即误差最小)的 BP 神经网络权值和阈值导出，形成与 IPSO 算法粒子相同的数据编码格式，加入粒子速度计算过程。并通过动态系数 η 依据计算进度调整 IPSO 算法与梯度下降法计算结果所占比例。

$$v_{ij}^{k+1} = v_{ij}^k + c_1 r_1 (P_{ij}^k - x_{ij}^k) + c_2 r_2 (P_{gj}^k - x_{ij}^k) \quad (1)$$

$$v_{ij}^{k+1} = (1-\eta) [v_{ij}^k + c_1 r_1 (P_{ij}^k - x_{ij}^k) + c_2 r_2 (P_{gj}^k - x_{ij}^k)] + \eta V_{BPbest} \quad (2)$$

$$\eta = \frac{k}{2K} \quad (3)$$

式中： v 为粒子速度； x 为粒子位置； i 为第 i 个粒子， j 为粒子的维度； k 为当前的迭代次数； c_1 、 c_2 为学习因子； r_1 、 r_2 为 $(0, 1)$ 内的随机数； P_{ij} 和 P_{gj} 分别为个体和全体粒子适宜度极值； K 为最大迭代次数； V_{BPbest} 为对应全体最优适宜度粒子的 BP 神经网络的权值和阈值。

本文同时引入了惯性权重和动态学习因子，对粒子速度更新算法进行了改进。惯性权重采用陈博文等^[21]基于 Logistic 回归曲线提出的衰减策略，将惯性权重变化分为下降、上升、再下降三个部分。可在迭代计算初期提高粒子的广域搜索能力和收敛效率，中期随着权重转折上升而扩大搜索空间和寻优能力，后期依靠局部搜索获得高精度解。非线性自适应改变的学习因子在算法初期提高个体极值的权重，后期提高了全体极值的权重。本文采用了全秋娟等^[22]提出的学习因子异步变化规则，能够始终保持 c_1 和 c_2 之和为 4。改进后的 IPSO 算法粒子速度和位置更新公式如下：

$$\begin{cases} v_{ij}^{k+1} = (1-\eta) [\omega v_{ij}^k + c_1 r_1 (P_{ij}^k - x_{ij}^k) + c_2 r_2 (P_{gj}^k - x_{ij}^k)] + \eta V_{BPbest} \\ x_{ij}^{k+1} = x_{ij}^k + v_{ij}^{k+1} \end{cases} \quad (4)$$

$$\omega = \frac{-2k(\omega_{\max} - \omega_{\min})}{K} + \frac{\omega_{\max} - \omega_{\min}}{1 + e^{-(\frac{12}{K}k - 6)}} + \omega_{\max} \quad (5)$$

$$c_1 = 2 + \frac{f - f_{ave}}{f_{ave} - f_{\min}}, \quad c_2 = 2 - \frac{f - f_{ave}}{f_{ave} - f_{\min}} \quad (6)$$

式中： ω 为惯性权重； $\omega_{\max}$ 、 $\omega_{\min}$ 分别为最大惯性权重和最小惯性权重，本文 $\omega_{\max} = 0.8$ ， $\omega_{\min} = 0$ ； f 为该粒子本次迭代的适宜度值， f_{ave} 和 $f_{\min}$ 分别为全体适宜度的平均值和最小值。

2) 粒子的变异扰动。为了提高粒子种群多样性，进一步扩大搜索空间，本文引入了变异扰动。在粒子每次更新后，根据该粒子前 2 次适宜度值变化趋势计算变异概率 p ，若前 2 次适宜度值变化幅度均小于 5%，则增大变异概率。引入变异扰动有利于在迭代后期扩大搜索空间，跳出局部极值。根据黄璇等^[23]向 PSO 算法引入的变异操作，本文设置的粒子速度变异公式和变异概率为：

$$x_{ij} = \begin{cases} x_{ij} + (x_{ij} - x_{\min})(1 - k/K)a, & a > 0.5 \\ x_{ij} - (x_{ij} - x_{\max})(1 - k/K)a, & a \leq 0.5 \end{cases} \quad (7)$$

$$p^k = \begin{cases} [(p_1 + p_0) - (p_1 - p_0) \cos(\pi k/K)], & \beta < 0.05 \\ [(p_1 + p_0) - (p_1 - p_0) \cos(\pi k/K)]/2, & \beta \geq 0.05 \end{cases} \quad (8)$$

式中： $x_{\min}$ 、 $x_{\max}$ 分别为粒子位置的最小和最大值； p_0 、 p_1 为初始和最终概率，本文 $p_0 = 0.05$ ， $p_1 = 0.35$ ； β 为该粒子前 2 次适宜度值变化幅度； a 为 $(0, 1)$ 内的随机数。

(3) IPSO-BP 神经网络。本文 IPSO-BP 神经网络算法流程如图 5 所示，其具体实现步骤如下：①根据实验数据构建含沙水体中目标鱼类死亡率的数据集，并进行归一化处理；②将数据集导入 IPSO-BP

神经网络，对其中的 BP 神经网络和 IPSO 算法粒子群初始化；③IPSO 算法调用 BP 神经网络计算当前适宜度值(仅第一次迭代时)以寻求粒子个体和群体的适宜度极值；④根据式(4)进行粒子速度和位置更新，判断是否施加变异扰动，并调用 BP 神经网络计算粒子适宜度值；⑤判断是否达到最大迭代数或预设精度，否则返回到步骤③；⑥将寻优得到的权值和阈值赋予 BP 神经网络，再利用梯度下降法进行训练；⑦将待预测的高含沙水体和鱼类数据输入 BP 神经网络，输出相应的鱼类死亡率。




图5 利用 IPSO-BP 神经网络预测鱼类死亡率算法流程

3 基于 IPSO-BP 神经网络的鱼类致死影响预测

3.1 神经网络参数的确定

(1)评价指标。为了衡量神经网络的预测效果，使用均方根误差(Root Mean Square Error, RMSE)、平均相对误差绝对值(Mean Absolute Percentage Error, MAPE)和纳什效率系数(Nash-Sutcliffe efficiency coefficient, NSE)进行评价^[24]。计算公式分别为：

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (9)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{\hat{y}_i} \right| \quad (10)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2} \quad (11)$$

式中： $\hat{y}_i$ 、 y_i 分别为神经网络输出值和期望值，即鱼类死亡率的预测值和实测值； $\bar{y}$ 为期望值的平均值，即鱼类死亡率实测值的平均值； i 为样本数据组数； n 为全部样本数据个数。

(2)BP 神经网络结构。建立 BP 神经网络的关键是拓扑网络的构造，包括网络层和结点数量的选定。本文使用的 BP 神经网络训练算法为 Bayes 正则化算法，学习率为 0.01。网络结构包含输入层、隐含层和输出层 3 层，输入层与隐含层间选用双曲线正切函数 Tansig 作为传递函数，隐含层与输出层间的选取线性函数 Purelin 作为传递函数。BP 神经网络隐含层的神经元个数取值依据式(12)初步确定为 9~13 个，通过由小到大改变神经元个数训练并检验其精度，计算表明当隐含层神经元个数为 12 时精度最高，最终确定神经元数为：输入层 6 个、隐含层 12 个、输出层 1 个。

$$p = \sqrt{m+n} + A \quad (12)$$

式中： p 为隐含层神经元数量； m 为输入参数数量； n 为输出参数数量； A 为[1, 10]之间的常数。

(3)IPSO 算法参数。粒子群方法中的粒子种群规模对系统的收敛速度、准确性和稳定性都有影响。增加种群规模可以提高算法的搜索精度，但会减慢算法的收敛时间。王维博等^[25]根据实验法推荐将粒子群的种群规模设置为 20~50。利用粒子群算法优化 BP 神经网络时，其最大迭代次数通常为 100~300 次^[23,26]。本文选取 IPSO 算法参数为：粒子种群规模 30、迭代次数 100 次。

3.2 IPSO-BP 神经网络训练结果 对于实验得出的 439 条测量数据，使用 419 条对 IPSO-BP 神经网络进行训练和验证，其中随机选取的训练集占 80%，验证集占 20%^[27]。使用 20 条数据作为测试数据（测试集不用于神经网络训练），测试数据集的变量值基本覆盖了实验测量的范围，具有较强的代表性。部分训练样本数据的预测和实测死亡率如图 6 所示，在不同实验鱼种类和含沙量时，实测值和预测值均较为接近且变化趋势一致。在图 7 中，训练样本死亡率的数据点均集中分布于 $y=x$ 辅助线附近，相关系数 $R=0.995$ ，满足训练要求。通过对预测误差的分布进行统计可知，训练样本的预测误差基本处于 $\pm 5\%$ 以内，仅有 1 组数据的误差大于 10%。基于以上分析，认为建立的 IPSO-BP 神经网络在预测高含沙水体中花斑裸鲤和鲤鱼的死亡率时拥有较高的准确率。

3.3 IPSO-BO 神经网络预测结果 IPSO-BP 神经网络训练完成后，为了消除 BP 神经网络的随机性对预测结果的影响，参照文献[26]的数据处理方法，对 20 组测试数据重复计算 10 次取平均值进行分析，实验测量数据和预测结果如表 4 所示。由表可知，死亡率的预测和实测值基本保持一致，平均误差为 1.81%，最大误差为 5.48%。在预测数据中鲤鱼死亡率的误差比花斑裸鲤相对较大，因为鲤鱼水槽实验的测量数据较少，训练样本数据少于花斑裸鲤，可通过增加训练样本、结合野外观测数据等方法提高预测准确率。




图 6 用于训练的部分样本数据和预测结果对比




图 7 IPSO-BP 神经网络训练误差分析

表 4 实验数据和 IPSO-BP 神经网络预测值

数据编号	鱼种类	暴露时间/min	含沙量/(kg/m^3)	溶解氧/(mg/L)	水温/ $^{\circ}\text{C}$	实验死亡率/%	IPSO-BP 预测死亡率/%
1	花斑裸鲤	15	58.9	8.3	7.5	0.0	0.1
2		30	64.2	5.9	15.4	0.0	0.0
3		90	21.7	7.7	8.5	0.0	0.0
4		140	64.2	5.3	15.8	10.0	7.3
5		140	80.8	5.4	13.3	10.0	8.7
6		160	80.8	5.4	13.4	20.0	16.7
7		340	80.8	5.0	13.7	90.0	91.2
8		395	62.8	6.9	9.8	30.0	29.3
9		415	80.8	5.0	13.9	90.0	90.5
10		465	21.7	5.8	12.0	0.0	0.0
11		485	39.4	4.9	16.8	0.0	0.0
12		498	3.3	7.8	9.1	0.0	0.0
13		525	64.2	4.6	19.1	50.0	52.8
14		560	59.7	6.4	11.8	20.0	19.7
15	鲤鱼	30	118.0	1.8	28.5	40.0	35.6
16		40	182.0	1.6	26.0	90.0	91.6
17		54	89.0	1.7	27.2	70.0	74.8
18		120	60.0	1.8	26.8	60.0	63.7
19		330	16.0	2.2	25.2	0.0	5.5
20		570	60.0	2.2	29.0	70.0	73.2

3.4 不同神经网络预测精度对比分析 为了对比不同神经网络的预测精度，同时采用 IPSO-BP 神经网络、PSO-BP 神经网络、BP 神经网络使用相同的数据集进行预测，三者的网络结构等参数设置均相同，各取 10 次计算结果进行对比分析。由图 8 可知，IPSO-BP 神经网络的 $RMSE$ 、 $MAPE$ 均值分别为 PSO-BP 神经网络的 89%、61%，为 BP 神经网络的 85%、57%，且相较于 BP 神经网络相应的标准差降低了 25%~60%。 NSE 值也较 PSO-BP 和 BP 神经网络提高了 1%~2%。计算结果说明引入 IPSO 算法改进后的 BP 神经网络预测能力有所提升，预测极值偏离变小，预测平稳性更佳。

对比采用了惯性权重、动态学习率和变异扰动的 IPSO-BP 神经网络和传统 PSO-BP 神经网络，改进后的算法除了拥有更小的预测误差，在计算 BP 神经网络的初始权重和阈值时也得到了更优的粒子适宜度。由图 9 可知，PSO-BP 神经网络在 25 次进化后粒子适宜度下降速率大幅放缓，在随后的 75 次进化时适宜度下降了不足 0.005。改进后的 IPSO 算法在前 60 次进化时都能保持较大的下降梯度，最终输出的粒子适宜度均值较改进前下降约 10%。通过对 PSO 算法的改进，BP 神经网络可以获得更优的输出精度。




图8 三种神经网络10次预测的误差均值和标准差




图9 两种粒子群算法粒子适宜度变化情况（样本数 $n=10$ ）

4 与传统评估方法的对比分析

国际上广泛采用 $SI^{[11]}$ 和 $SEV^{[12]}$ 方法评估和预测含沙水体对鱼类等水生动物的威胁程度^[28]。这两种方法将含沙量 (SSC) 和暴露时间 (ED) 作为关键因素，通过将影响程度进行分级，对行为影响、亚致死和致死效应做了深入研究。 SI 和 SEV 值分别为 $0\sim 14$ 之间的压力指数，当大于 10 时说明悬浮泥沙对鱼类有致死影响，处于 $10\sim 14$ 时分别对应于 $0\sim 20\%$ 、 $20\sim 40\%$ 、 $40\sim 60\%$ 、 $60\sim 80\%$ 和 $80\sim 100\%$ 的死亡率范围。两种方法的计算公式分别为：

$$SI = \ln(ED \times SSC) \quad (13)$$

$$SEV = a + b \times (\ln ED) + c \times (\ln SSC) \quad (14)$$

式中： ED 为鱼类在含沙水体中的暴露时间，h； SSC 为含沙量，mg/L； a 、 b 、 c 为回归系数。

Newcombe C P 等^[12]将鲑鱼、非鲑鱼和成鱼、幼鱼等不同类型、不同生长阶段的鱼种分为6组，利用以往文献样本数据分别进行了 SEV 值与 $\ln ED$ 、 $\ln SSC$ 二元回归拟合，即式(14)。其中，对于淡水成年非鲑鱼的一组，式(14)的回归系数拟合结果为： $a = 4.08$ ， $b = 0.71$ ， $c = 0.28$ 。采用该组系数的方程对表4中的验证数据计算 SEV 评估值，计算结果 (SEV 值 < 10) 与实验结果差异较大，说明该系数不适用于鲤科淡水鱼类急性影响的预测。Xu 等^[29]和 Tritthart 等^[30]指出了 SEV 方法预测值和观察值之间的差异，建议在当地使用该方法时应重新校准或调整模型。因此，使用实验数据重新率定了式(14)适用于花斑裸鲤 ($a = -113.00$ ， $b = 1.79$ ， $c = 10.89$) 和鲤鱼 ($a = -20.47$ ， $b = 1.01$ ， $c = 2.83$) 的 SEV 公式系数，并分别计算了表4中测试数据对应的死亡率。




图10 IPSO-BP神经网络和其他方法的预测误差对比

将基于IPSO-BP神经网络的鱼类致死影响预测结果与 SI 、 SEV 方法和四元拟合方程（见表3）计算结果进行比较，计算误差 ($RMSE$ 、 $MAPE$ 、 NSE) 如图10所示。 SI 方法和四元拟合方程的 $NSE < 0$ ， NSE 值反应了预测值和实测值重合程度，说明其预测值严重偏离实测值。而且 SI 方法的 $RMSE$ 和 $MAPE$ 值均为所有方法中最高，说明预测效果最差。采用实验数据重新率定参数的式(14)，其预测精度虽然相较于 SI 方法有所改善，但因未能考虑溶解氧、水温等因素对鱼类的影响，预测值和实测值差异较大。与IPSO-BP神经网络相比， SEV 方法的 $RMSE$ 和 $MAPE$ 值为神经网络的 $3\sim 5$ 倍，预测能力处于较低

的水平。综上分析, IPSO-BP 神经网络相比另外三种方法拥有更高的预测精度, 性能最佳, 可作为评估水库排沙对下游鱼类影响的可靠手段。

5 结论

本文建立了改进粒子群算法—反向传播(IPSO-BP)神经网络, 采用高含沙水体对鱼类影响的实验数据对其进行了训练和测试。使用训练后的 IPSO-BP 神经网络对高含沙水体中花斑裸鲤和鲤鱼的死亡率进行了预测, 与其他方法对比分析了预测精度。本文主要结论如下: (1) 本文使用了具有动态惯性权重、学习率和变异扰动的 IPSO 算法, 并将 IPSO 算法与 BP 神经网络耦合, 建立了基于 IPSO-BP 神经网络的高含沙水体对鱼类影响的预测方法。本文建立的 IPSO-BP 神经网络可以准确预测高含沙水体中花斑裸鲤和鲤鱼的死亡率, 预测误差处于 $\pm 6\%$ 以内, 相比 PSO-BP 和 BP 神经网络性能更优。(2) 对比 IPSO-BP 神经网络和传统多元拟合方程、SI 和 SEV 评估方法的评估预测能力, 本文提出的 IPSO-BP 神经网络能够综合考虑各种环境因子的非线性作用, 在预测精度上有了较大提升, 可为评估水库排沙的水生态影响提供新的方法。

参 考 文 献:

- [1] 白音包力皋, 许凤冉, 陈兴茹, 等. 小浪底水库排沙对下游鱼类的影响研究[J]. 水利学报, 2012, 43(10): 1146-1153.
- [2] 朱国清, 赵瑞亮, 胡振平, 等. 小浪底水库调水调沙对黄河中游鱼类及生态敏感区的影响[J]. 水生态学杂志, 2012, 33(5): 7-12.
- [3] 蒋晓辉, 赵卫华, 张文鸽. 小浪底水库运行对黄河鲤鱼栖息地的影响[J]. 生态学报, 2010, 30(18): 4940-4947.
- [4] 刘哲, 张宁, 彭定华, 等. 水生态监测方法研究进展及在黄河流域的应用实践[J]. 中国环境监测, 2022, 38(1): 58-71.
- [5] 白音包力皋, 陈兴茹. 水库排沙对下游河流鱼类影响研究进展[J]. 泥沙研究, 2012(1): 74-80.
- [6] SUEDEL B C, WILKENS J L, KENNEDY A J. Effects of suspended sediment on early life stages of smallmouth bass (*Micropterus dolomieu*) [J]. Archives of Environmental Contamination and Toxicology, 2016, 72(1): 1-13.
- [7] AFFANDI F A, ISHAK M Y. Impacts of suspended sediment and metal pollution from mining activities on riverine fish population—a review[J]. Environmental Science and Pollution Research, 2019, 26(17): 16939-16951.
- [8] PAUL K, DAVID S, ADRIAN C, et al. The impacts of fine sediment on riverine fish[J]. Hydrological Processes, 2011, 25(11): 1800-1821.
- [9] BERGSTEDT L C, BERGERSEN E P. Health and movements of fish in response to sediment sluicing in the Wind River, Wyoming[J]. Canadian Journal of Fisheries and Aquatic Sciences, 1997, 54(2): 312-319.
- [10] CROSA G, CASTELLI E, GENTILI G, et al. Effects of suspended sediments from reservoir flushing on fish and macroinvertebrates in an alpine stream[J]. Aquatic Sciences, 2010, 72(1): 85-95.
- [11] NEWCOMBE C P, MACDONALD D D. Effects of suspended sediments on aquatic ecosystems [J]. North American Journal of Fisheries Management, 1991, 11(1): 72-82.
- [12] NEWCOMBE C P, JENSEN J O T. Channel suspended sediment and fisheries: A synthesis for quantitative assessment of risk and impact[J]. North American Journal of Fisheries Management, 1996, 16(4): 693-727.
- [13] 刘彪, 赵宇飞, 陈祖煜, 等. 基于碾压波速的堆石坝压实质量实时监测指标的研究[J]. 中国水利水电科学研究院学报(中英文), 2022, 20(1): 20-29.
- [14] 武云飞, 吴翠珍. 青藏高原鱼类[M]. 成都: 四川科学技术出版社, 1991.
- [15] 胡鹏, 杨庆, 杨泽凡, 等. 水体中溶解氧含量与其物理影响因素的实验研究[J]. 水利学报, 2019, 50(6): 679-686.
- [16] 孙亚翥, 王涛, 路锦枝, 等. 基于 BP-DEMATEL 算法的冰情预报因子敏感性分析[J]. 水利学报, 2022, 53(9): 1083-1091.
- [17] 相鑫, 刘秀丽. 四层参数自调整 BP 神经网络模型及其在人口死亡率预测中的应用[J]. 系统科学与数学, 2018, 38(6): 702-710.

- [18] 刘媛媛, 刘业森, 郑敬伟, 等. BP 神经网络和数值模型相结合的城市内涝预测方法研究[J]. 水利学报, 2022, 53(3): 284-295.
- [19] 刘靖洁, 陈桂明, 刘小方, 等. BP 神经网络权重和阈值初始化方法研究[J]. 西南师范大学学报(自然科学版), 2010, 35(6): 137-141.
- [20] 张忠波, 何晓燕, 耿思敏, 等. 改进的粒子群算法在水库优化调度中应用[J]. 中国水利水电科学研究院学报, 2017, 15(5): 338-345.
- [21] 陈博文, 邹海. 总结性自适应变异的粒子群算法[J]. 计算机工程与应用, 2022, 58(8): 67-75.
- [22] 仝秋娟, 赵岂, 李萌. 基于自适应动态改变的粒子群优化算法[J]. 微电子学与计算机, 2019, 36(2): 6-10, 15.
- [23] 黄璇, 郭立红, 李姜, 等. 改进粒子群优化 BP 神经网络的目标威胁估计[J]. 吉林大学学报(工学版), 2017, 47(3): 996-1002.
- [24] 韩信, 张宝忠, 魏征, 等. 考虑气象因子不确定性的参考作物蒸散量预报方法[J]. 中国水利水电科学研究院学报, 2021, 19(1): 33-44.
- [25] 王维博, 林川, 郑永康. 粒子群算法中参数的实验与分析[J]. 西华大学学报(自然科学版), 2008(1): 76-80, 105-106.
- [26] 龙远, 邓小龙, 杨希祥, 等. 基于 PSO-BP 神经网络的平流层风场短期快速预测[J]. 北京航空航天大学学报, 2022, 48(10): 1970-1978.
- [27] 高昶霖, 宋燕利, 左洪洲, 等. 基于动态权重的自适应 PSO-BP 神经网络焊接缺陷成因诊断[J]. 焊接学报, 2022, 43(1): 98-106.
- [28] COURTICE G, BAUER B, CAHILL C, et al. A categorical assessment of dose-response dynamics for managing suspended sediment effects on salmonids[J]. Science of the Total Environment, 2020(807): 150844.
- [29] XU F, BAOLIGAO B, CHEN X, et al. Short informative title: Quantitative assessment of acute impacts of suspended sediment on carp in the Yellow River[J]. River Research and Applications, 2018, 34: 1298-1303.
- [30] TRITTHART M, HAIMANN M, HABERSACK H, et al. Spatio-temporal variability of suspended sediments in rivers and ecological implications of reservoir flushing operations[J]. River Research and Applications, 2019, 35: 918-931.

A prediction method for the impact of hyper-concentrated flow on fishes based on the IPSO-BP neural network

LI Xiaochen¹, Baiyinbaoligao¹, LI Xiangdong², XU Fengran¹, MU Xiangpeng¹, DONG Zhiqiang¹

(1. State Key Laboratory of Simulation and Regulation of Water Cycle in River Basin,

China Institute of Water Resources and Hydropower Research, Beijing 100038, China;

2. Qinghai Institute of Water Conservancy and Hydro-electric power Design Co., Ltd, Xining 810001, China)

Abstract: The hyper-concentrated flow process may cause negative impacts on fishes and other aquatic animals during reservoir sediment flushing. Nevertheless, there is a lack of studies on corresponding quantitative assessment methods for the degree of impact of the hyper-concentrated flow. In order to predict and evaluate the impact of reservoir sediment discharge processes on downstream fish, this paper uses experimental data from the study of survival characteristics of Yellow River *Gymnocypris Eckloni* and *Cyprinus Carpio* in hyper-concentrated flow and established an IPSO-BP neural network-based method for predicting the impact on fish mortality, and takes into account the effects of suspended sediment concentration, median particle size, dissolved oxygen, exposure time, water temperature, and other factors on fish survival. The prediction error of the target fish mortality is less than 6%. In this paper, the IPSO algorithm, which is closely coupled with BP neural network and introduces dynamic parameters and variational perturbations, has better prediction ability than BP and PSO-BP neural networks, and its accuracy is significantly improved when compared to existing Stress Index (SI), Severity of Ill Effect (SEV), and multivariate fitting evaluation methods at home and abroad. The analysis demonstrates that the prediction method proposed in this paper can account for the situation in which fish mortality in hyper-concentrated flow is governed by a combination of multiple environmental factors with complex correlations among multiple factors. This paper provides a new method for assessing the impact of hyper-concentrated flow on fishes.

Keywords: IPSO-BP neural network; hyper-concentrated flow; fish; mortality; prediction method

(责任编辑: 韩 昆)