

DOI: 10.3901/JME.2019.21.029

基于粒子群优化神经网络的水下链式机器人直航阻力预报*

康帅^{1,2,3} 俞建成^{1,2} 张进^{1,2} 金乾隆^{1,2,3} 胡峰^{1,2}

(1. 中国科学院沈阳自动化研究所机器人学国家重点实验室 沈阳 110016;

2. 中国科学院机器人与智能制造创新研究院 沈阳 110016;

3. 中国科学院大学 北京 100049)

摘要: 多单体水下机器人串联组成的水下链式机器人具有航行效率高、稳定性好、搭载能力强等优势,对其直航阻力的精确预报可实现更有效的运动控制和更合理的动力编组。针对由于水下链式机器人各单体间耦合关系复杂及使用计算流体力学分析阻力耗时较长导致无法快速准确进行阻力预报问题,开展了水下链式机器人直航阻力预报研究。利用计算流体力学分析获得大量输入量(单体数量、航速和单体间间距)与输出量(直航阻力)样本数据,使用BP神经网络建立输入量与输出量模型关系,并通过粒子群算法优化神经网络的初始权值和偏差以改善BP神经网络易陷入局部极值点和过拟合等问题。由大量测试样本的预报结果可知:基于粒子群优化的BP神经网络算法比传统BP神经网络算法预报结果更准确,在给定不同速度和间距测试中均方误差分别降低了 2.04×10^{-5} 和 7.40×10^{-6} ;在5单体水下链式机器人以 0.25 m/s^2 的加速度做匀加速运动过程中,基于粒子群优化的BP神经网络模型预报结果的平均相对误差为0.42%,精度较高。试验结果说明所提方法是可行且有效的。

关键词: 水下链式机器人;神经网络;粒子群算法;阻力预报

中图分类号: TP242

Direct Route Drag Prediction of Chain-structured Underwater Vehicle Based on Neural Network Optimized by Particle Swarm Optimization

KANG Shuai^{1,2,3} YU Jiancheng^{1,2} ZHANG Jin^{1,2} JIN Qianlong^{1,2,3} HU Feng^{1,2}

(1. State Key Laboratory of Robotics, Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016;

2. Institutes for Robotics and Intelligent Manufacturing, Chinese Academy of Sciences, Shenyang 110016;

3. China University of Chinese Academy of Sciences, Beijing 100049)

Abstract: The chain-structured underwater vehicle is composed of several autonomous underwater vehicles in series. It has advantages in terms of navigation efficiency, stability, and carrying capacity. The motion can be better controlled and the power can be better organized if its direct route drag can be predicted accurately. Aiming at the problem that the drag prediction of chain-structured underwater vehicle cannot be carried out quickly and accurately because of the complex coupling relationship among the units and the long time-consuming of computational fluid dynamics (CFD) analysis, the research on the direct route drag prediction carried out. A large number of input (number of units, velocity and spacing between units) and output (direct route drag) sample data are obtained by using CFD. BP neural network is used to establish the relationship between input and output. Particle swarm optimization is used to optimize the initial weights and biases of the neural network to improve the problem that BP neural network is easy to fall into local extreme points and over-fitting. The prediction results of a large number of test samples show that the BP neural network algorithm based on particle swarm optimization is more accurate than the traditional BP neural network algorithm, and the mean square error is reduced by 2.04×10^{-5} and 7.4×10^{-6} respectively in the tests of given different velocities and spacing. The average relative error of BP neural network model optimized by particle swarm optimization is 0.42% during the uniform acceleration of the 5-unit chain-structured underwater vehicle with an acceleration of 0.25 m/s^2 . The accuracy of prediction results is high. The

* 国家自然科学基金(U1709202)和机器人学国家重点实验室自主课题(2019-Z13)资助项目。20190102 收到初稿,20190401 收到修改稿

experimental results show that the proposed method is feasible and effective.

Key words : chain-structured underwater vehicle ; neural network ; particle swarm optimization ; drag prediction

0 前言

自主水下机器人 (Autonomous underwater vehicle, AUV) 是一种自身携带能源并自主航行的水下机器人, 能够独立完成海洋环境观测、海底地形勘察、资源探索等任务^[1]。由于单体水下机器人作业能力有限, 近年来水下机器人的作业方式发生了很大的改变, 集群智能化作业方式成为新需求^[2]。然而, 水下机器人携带能源有限, 各单体 AUV 克服所受阻力及使用传感器获取环境信息并进行群体间信息交互将消耗大量能源, 限制了作业时间, 尤其当到深远海作业时将面临更大挑战。此外, 单体分散独立的集群作业方式在某些任务中面临困难, 如需要搭载大尺寸声学线列阵声呐以实现更远、更精确探测时, 单体 AUV 由于受尺寸限制而无法实现高能力的目标探测。

本文创新性地提出将单体 AUV 串联组成水下链式机器人的新型作业平台, 该平台可同时具备高效航行和搭载较大尺寸载荷作业的能力, 可有效解决上述问题。水下链式机器人具有航行效率高、灵活、抗干扰能力强、搭载载荷能力强、模块化结构易增减单体等优点, 将在军民应用中发挥重要作用, 如对相对安静的可疑目标进行更精确探测和跟踪、作为水下运载器(水下动车)向深海空间站中运送物资等, 研究具有重要的理论意义和实际应用价值。为了实现稳定和高效航行, 需要对水下链式机器人进行有效控制, 因此对各单体的航行阻力进行精确预报具有重要意义。然而, 与陆地动车近似二维平面的直线运动不同, 水下链式机器人是刚柔混合的全新作业平台, 其运动在三维空间内进行, 轨迹多样, 且该类平台国内外未有相关报道。

水下链式机器人属于多体、动力分布式机器人^[3], 单体间耦合关系复杂, 给阻力预报带来挑战。研究发现, 其直航阻力除受载体自身尺寸、外形等因素影响外, 还与单体间距离、单体串联个数等结构参数及航行速度有着密切联系。但目前尚无模型可对水下链式机器人的直航阻力进行准确预估。BLOCKEN 等^[4]采用计算流体力学(Computational fluid dynamics, CFD)数值分析和风洞试验的方法对自行车赛中尾随在车手后面的摩托车对车手所受风阻的影响进行了研究, 阻力预报准确但耗时久, 且

对计算环境配置要求较高。TIAN 等^[5]利用误差反向传播神经网络(Back propagation neural network, BPNN)算法具有较强非线性逼近能力的特性, 结合 CFD 与 BP 神经网络方法对两个 AUV 进行了阻力预报和队形优化, 但由于神经网络中初始权值和偏差具有随机性^[6], 导致网络模型的每次阻力预报值均不一致, 甚至出现较大差异。粒子群优化方法(Particle swarm optimization, PSO)在多机器人系统中应用广泛, 在寻找全局最优问题中具有一定的优越性^[7]。针对神经网络算法中由于初始值的随机选取导致网络学习算法的求解结果出现局部极小值问题, 谢延敏等^[8]在解决高强钢扭曲回弹工艺参数优化问题时, 利用粒子群算法确定神经网络的初始权值和偏差后再进行训练, 有效地限制了局部极小值的出现, 获得了良好的扭曲回弹预报效果。

水下链式机器人直航阻力影响因素多且具有复杂的非线性特性, 对其直航阻力进行快速、准确的预报具有一定挑战性, 目前国内外还没有开展相关研究。本文利用神经网络可对非线性系统进行多输入-多输出关系拟合的特性及粒子群算法具有摆脱局部极值寻找全局最优的特性, 创新性地提出基于粒子群优化神经网络的算法来建立阻力预报模型以解决水下链式机器人直航阻力预报难的问题。该模型可以对不同参数下水下链式机器人航行过程中的各单体所受阻力进行精确预报, 并发掘链式结构实现最优航行效率的规律。

1 基于 CFD 的直航阻力计算

将单体 AUV 串联组成动力分布式的水下机器人称为水下链式机器人, 其在直线运动过程中所受的阻力称为直航阻力(包括整体及各单体所受阻力)。定义单体间间距为 X , 其取值为实际间距(L_0)占单体长度(L)的比值, 则 N 个单体 AUV 以 X 为间距串联便组成了串联间距为 X 的 N 单体水下链式机器人。图 1 为由 5 个单体 AUV 串联组成的 5 单体水下链式机器人。

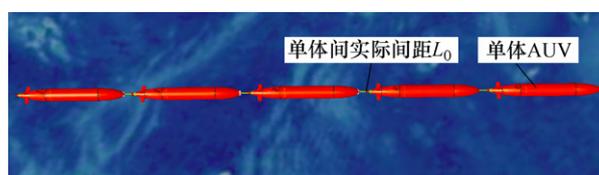


图 1 水下链式机器人

AUV 外形有多种不同形式,大致可以分为回转体形、立扁形、扁平形、多体形等,因回转体形的 AUV 航行阻力小,结构对称便于控制,所以回转体形自主水下机器人的数目居多^[9-10]。获得回转体直航阻力的方法主要有经验公式法、CFD 法和模型试验法。经验公式法计算精度无法满足实际应用需求,只能为设计者提供参考。模型试验法最为精确,但成本高,且受到试验设备精度和模型尺寸缩放影响,仍会存在一定误差^[11]。CFD 法利用计算机的快速计算能力得到流体控制方程的近似解,求解结果较经验公式更为准确,且耗时、成本远小于模型试验法,得到了广泛应用^[12]。为了精确分析不同因素对水下链式机器人直航阻力的影响,本文采用 CFD 法计算水下链式机器人在影响因素不同取值下的直航阻力,计算结果同时为建立神经网络阻力预报模型提供了所需样本。

1.1 水下链式机器人结构参数的设定

回转体形 AUV 在外形上也会存在一些差异。其船艏形状曲线一般由公式给出,并根据需要决定是否使用平行舢段。常用的船艏形状有 Myring 型^[13]、Nystrom 型^[14]、鱼雷型和水滴型等,通过改变这些艇型对应公式的参数值可获得不同的回转体形状。在所有形状中 Myring 型使用较多^[15],如著名的 REMUS^[16]和 MAYA^[17]都使用了该种形式。Myring 型的船部和艏部形状方程分别如下

$$r_f(x) = \frac{1}{2}D \left[1 - \left(\frac{x-a}{a} \right)^2 \right]^{\frac{1}{n}} \quad (1)$$

$$r_a(x) = \frac{1}{2}D - \left(\frac{3D}{2c^2} - \frac{\tan\theta}{c} \right) (x-a-b)^2 + \left(\frac{D}{c^3} - \frac{\tan\theta}{c^2} \right) (x-a-b)^3 \quad (2)$$

式中, a 为船部长度, b 为平行舢体长度, c 为艏部长度, D 为舢体直径, x 是长轴上点到船部顶点的距离, r 为 x 点处的半径, n 和 θ 分别是控制船艏曲线饱和程度的参数, n 和 θ 越大船艏越饱满^[15], L 为单体 AUV 的长度。图 2 给出了式(1)、(2)中各参数在单体 AUV 结构上的对应关系。

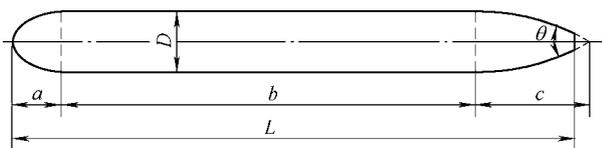


图 2 单体 AUV 外形结构

表 1 给出了本文设定的 AUV 结构参数。

表 1 AUV 结构参数表

参数	数值
直径 D/m	0.1
总体长度 L/m	0.9
船部长度 a/m	0.08
舢部长度 b/m	0.65
艏部长度 c/m	0.19
船部曲线饱和度 n	2
艏部曲线饱和度 $\theta/(^\circ)$	35

1.2 CFD 环境参数设置

水下机器人周围流场的分析预测基于不可压缩的“Navier-Stokes”控制方程,求解该控制方程的方法分为线性非粘性流方法、非线性非粘性流方法、平均雷诺数基础上的 N-S 方程方法和全 N-S 方程方法四类^[18]。这里采取平均雷诺数基础上的 N-S 方程方法。在选定控制方程后要确定湍流模型,这里选取工程计算中广泛应用的标准 $k-w$ 模型^[19]。

在分析水下链式机器人的周围流场之前需要确定计算域,为了减小回流对水下机器人的影响,选取直径为 $20D$ 、高度为 $(8+N)L$ 的圆柱区域作为计算域,如图 3 所示。水下链式机器人被放置在圆柱形计算域中心轴线上,其前端与边界距离为 $2L$,后端与边界距离为 $6L$ 。定义左侧边界为速度进口,右侧边界为压力出口,柱面边界为平滑壁面。

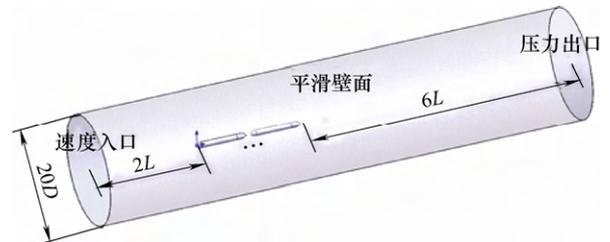


图 3 计算域设置

为使计算结果更加准确,本文水动力仿真算例中均采用六面体结构化网格对计算域进行划分。由于水下机器人的近壁及尾部流场复杂且具有更高的速度梯度^[5],因此在此处使用更高密度的网格和棱柱层,如图 4 所示,这里使用 6 层的棱柱层来改善边界层网格质量。在计算流体力学中, y^+ 是指第一层网格质心到壁面的无量纲距离,网格质量好的算例中一般取值在 30~60 之间^[11],本文所有算例的

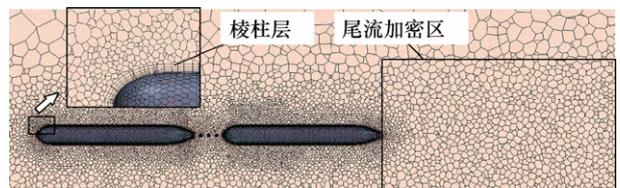


图 4 网格设置

$y+$ 值均在此范围内。同时,为了使相邻网格更平滑的过渡,网格延伸率设置为 1.3。

1.3 计算结果及分析

STAR-CCM+软件具有一体化集成环境、高重复性和适应性的特点,是新一代通用计算流体力学分析软件^[18]。本文使用 STAR-CCM+水动力分析软件来计算单体数量、单体间间距及航行速度不同取值下水下链式机器人的总直航阻力及各单体分别所受阻力。其中,单体数量 N 取值为 1, 2, 3, 4 或 5; 单体间间距 X 取值为 10%, 15%, 20%, 25%, 30%, 35%, 40%, 45% 或 50%; 航行速度 v (单位为 m/s) 取值为 0.50, 0.75, 1.00, 1.25, 1.50, 1.75 或 2.00。表 2 为影响因素不同取值下通过 CFD 计算得出的水下链式机器人直航阻力。表 3 为影响因素不同取值

下的 5 单体水下链式机器人各单体所受阻力。

表 2 影响因素不同取值下的水下链式机器人直航阻力

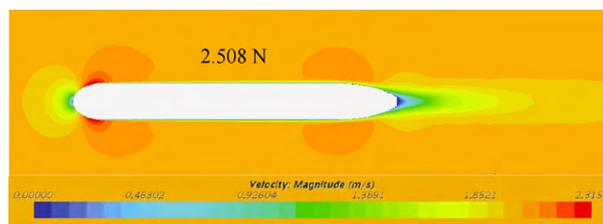
样本	单体数 N	间距 X	航速 v /(m/s)	直航阻力 F/N
(1)	1	0.10	0.50	0.2017
(2)	2	0.10	0.50	0.3592
(3)	3	0.10	0.50	0.5074
(4)	4	0.10	0.50	0.6487
(5)	5	0.10	0.50	0.7850
⋮	⋮	⋮	⋮	⋮
(311)	1	0.50	2.00	2.5080
(312)	2	0.50	2.00	4.6773
(313)	3	0.50	2.00	6.5266
(314)	4	0.50	2.00	8.6451
(315)	5	0.50	2.00	10.6147

表 3 影响因素不同取值下的 5 单体水下链式机器人各单体所受阻力

样本	单体数 N	间距 X	航速 v /(m/s)	单体 1 阻力 F_1/N	单体 2 阻力 F_2/N	单体 3 阻力 F_3/N	单体 4 阻力 F_4/N	单体 5 阻力 F_5/N
(1)	5	0.10	0.50	0.1396	0.1636	0.1498	0.1429	0.1891
(2)	5	0.15	0.50	0.1666	0.1592	0.1489	0.1429	0.1717
(3)	5	0.20	0.50	0.1782	0.1602	0.1493	0.1447	0.1632
(4)	5	0.25	0.50	0.1852	0.1624	0.1500	0.1447	0.1575
(5)	5	0.30	0.50	0.1894	0.1634	0.1498	0.1445	0.1538
(6)	5	0.35	0.50	0.1936	0.1660	0.1511	0.1441	0.1499
(7)	5	0.40	0.50	0.1944	0.1662	0.1505	0.1441	0.1486
(8)	5	0.45	0.50	0.1955	0.1681	0.1516	0.1440	0.1457
(9)	5	0.50	0.50	0.1967	0.1698	0.1536	0.1577	0.1413
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
(56)	5	0.15	2.00	1.9456	2.0959	1.9703	1.8976	2.3777
(57)	5	0.20	2.00	2.1446	2.1014	1.9947	1.9177	2.2036
(58)	5	0.25	2.00	2.2538	2.1151	1.9982	1.9141	2.0984
(59)	5	0.30	2.00	2.3228	2.1220	2.0006	1.9369	2.0573
(60)	5	0.35	2.00	2.3707	2.1344	1.9984	1.9366	2.0146
(61)	5	0.40	2.00	2.3998	2.1449	2.0043	1.9203	1.9753
(62)	5	0.45	2.00	2.4172	2.1501	2.0096	1.9325	1.9523
(63)	5	0.50	2.00	2.4354	2.1641	2.0184	2.0862	1.9106

由表 2 和表 3 可知,在同等航速下,水下链式机器人中各单体所受阻力比独立单体 AUV 航行所受阻力更小,各单体均获得了不同程度的减阻效果。如当航速 $v=2$ m/s、间距 $X=0.2$ 时,5 单体水下链式机器人各单体所受阻力分别为 2.145 N, 2.101 N, 1.995 N, 1.918 N 和 2.204 N,约为独立单体 AUV 直航阻力(2.508 N)的 86%, 84%, 80%, 76% 和 88%,前 4 个单体所受阻力逐渐减低,尤其是第 2~4 单体在前面单体行进后的尾流中受益更多,减阻效果明显,而第 1 个和第 5 个单体由于其艏部和艉部区域水体流速差更大,比处于中间的单体所受阻力略大。上述结果说明, N 单体水下链式机器人在直航状态下相比于 N 个 AUV 独立单体拥有更高的航行效率和更好的续航能力。航速为 2 m/s 时独立单体 AUV

水动力分析速度云图如图 5a 所示,5 单体水下链式机器人水动力分析速度云图如图 5b 所示。



(a) 独立单体 AUV 速度云图



(b) 5 单体水下链式机器人速度云图

图 5 独立单体 AUV 与 5 单体水下链式机器人速度云图

水下链式机器人直航阻力与航速、单体个数、单体间间距和单体 AUV 外形等多种因素有关。其在航行过程中所受阻力包括摩擦阻力和粘性压差阻力。其中，摩擦阻力与湿表面积和航速的平方成正比，粘性压差阻力与航速和型体外形有关^[20]。航速 v 在 0.5 ~ 2.0 m/s 的范围内取值时，水下链式机器人摩擦阻力占比约为 80%，粘性压差阻力占比约为 20%。在航速一定时，随着单体个数的增加，水下链式机器人湿表面积随之线性增加，同时从前方单体尾流中受益的各单体所受阻力逐渐降低，因此整体直航阻力随单体个数的增加而非线性增加。当单体数量和间距一定时，随着航速的增加，水下链式机器人所受摩擦阻力与粘性压差阻力均会增加，因此直航阻力与航速同样成正相关。而当航速和单体数量一定时，水下链式机器人直航阻力与单体间间距成非线性、非正相关，以 5 单体水下链式机器人在航速为 1.75 m/s 时的直航阻力为例，间距 X 为 0.20 时阻力最小，间距 X 在 0.10 和 0.35 处阻力相近，如图 6 所示。一定数量的水下链式机器人以恒速航行时，合理的间距有利于减小自身航行阻力、提高整体航行效率，而水下链式机器人阻力预报模型的建立将会为单体间间距优化提供理论依据。

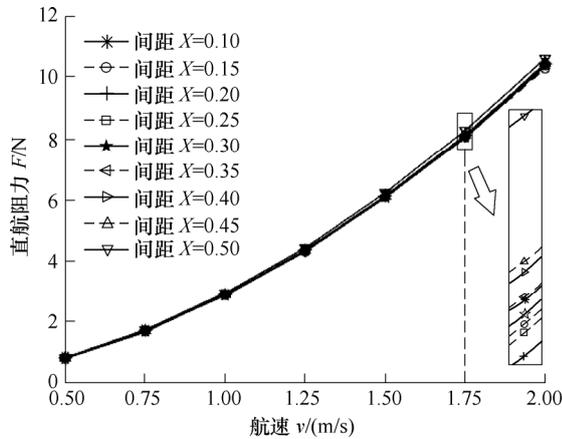


图 6 5 单体水下链式机器人直航阻力 F 与航速 v 和单体间间距 X 的关系图

2 直航阻力预报模型建立

对于水下链式机器人的直航阻力预报，CFD 方法虽然计算准确，但当单一或多个影响因素发生变化时，需要在水动力仿真软件中更新模型、计算域和网格后重新求解，步骤繁琐，难以快速得到预报结果。水下链式机器人相对单体 AUV 结构更为复杂，非线性特性明显，较难建立精确的水动力方程来预报阻力，可使用神经网络对该系统建模的方法

来实现水下链式机器人的阻力预报。

2.1 BP 神经网络

BP 神经网络是一种根据误差反向传播算法进行训练的多层全连接前馈型人工神经网络，是一种结构简单的有监督神经网络训练算法，具有较强非线性逼近能力，且具有自学习和自适应能力^[21-22]。可将 STAR-CCM+水动力软件分析出的 315 组数据作为样本，以单体数量、航行速度和单体间间距作为模型输入量，以水下链式机器人直航阻力或各单体阻力作为模型输出量，通过误差反向传播算法计算神经元连接权重，建立能够表达输入-输出关系的最优化神经网络模型。

设定神经网络结构具有 n 个输入节点， l 个隐层节点和 m 个输出节点，网络拓扑结构如图 7 所示。含有一个隐含层并使用连续型激活函数的 BP 神经网络理论上可逼近任意非线性连续函数^[21]，这里设定网络结构包含 1 个隐含层。由样本数据确定的输入层节点个数 $n=3$ (包括单体数量 N 、航速 v 和单体间间距 X)，输出层节点个数 $m=1$ (整体所受阻力 F) 或 N (包括各单体所受阻力 F_k)，设定隐含层节点数 $l=10$ 。隐含层采用 S 型激活函数 tansig ，输出层采用线性激活函数 purlin ，网络学习算法采用 trainlm ^[23]。

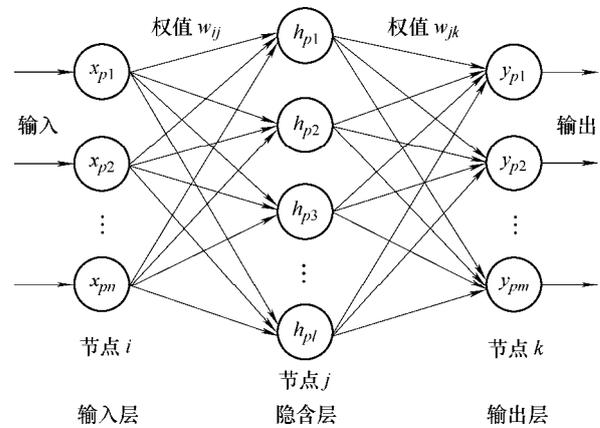


图 7 BP 神经网络拓扑结构

BP 神经网络的具体训练步骤如下。

(1) 根据训练样本确定输入层和输出层。网络的输入层 X_p 、隐含层 H_p 和输出层 Y_p 可用以下矩阵表示

$$\begin{aligned}
 X_p &= (x_{p1}, x_{p2}, \dots, x_{pm}) \\
 H_p &= (h_{p1}, h_{p2}, \dots, h_{pl}) \\
 Y_p &= (y_{p1}, y_{p2}, \dots, y_{pm})
 \end{aligned}
 \tag{3}$$

式中， n ， l 和 m 分别表示输入层，隐含层和输出层神经元的个数， p 表示训练样本。

(2) 初始化输入层与隐含层神经元连接权值 w_{ij} 、隐含层偏差 a_j 、隐含层与输出层权值神经元连

接 w_{jk} 、输出层偏差 b_k 。

(3) 隐含层输出为

$$h_{pj} = f_1 \left(\sum_{i=1}^n w_{ij} x_{pi} - a_j \right) \quad j=1,2,\dots,l \quad (4)$$

式中, f_1 为隐含层激活函数。

(4) 网络预测输出为

$$\hat{y}_{pk} = f_2 \left(\sum_{j=1}^l w_{jk} h_{pj} - b_k \right) \quad k=1,2,\dots,m \quad (5)$$

式中, f_2 为输出层激活函数。

(5) 模型预测误差为

$$e_k = y_{pk} - \hat{y}_{pk} \quad (6)$$

(6) 目标函数为预测输出的均方误差^[24]

$$MSE = \frac{1}{mp} \sum_{p=1}^p \sum_{k=1}^m (y_{pk} - \hat{y}_{pk})^2 \quad (7)$$

(7) 当目标函数 MSE 小于设定值 E_1 ; 迭代次数达到设定值 E_2 ; 下降梯度小于设定值 E_3 时, 网络迭代停止。如果未达到上述条件之一, 则使用网络学习算法更新权值和偏差并返回步骤(3), 直至达到迭代停止条件。

(8) 完成整个训练过程后即可确定最优权值和偏差, 建立输入-输出函数关系

$$Y_p = f_2 \left\{ W_2^T \left[f_1 \left(W_1^T X_p + B_1 \right) \right] + B_2 \right\} \quad (8)$$

式中, W_1^T 、 W_2^T 分别为 w_{ij} 、 w_{jk} 组成的矩阵; B_1 、 B_2 分别为 a_j 、 b_k 组成的矢量。经过神经网络模型的训练, 可以得出在 $v \in (0.50, 2.00)$ 、 $X \in (0.10, 0.50)$ 、 $N \in \{1, 2, 3, 4, 5\}$ 范围内水下机器人模型预测直航阻力及各单体所受阻力。

2.2 基于粒子群优化的 BP 神经网络算法

BP 神经网络通过对大量的样本 (X, Y) 进行训练, 经过网络自适应算法不断调整权值 (W_1, W_2) 和偏差 (B_1, B_2) , 使目标函数均方误差 MSE(式(7))最小来建立输入-输出关系, 易陷入局部极值点是其固有缺陷, 主要原因是在整个训练过程中没有引入任何额外的参数, 只是根据训练样本对初始权值和偏差进行调整。权值和偏差的初始值会影响整个算法的性能^[25], 如果随机选取, 求解过程中一旦均方误差 MSE 陷入局部极值点, 训练得出的权值和偏差并非最优值, 进而导致网络训练结果不准确。

粒子群是从生物种群行为特性中得到启发并用于求解优化问题的算法, 具有摆脱局部极值、求解全局最优能力强的优点^[26]。在粒子群算法中, 目标函数被称为适应度函数, 搜索空间中的每个粒子均

有一个由适应度函数确定的适应度值, 且每个粒子具有位置和速度的特征, 粒子通过比较个体最优适应度值和全局最优适应度值进行对位置和速度的更新, 最终收敛于适应度函数的最优值, 即实现了使目标函数最优的求解^[8]。

基于粒子群优化 BP 神经网络算法的本质是将神经网络中的权值和偏差看作粒子群中的粒子, 将神经网络中的目标函数作为粒子群算法的适应度函数, 利用摆脱局部极值、寻找全局最优能力强的特性, 计算出使得适应度函数值最优的粒子, 并将其作为神经网络初始权值和偏差, 再通过神经网络训练得出最优权值和偏差, 最终更准确地建立输入-输出函数关系。具体过程如下。

(1) 确定粒子和适应度函数。将神经网络中权值 $(w_{ij}$ 、 $w_{jk})$ 和偏差 $(a_j$ 、 $b_k)$ 作为粒子群算法中的粒子; 将神经网络中的目标函数(即均方误差)作为粒子群算法的适应度函数, 求解适应度函数的最小值为优化目标。

(2) 初始化粒子群。设定最大迭代次数为 E_0 , 粒子数为 t 。在搜索空间内随确定 t 个粒子的初始速度和位置。即随机确定 t 组权值 w_{ij} 、 w_{jk} 和偏差 a_j 、 b_k 的初始速度和位置, 分别为 $(w_{ij_1}, w_{ij_2}, \dots, w_{ij_t})$ 、 $(w_{jk_1}, w_{jk_2}, \dots, w_{jk_t})$ 、 $(a_{j_1}, a_{j_2}, \dots, a_{j_t})$ 和 $(b_{k_1}, b_{k_2}, \dots, b_{k_t})$, 设其中第 r 组为 w_{ij_r} 、 w_{jk_r} 、 a_{j_r} 和 b_{k_r} 。

(3) 计算个体粒子的最优适应度值。将粒子的当前适应度值与其历史最优适应度值进行比较, 若当前适应度值更优, 则该值成为新的个体历史最优适应度值。即计算每组初始权值和偏差的均方误差

$$MSE_r = \frac{1}{mp} \sum_{p=1}^p \sum_{k=1}^m (y_{pk_r} - \hat{y}_{pk_r})^2$$

$$\hat{y}_{pk_r} = f_2 \left(\sum_{j=1}^l w_{jk_r} f_1 \left(\sum_{i=1}^n w_{ij_r} x_{pi} - a_{j_r} \right) - b_{k_r} \right) \quad (9)$$

由第 r 组权值和偏差计算的当前均方误差 MSE_r 值与该组权值和偏差计算的个体历史最小均方误差 $MSE_{r_{\min}}$ 比较, 若当前均方误差 MSE_r 值更小, 则该值成为新的个体历史最小均方误差 $MSE_{r_{\min}}$ 。

(4) 计算全局粒子的最优适应度值。经过所有 t 个粒子最优适应度值的相互比较确定全局最优粒子和最优适应度。即比较所有 t 组权值和偏差计算的均方误差, 其中的最小值为本次迭代的全局最小均方误差 $MSE_{G_{\min}}$ 。

(5) 如果未达到最大迭代次数, 则根据下列公式进行粒子(权值和偏差)速度和位置的更新并返回步骤(3)。

$$V_r(s+1) = \sigma V_r(s) + c_1 \mu_1 (P_r(s) - X_r(s)) +$$

$$c_2\mu_2(P_G(s) - X_r(s)) \quad (10)$$

$$X_r(s+1) = X_r(s) + V_r(s+1) \quad (11)$$

$$\sigma = (1 - s / E_0)\sigma_{\max} + (s / E_0)\sigma_{\min} \quad (12)$$

式中, c_1 、 c_2 为学习因子, 这里取 $c_1=c_2=2$; μ_1 、 μ_2 为 $[0, 1]$ 之间随机数; σ 为惯性权重, 其中 $\sigma_{\max}=0.9$, $\sigma_{\min}=0.4$; V_r 、 X_r 为第 r 组粒子(权值和偏差)的速度和位置; P_r 、 P_G 分别为个体历史最佳位置和全局最佳位置; s 为迭代次数。

(6) 为了加速目标函数收敛, 每个粒子具备一定的速度, 且受设定的粒子个数和迭代次数限制, 经过粒子群算法 E_0 次迭代后的结果 $MSE_{G_{\min}}$ 仅为全局近似最优解, 但算法求取全局最优的特性使得该近似解在全局绝对最优解邻域内。利用神经网络非线性拟合和求解局部极值的优越性, 将 $MSE_{G_{\min}}$ 对应的权值和偏差作为网络的初始权值和偏差再进行训练, 得出满足精度要求的全局最优解, 进而更准确地建立输入-输出关系。

算法流程图如图 8 所示。

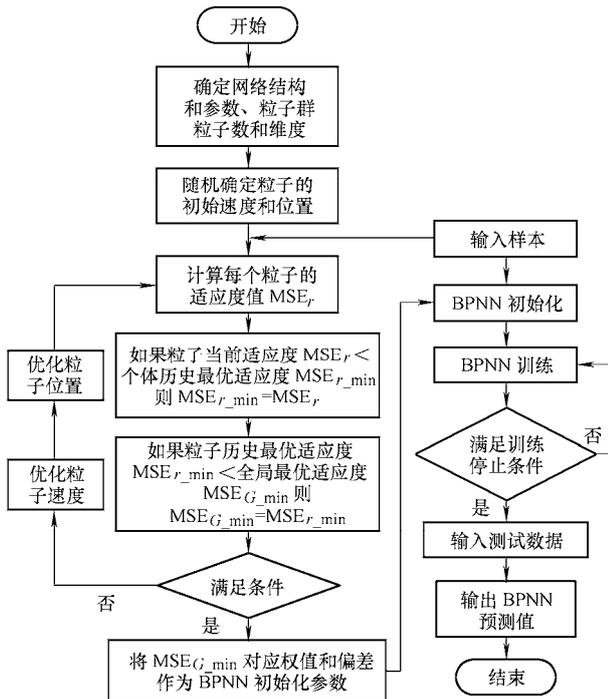


图 8 粒子群优化 BPNN 算法流程图

3 试验验证

为了说明基于粒子群优化的神经网络方法在预报准确度、摆脱局部极值和防止过拟合方面的优越性, 将其与传统 BP 神经网络方法进行了试验对比。在两种方法的模型建立和测试过程中, 使用了分组交叉验证法以增加评判的合理性与客观性。令表 2

中 315 组样本的 5/7 为训练集, 1/7 为验证集, 其余 1/7 为测试集。首先对试验过程中的训练集、验证集和测试集的均方误差进行记录, 待训练完成、建立输入-输出函数关系后, 选取测试样本对两种方法的准确性进行比较, 即分别计算和比较测试样本和模型预测输出的相对误差(Relative error, RE)和均方误差。为了更直观地对比两种算法的预报性能, 采用控制变量的方式, 分别选取 5 单体水下链式机器人在定速变间距和定间距变速两组数据作为测试样本进行验证。同时为了说明基于粒子群优化的神经网络阻力预报模型在实际中的有效性, 使用该模型对加速度为 0.25 m/s^2 的运动过程中水下链式机器人的直航阻力进行预报, 并与由 CFD 方法计算值作比较以分析预报结果的精度。训练试验环境为 PC-10G4S04E00, 处理器为 Intel(R) Core(TM) i7-6700 CPU @ 3.40GHz (8 CPUs), 神经网络迭代停止条件中各设定值分别为 $E_1=10^{-4}$, $E_2=10^4$, $E_3=10^{-7}$, 粒子群算法中最大迭代次数 $E_0=4000$, 粒子数 $t=1000$ 。

3.1 变间距数据组为测试样本时模型预报结果对比

变间距数据组为测试样本时, 测试样本输入为水下链式机器人单体数 $N=5$ 、航速 $v=1.5 \text{ m/s}$, 间距 $X \in \{0.10, 0.15, 0.20, 0.25, 0.30, 0.35, 0.40, 0.45, 0.50\}$; 测试样本输出为对应样本输入条件下由 STAR-CCM+软件计算得出的阻力。表 4 为 5 单体水下链式机器人在航速为 1.5 m/s 时传统 BPNN 算法与 PSO-BPNN 算法的直航阻力预报结果对比。由该表可知, 在测试样本处粒子群优化 BP 神经网络模型预报结果的均方误差(1.80×10^{-6})比传统神经网络模型预报的均方误差(9.20×10^{-6})更小, 预报结果更准确。5 单体水下链式机器人在航速为 1.5 m/s 时, 两种算法直航阻力预报值 F 与间距 X 的关系曲线如图 9 所示。传统神经网络在 Matlab 工具箱中采用的

表 4 变间距数据组为测试样本时传统 BPNN 模型和粒子群优化的 BPNN 模型阻力预报对比

间距	CFD		传统 BPNN		PSO-BPNN	
	计算值 /N	预测值 /N	相对误差(%)	预测值 /N	相对误差(%)	
0.10	6.123 4	6.087 6	0.58	6.113 0	0.17	
0.15	6.080 6	6.050 1	0.50	6.076 8	0.06	
0.20	6.061 8	6.048 8	0.21	6.071 2	0.15	
0.25	6.065 9	6.070 5	0.08	6.076 6	0.18	
0.30	6.082 2	6.086 2	0.07	6.086 1	0.06	
0.35	6.105 4	6.086 7	0.31	6.097 1	0.14	
0.40	6.119 1	6.102 7	0.27	6.108 6	0.17	
0.45	6.123 1	6.117 7	0.09	6.120 6	0.04	
0.50	6.225 3	6.220 8	0.07	6.216 3	0.14	
均方误差	0.000 009 201		0.000 001 799			

初始化方法为随机取数^[6], 训练过程中目标函数求解易陷入局部极值或出现过拟合的情况, 如图 10 所示, 而基于粒子群优化的神经网络算法在训练中极少出现此情况, 证明了后者在摆脱极值和防止过拟合方面的优越性。

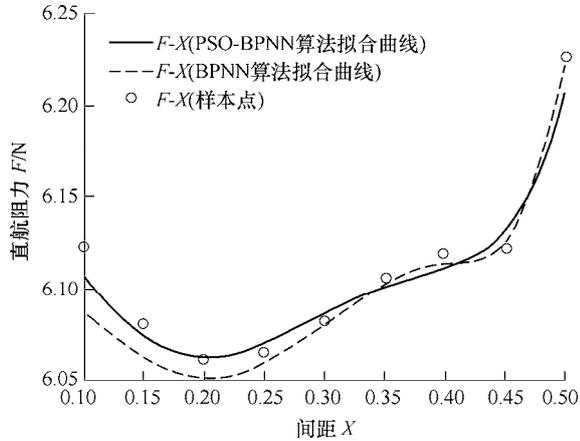


图 9 5 单体水下链式机器人在航速为 1.5 m/s 时, 两种算法直航阻力预报值 F 与间距 X 的关系曲线

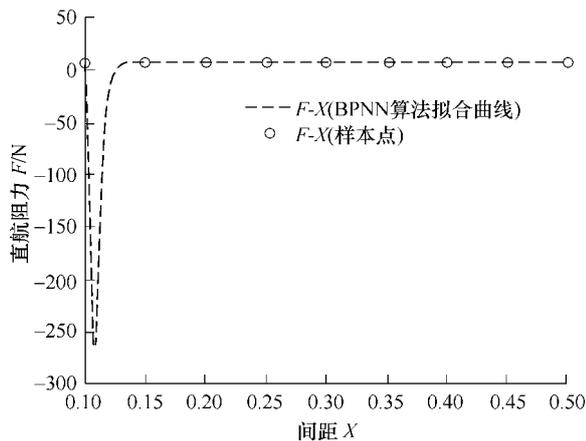


图 10 5 单体水下链式机器人在航速为 1.5 m/s 时, 传统神经网络算法直航阻力预报结果中出现的过拟合情况

3.2 变速数据组为测试样本时模型预报结果对比

变速数据组为测试样本时, 测试样本输入为水下链式机器人单体数量 $N=5$, 间距 $X=0.15$, 航速 $v \in \{0.50, 0.75, 1.00, 1.25, 1.50, 1.75, 2.00\}$; 测试样本输出为对应样本输入条件下由 STAR-CCM+ 软件计算得出的直航阻力。表 5 为 5 单体水下链式机器人在间距为单体 AUV 长度 15% 时传统 BPNN 算法与 PSO-BPNN 算法的直航阻力预报结果对比。由该表可知, 在测试样本处粒子群优化 BP 神经网络模型预报结果的均方误差 (1.32×10^{-5}) 比传统神经网络模型预报的均方误差 (3.36×10^{-5}) 更小, 预报结果更准确。5 单体水下链式机器人在间距 X 为 0.15 时, 两种算法直航阻力预报值 F 与航速 v 的关系曲线如图 11 所示。

表 5 变速数据组为测试样本时传统 BPNN 模型和 PSO 优化的 BPNN 模型阻力预报对比

航速 v / (m/s)	传统 BPNN		PSO-BPNN		
	计算值 /N	预测值 /N	相对误差 (%)	预测值 /N	相对误差 (%)
0.50	0.789 3	0.798 0	1.10	0.787 5	0.23
0.75	1.681 7	1.679 8	0.11	1.686 3	0.27
1.00	2.875 5	2.863 6	0.41	2.864 7	0.37
1.25	4.304 8	4.342 3	0.87	4.324 6	0.46
1.50	6.080 6	6.082 4	0.03	6.076 8	0.06
1.75	8.072 0	8.072 4	0.01	8.039 4	0.40
2.00	10.287 1	10.333 3	0.45	10.342 0	0.53
均方误差		0.000 033 646		0.000 013 244	

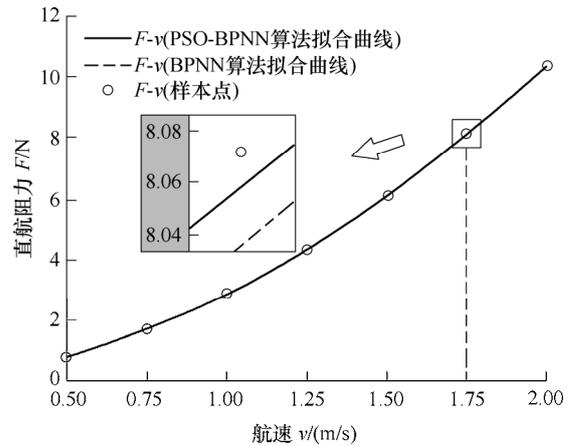
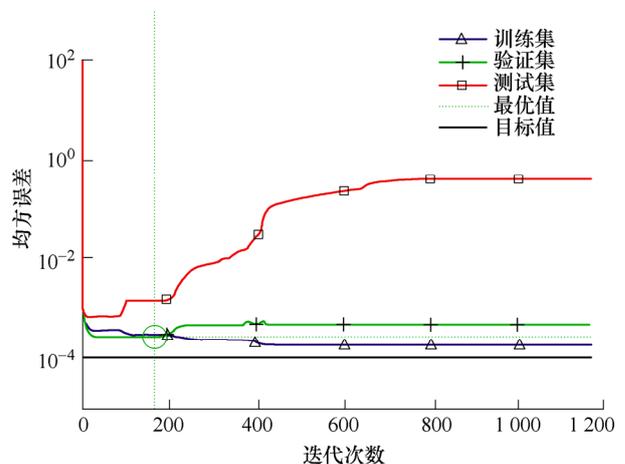
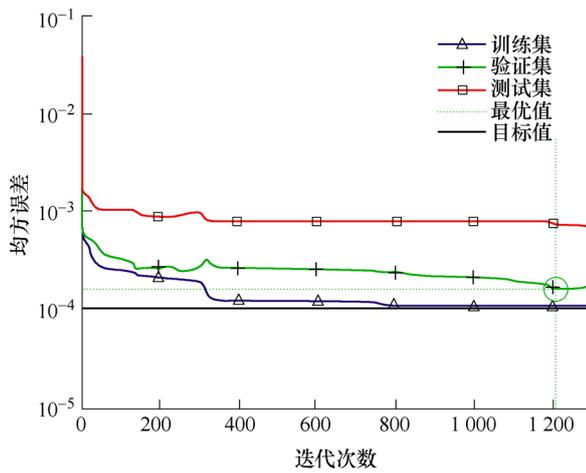


图 11 5 单体水下链式机器人在间距 $X=0.15$ 时, 两种算法直航阻力预报值 F 与航速 v 的关系曲线

在使用两种方法训练过程中, 训练集、验证集和测试集均方误差曲线如图 12 所示。其中测试集用于衡量模型的性能, 其均方误差越小说明模型训练结果越好, 预报结果越准确; 训练集用于建立模型, 其均方误差越小说明在训练样本处越精确; 验证集用于控制模型复杂程度; 最优值为目标函数 MSE 的历史最小值; 目标值为目标函数 MSE 的迭代停止界限值即 E_1 。基于粒子群优化的神经网络模型的初



(a) 传统神经网络模型均方误差曲线



(b) 基于粒子群优化的神经网络模型均方误差距离曲线

图 12 训练过程中的均方误差曲线

始权值和偏差是由粒子群算法优化确定的，初始均方误差为 10^{-1} 数量级，小于传统神经网络模型初始均方误差的 10^2 数量级，加快了收敛速度，同时减小了陷入局部极值和出现过拟合的概率。基于粒子群优化的神经网络模型测试集均方误差最终收敛接

近 10^{-3} 数量级，而传统神经网络模型测试集均方误差最终收敛更接近 10^{-1} 数量级，进一步说明前者预报结果更准确。

3.3 粒子群优化神经网络模型在加速运动过程中的直航阻力预报结果

在 5 单体水下链式机器人以 0.25 m/s^2 的加速度做匀加速运动过程中，选取水下链式机器人单体数量 $N=5$ ，航速 $v=\{0.60,0.85,1.10,1.35,1.60\}$ 和间距 $X=0.18$ 为测试样本输入；在对应条件下由 STAR-CCM+ 软件计算得出的直航阻力为测试样本输出。使用该模型对训练样本进行反复训练，得出模型对测试样本的 4 次预报结果如表 6 所示。由该表可知，基于粒子群优化的神经网络模型在测试样本处的预报结果平均相对误差为 0.42%，预报精度较高。在匀加速运动过程中，基于粒子群优化的神经网络模型对水下链式机器人各单体的阻力预报结果如图 13 所示。运动过程的预报结果为水下链式机器人在加速过程中的稳定控制提供了参考，缓解了单体间由于动力分配不合理而产生的过拉与过挤问题。

表 6 基于 PSO 优化的 BPNN 模型对测试样本的预报结果

	航速	单体 1 阻力	相对误差	单体 2 阻力	相对误差	单体 3 阻力	相对误差	单体 4 阻力	相对误差	单体 5 阻力	相对误差
	$v/(\text{m/s})$	F_1/N	RE(%)	F_2/N	RE(%)	F_3/N	RE(%)	F_4/N	RE(%)	F_5/N	RE(%)
CFD	0.60	0.240 6		0.224 8		0.209 9		0.202 2		0.233 7	
	0.85	0.448 1		0.424 7		0.398 4		0.387 8		0.452 3	
	1.10	0.710 5		0.684 4		0.643 8		0.626 6		0.734 0	
	1.35	1.027 1		1.010 0		0.953 4		0.924 7		1.081 0	
	1.60	1.396 1		1.386 4		1.308 9		1.258 6		1.484 0	
训练 1	0.60	0.244 7	0.41	0.229 5	0.47	0.216 0	0.61	0.211 4	0.91	0.251 9	1.82
	0.85	0.446 2	0.18	0.430 2	0.56	0.406 4	0.80	0.396 5	0.87	0.466 0	1.36
	1.10	0.702 8	0.77	0.687 8	0.33	0.649 7	0.59	0.631 8	0.52	0.739 2	0.52
	1.35	1.018 2	0.89	1.008 3	0.17	0.951 2	0.22	0.922 0	0.27	1.078 3	0.27
	1.60	1.389 2	0.69	1.392 7	0.63	1.311 1	0.21	1.266 4	0.78	1.485 2	0.12
训练 2	0.60	0.239 7	0.09	0.231 0	0.63	0.214 6	0.47	0.207 7	0.54	0.243 2	0.95
	0.85	0.450 3	0.22	0.428 8	0.42	0.403 8	0.54	0.391 6	0.38	0.458 9	0.66
	1.10	0.709 3	0.12	0.686 0	0.16	0.646 8	0.30	0.626 2	0.05	0.735 3	0.13
	1.35	1.022 7	0.43	1.008 3	0.17	0.949 7	0.36	0.917 4	0.73	1.079 6	0.14
	1.60	1.392 4	0.37	1.392 6	0.62	1.311 3	0.24	1.265 0	0.64	1.493 2	0.92
训练 3	0.60	0.244 3	0.37	0.228 5	0.37	0.212 1	0.21	0.203 3	0.11	0.235 8	0.21
	0.85	0.449 1	0.10	0.434 6	0.99	0.404 8	0.63	0.389 2	0.14	0.448 1	0.42
	1.10	0.708 4	0.21	0.687 0	0.26	0.648 0	0.42	0.627 3	0.07	0.735 0	0.10
	1.35	1.020 9	0.62	1.003 6	0.64	0.948 8	0.46	0.918 0	0.67	1.081 1	0.01
	1.60	1.385 0	1.11	1.391 6	0.53	1.310 3	0.13	1.261 1	0.25	1.479 2	0.48
训练 4	0.60	0.239 6	0.10	0.229 7	0.49	0.208 7	0.12	0.205 1	0.29	0.239 6	0.59
	0.85	0.449 9	0.18	0.427 6	0.29	0.399 9	0.15	0.388 7	0.09	0.455 5	0.32
	1.10	0.712 6	0.21	0.683 6	0.08	0.645 5	0.17	0.626 2	0.04	0.735 3	0.13
	1.35	1.027 5	0.04	1.001 4	0.86	0.947 4	0.60	0.919 1	0.56	1.080 8	0.02
	1.60	1.392 3	0.38	1.381 0	0.54	1.306 0	0.29	1.263 8	0.52	1.486 4	0.24

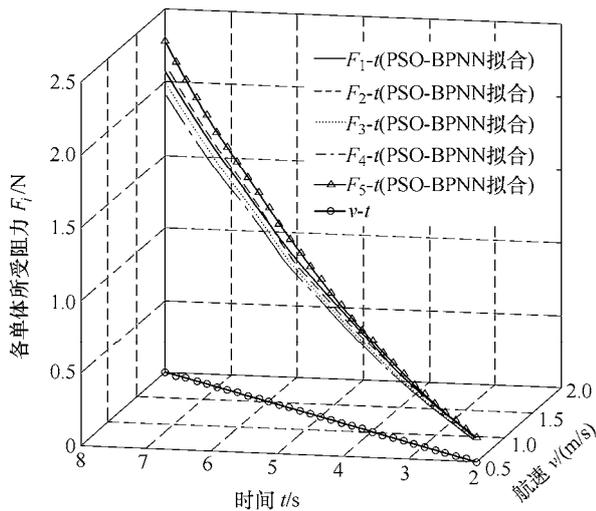


图 13 在动态加速过程中基于粒子群优化的神经网络模型对水下链式机器人各单体的阻力预报结果

4 结论

(1) 通过 CFD 方法对不同影响因素(单体数量、单体间间距和航速)取值下的水下链式机器人直航阻力进行计算分析可知,水下链式机器人的直航阻力随不同的影响因素呈现出明显的非线性特性。

(2) 提出采用粒子群算法确定 BP 神经网络中的初始权值和偏差,改善了 BP 神经网络算法在训练过程中易陷入局部极值和过拟合的问题。

(3) 提出的基于粒子群优化的神经网络模型准确地对水下链式机器人直航阻力进行了预报,说明了该算法的可行性和有效性,解决了水下链式机器人直航阻力实时预报难、精度预报低的问题。此预报模型的建立不仅为能源与动力的合理分配以实现高效持久的作业提供参考,也为水下链式机器人的结构优化设计与非全动力下的动力分布式控制提供理论基础。

此外,本课题组将开展水下链式机器人调整航行方向时的非直航阻力预报工作,以实现对其在不同航向姿态下的精确、快速的阻力预报。

参 考 文 献

[1] 李一平,李硕,张艾群. 自主/遥控水下机器人研究现状[J]. 工程研究, 2016, 8(2): 217-222.
LI Yiping, LI Shuo, ZHANG Aiqun. Research status of autonomous-remotely operated vehicle[J]. Journal of Engineering Studies, 2016, 8(2): 217-222.

[2] EDWARDS D B, BEAN T A, ODELL D L, et al. A leader-follower algorithm for multiple AUV formations[C]// Autonomous Underwater Vehicles, 2004

IEEE/OES. IEEE, 2004: 40-46.

- [3] 陶广红,房立金,徐鑫霖,等. 多节链式移动机器人单元模块研究与设计[J]. 机器人, 2018, 40(6): 887-894.
TAO Guohong, FANG Lijin, XU Xinlin, et al. Research and design of the unit module of the multi-link mobile robot[J]. Robot, 2018, 40(6): 887-894.
- [4] BLOCKEN B, TOPARLAR Y, ANDRIANNE T. Aerodynamic benefit for a cyclist by a following motorcycle[J]. Journal of Wind Engineering and Industrial Aerodynamics, 2016, 155: 1-10.
- [5] TIAN W, MAO Z, ZHAO F, et al. Layout optimization of two autonomous underwater vehicles for drag reduction with a combined CFD and neural network method[J]. Complexity, 2017, 1: 1-15.
- [6] BALLABIO D, VASIGHI M. A MATLAB toolbox for self organizing maps and supervised neural network learning strategies[J]. Chemometrics and Intelligent Laboratory Systems, 2012, 18: 24.
- [7] 倪春波,孔一斐,杨月全,等. 粒子群优化及其在多机器人系统中的应用展望[J]. 中南大学学报, 2013(s2): 126-132.
NI Chunbo, KONG Yifei, YANG Yuequan, et al. Particle swarm optimization and its application in multi-robot systems[J]. Journal of Central South University, 2013(s2): 126-132.
- [8] 谢延敏,孙新强,田银,等. 基于改进粒子群算法和小波神经网络的高强钢扭曲回弹工艺参数优化[J]. 机械学报, 2016, 52(19): 162-167.
XIE Yanmin, SUN Xinqiang, TIAN Yin, et al. Optimization of parameters in twist springback process for high-strength sheets based on improved particle swarm optimization algorithm and wavelet neural network[J]. Journal of Mechanical Engineering, 2016, 52(19): 162-167.
- [9] 孟令帅,林扬,郑荣,等. 模块化自主水下机器人的机械设计与实现[J]. 机器人, 2016, 38(4): 395-401.
MENG Lingshuai, LIN Yang, ZHENG Rong, et al. Mechanical design and implementation of a modular autonomous underwater vehicle[J]. Robot, 2016, 38(4): 395-401.
- [10] MENG L S, LIN Y, XU H L, et al. Effects of front shapes of mini revolving AUV on sailing resistance characteristics[C]// IEEE International Conference on Information and Automation. Piscataway, USA: IEEE, 2015: 1795-1799.
- [11] 王亚兴. AUV 的水动力优化及近水面运动性能研究[D]. 哈尔滨: 哈尔滨工程大学, 2015.
WANG Yaxing. Study on AUV hydrodynamic optimization and motion performance near free surface[D].

- Harbin : Harbin Engineering University , 2015.
- [12] 庞永杰,王亚兴,杨卓懿,等. Myring 型回转体直航阻力计算及艇型优化[J]. 哈尔滨工程大学学报, 2014 , 35(9) : 1093-1098.
PANG Yongjie , WANG Yaxing , YANG Zhuoyi , et al. Direct route drag calculation and shape optimization of Myring shape axisymmetric revolution body[J]. Journal of Harbin Engineering University , 2014 , 35(9) : 1093-1098.
- [13] MYRING D. A theoretical study of body drag in subcritical axisymmetric flow[J]. Aeronautical Quarterly , 1976 , 27(3) : 186-194.
- [14] HOU Y H , LIANG X , MU X Y. AUV hull lines optimization with uncertainty parameters based on six sigma reliability design[J]. International Journal of Naval Architecture and Ocean Engineering , 2018 , 10(4) : 499-507.
- [15] GAO T , WANG Y , PANG Y , et al. Hull shape optimization for autonomous underwater vehicles using CFD[J]. Engineering Applications of Computational Fluid Mechanics , 2016 , 10(1) : 599-607.
- [16] WU N , WU C , GE T , et al. Pitch channel control of a REMUS AUV with input saturation and coupling disturbances[J]. Applied Sciences , 2018 , 8(2) : 10.3390/app8020253.
- [17] MADHAN R , DESA E S , PRABHUDESAI S , et al. Mechanical design and development aspects of a small AUV - Maya[C]// 2006 , 7th IFAC Conference in MCMC, 20-22 Sept. , 2006 , Lisbon. IFAC , 2006 : 1-6.
- [18] 李明,刘楠. STAR-CCM+11.0 与流场计算[M]. 北京 : 机械工业出版社, 2017.
LI Ming , LIU Nan. STAR-CCM+11.0 and flow field calculation[M]. Beijing : China Machnie Press , 2017.
- [19] 张亮,张继业,李田,等. 超高速列车流线型头型多目标优化设计[J]. 机械工程学报, 2017 , 53(2) : 106-114.
ZHANG Liang , ZHANG Yeji , LI Tian , et al. Multi-objective optimization design of the streamlined head shape of super high-speed trains[J]. Journal of Mechanical Engineering , 2017 , 53(2) : 106-114.
- [20] 蒋新松,封锡盛,王棣堂. 水下机器人[M]. 沈阳 : 辽宁科学技术出版社, 2000.
JIANG Xinsong , FENG Xisheng , WANG Ditang. Unmanned underwater vehicles[M]. Shenyang : Liaoning Science and Technology Press , 2000.
- [21] 丛爽. 智能控制系统及其应用[M]. 合肥 : 中国科学技术大学出版社, 2013.
CONG Shuang. Intelligent control system and its application[M]. Hefei : University of Science and Technology of China Press , 2013.
- [22] WANG Y , ZHANG F , CUI T , et al. Fault diagnosis for manifold absolute pressure sensor(MAP) of diesel engine based on Elman neural network observer[J]. Chinese Journal of Mechanical Engineering , 2016 , 29(2) : 386-395.
- [23] 周品. MATLAB 神经网络设计与应用[M]. 北京 : 清华大学出版社, 2013.
ZHOU Pin. Design and application of MATLAB neural network[M]. Beijing : Tsinghua University Press , 2013.
- [24] PEI J , WANG W , YUAN S , et al. Optimization on the impeller of a low-specific-speed centrifugal pump for hydraulic performance improvement[J]. Chinese Journal of Mechanical Engineering , 2016 , 29(5) : 992-1002.
- [25] 李镇,樊炳辉,王鑫,等. 基于 BP 神经网络的仿生眼定位追踪算法[J]. 机器人, 2017 , 39(1) : 63-69.
LI Zhen , FANG Binghui , WANG Xin , et al. Locating and tracking algorithm of biomimetic eye based on backpropagation neural network[J]. Robot , 2017 , 39(1) : 63-69.
- [26] 牛江川,韩利涛,李素娟,等. 基于 PSO-BP 神经网络的盾构刀具配置研究[J]. 机械工程学报, 2018 , 54(10) : 167-172.
NIU Jiangchuan , HAN Litao , LI Sujuan , et al. Research on shield cutting tool configuration based on PSO-BP neural network[J]. Journal of Mechanical Engineering , 2018 , 54(10) : 167-172.

作者简介:康帅,男,1993年出生,博士研究生。主要研究方向为水下链式机器人技术。

E-mail : kangshuai@sia.cn

俞建成,男,1976年出生,博士,研究员,博士研究生导师。主要研究方向为新概念海洋机器人技术、移动自主海洋环境观测理论与技术、海洋机器人智能控制方法与技术。

张进(通信作者),男,1987年出生,博士,助理研究员。主要研究方向为多体机器人建模与控制、移动机器人路径规划、最优化调度。

E-mail : zhangjin1@sia.cn

金乾隆,男,1994年出生,博士研究生。主要研究方向为海洋机器人控制与规划。

胡峰,男,1991年出生,硕士,研究实习员。主要研究方向为海洋机器人水动力学。