Optimized Extreme Learning Machines and Their Application in Decoupling of Multi-Component Force Information*

XU Jiaqi[1], *WU Wanneng*[1,2], *SUN Wei*[1,2,3], *WANG Yaonan*[1,2], *LIANG Qiaokang*[1,2,3]*

(1. *College of Electrical and Information Engineering, Hunan University, Changsha* 410082, *China*;
2. *National Engineering Laboratory for Robot Vision Perception and Control Technologies, Changsha* 410082, *China*;
3. *Hunan Key Laboratory of Intelligent Robot Technology in Electronic Manufacturing, Changsha* 410082, *China*)

Abstract: Excellent decoupling method is helpful to improve the detection accuracy of Multi-Axis Force Sensor. Aiming at solving the shortcomings of traditional non-linear force decoupling method, such as long decoupling time and low precision, this paper proposes using improved extreme learning machine algorithms with the advantages of high efficiency and high precision to solve coupling problem. Based on the traditional improved algorithms, such as Extreme Learning Machine based on Particle Swarm Optimization (PSO-ELM) and Extreme Learning Machine based on Genetic Algorithm (GA-ELM), this paper proposes an improved extreme learning machine based on Beetle Antennae Search Algorithm (BAS-ELM) creatively, which is optimized for each dimension of the parameters of the hidden layer nodes of the Extreme Learning Machine to reduce the Loss function. In order to compare the performance of these algorithms, this paper takes the six-dimensional force/torque sensor as the experimental object, and applies various improved algorithms to the actual force decoupling experiment with obvious nonlinear characteristics. Decoupling experiments show that compared with other algorithms, BAS-ELM has higher decoupling precision and shorter convergence time, and has excellent nonlinear decoupling performance.

Key words: multi-axis force/moment sensor; static decoupling; extreme learning machine; beetle antennae search algorithm; particle swarm optimization; genetic algorithm

EEACC: 7230; 7110 **doi**: 10.3969/j.issn.1004-1699.2019.10.010

优化极限学习机算法及其在力信息解耦中的应用*

徐家琪[1], 伍万能[1,2], 孙 炜[1,2,3], 王耀南[1,2], 梁桥康[1,2,3]*

(1.湖南大学电气与信息工程学院, 长沙 410082; 2.机器人视觉感知与控制技术国家工程实验室, 长沙 410082;
3.电子制造业智能机器人湖南省重点实验室, 长沙 410082)

摘 要: 高性能解耦算法有助于提高多维力传感器的检测精度。针对传统非线性解耦算法存在精度较低等缺点, 对极限学习机算法进行了优化和改进, 并将其应用于多维力信息解耦。在基于粒子群和遗传算法两种改进极限学习机算法(PSO-ELM、GA-ELM)的基础上, 提出了一种基于天牛须算法的改进极限学习机(BAS-ELM), 天牛须算法针对极限学习机隐含层节点参数的每一维进行逐步的优化, 使得整体损失函数最小。为验证算法性能, 本文以六维力/力矩传感器为实验对象, 将各类改进算法应用到力/力矩传感器的非线性解耦中, 通过解耦实验可知, 与其他算法相比, BAS-ELM 解耦精度更高、收敛时间更短, 对于非线性解耦具有更强的适应性。

关键词: 多维力传感器; 静态解耦; 极限学习机; 天牛须算法; 粒子群算法; 遗传算法

中图分类号: TP212.12 **文献标识码**: A **文章编号**: 1004-1699(2019)10-1487-06

多维力传感器在机器人柔顺操控与智能作业等方面承担了重要的感知作用[1]。其检测精度的提高有助于实现更精确有效的力觉控制。解耦算法的性能对多维力传感器的检测精度有极大的影响[2]。

项目来源: 国家自然科学基金项目(61673163); 湖南省科技计划项目(2017XK2102); 湖南省重点实验室开放基金项目(IRT2018003)

收稿日期: 2019-05-17 **修改日期**: 2019-08-27

近年来,以机器学习为核心的人工智能算法研究得到了飞速发展。许多机器学习方法因其优异的性能被应用到多维力传感器的解耦中。其中,韩彬彬[3]利用遗传算法优化 BP 神经网络,并以此融合算法对压电式六维力传感器进行解耦,解耦效果表明融合解耦算法对传感器测量性能有显著提高。石中盘等[4]利用混合递阶遗传算法优化小波神经网络并以此进行多维力解耦,实验结果表明,该优化算法的精度较其他常见的非线性解耦方法有明显优势。

尽管神经网络在力解耦方面表现出较好的解耦性能,但是解耦精度仍有待进一步提高。同时,常用的神经网络存在解耦时间长的问题,使得解耦效率较低。本文旨在设计具有更高解耦精度与更高效率的解耦方法的多维力信息解耦算法。

Guangbin Huang 等人于 2004 年提出了一种基于前馈神经网络的高效机器学习算法——极限学习机(Extreme Learning Machine,ELM)。相比于神经网络,极限学习机的特点在于其输入层与隐含层的神经元权值参数与阈值参数是随机给定或者人为给定的,在学习过程中无需调整,仅需要通过合适的算法计算隐含层与输出层之间的权重。极限学习机具有较高的学习效率、准确度、泛化能力和学习能力,因此被广泛应用于机器学习的分类、聚类和回归等各个环节。

尽管极限学习机训练快且具有较强的泛化能力,但是常常存在优化不足与复共线性的问题,使得模型预测结果不够稳定。因此,诸多优化算法不断被应用于极限学习机中(如表 1 所示),常见的有粒子群算法(Particle Swarm Optimization,PSO)和遗传算法(Genetic Algorithm,GA)。李婉华等[5]设计了基于粒子群算法优化的并行极限学习机,用于处理大规模电力预测,与真实电力负荷预测结果对比可知,改进的极限学习机具有较高的稳定性与可扩展性。针对极限学习机随机产生的输入值权值与隐含层阈值容易导致网络结构不稳定的问题,律方成等[6]提出利用遗传算法对极限学习机进行改进,并将其应用到短期电力负荷预测中,实验结果表明,其模型具有较快的训练速度与更精确的预测结果。

表 1 极限学习机优化算法

年份	优化算法	优化对象	研究人员	应用领域
2016	粒子群算法[5]	输入层与隐含层之间的权值与阈值、隐含层节点数	李婉华,陈羽中等	大规模电力负载预测
2018	遗传算法[6]	输入层与隐含层之间的权值与阈值	律方成,刘怡等	短期电力负荷预测
2018	鲸鱼优化算法[7]	输入层与隐含层之间的权值与阈值	林春伟,郭永洪等	水质光谱建模分析
2018	人工蜂群算法[8]	输入层与隐含层之间的权值与阈值	郭一君,周杰等	机械切削加工中刀具磨损检测
2019	花授粉算法[9]	输入层与隐含层之间的权值与阈值	邵良杉,兰亭洋等	瓦斯突出风险检测

本文提出基于天牛须优化算法的改进极限学习机算法(BAS-ELM),利用天牛须优化算法对极限学习机随机产生的输入层与隐含层之间的权值与阈值进行优化计算,并将其应用于多维力传感器的解耦,通过多维力传感器的解耦实验,逐一比较各个优化算法对极限学习机的改进效果。

1 极限学习机理论及其改进算法理论

1.1 极限学习机

极限学习机是一种新型的单隐层前向传播神经网络的高效机器学习算法,仅包含一个隐含层,其以广义逆矩阵理论作为理论依据,具有很强的非线性拟合能力[10],由于仅存在一个隐含层且输入层与隐含层之间的权值与阈值是人为给定或者随机得到的,其训练速度极快,其网络结构如图 1 所示。

极限学习机第 j 个输入信息 X_j 对应的输出数据为 Y_j,二者关系可以表示为:

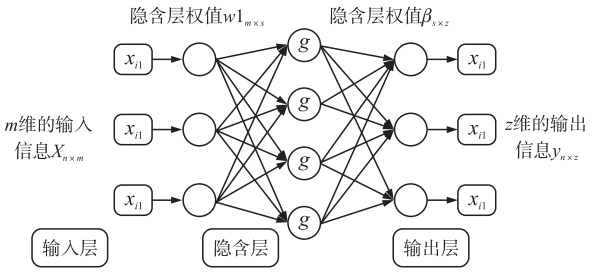

图 1 极限学习机结构示意图

$$Y_j=\sum_{i=1}^{s}\beta_i g(X_j\cdot w1_i+b_i) \tag{1}$$

式中:$g(X)$ 是激活函数,X_j 是第 j 个预测数据,$w1_i$ 是输入层与隐含层之间的权值的第 i 列,b_i 是第 i 列隐含层偏置,β_i 是隐含层第 i 个神经元到第 j 个输出值得权值,$X_j\cdot w1_i$ 表示内积。

极限学习机算法常使用 Sigmoid 函数作为隐含层的激活函数,其可以表示为:

$$g(X)=\frac{1}{1+e^{-X}} \tag{2}$$

在极限学习机的网络结构中,输入层与隐含层之间的权值 $w1_{m\times s}$ 与阈值 $b1_{1\times s}$ 可以通过随机选取或者人工设定;而隐含层与输出层权值 $\beta_{s\times x}$ 可以通过最小二乘法进行确定,最小二乘法的计算公式如下:

$$\beta_{s\times x}=H^{\mathrm{T}}\times(H\times H^{\mathrm{T}})^{-1}\times Y \tag{3}$$

式中:H 为隐含层通过激活函数后的输出值,其运算公式为:

$$H=g(U_{n\times m}\cdot w1_{m\times s}+b_{n\times s}) \tag{4}$$

式中:$b_{n\times s}$ 是阈值 $b1_{1\times s}$ 复制 n 行后的整体阈值矩阵。

1.2　天牛须算法

天牛须优化算法是一种模拟自然界天牛行为的优化算法,其求取最优解的方式是通过模拟天牛寻找食物的过程而完成的。天牛通过头上两只触角接收食物的气味,根据触角接收到的气味方向行走一段距离[11]。参数自变量 X 代表天牛当前的位置,参数自变量 X 的最优解相当于食物的位置,参数自变量 x_i 按照一定方向增加或减少相当于向左走向右走,当参数自变量 X 达到最优解时,目标函数便求得了最小值或者最大值。

当利用天牛须算法进行最优解运算时,首先初始化参数自变量 X,然后按照正态分布初始化向量 dir,之后使得参数自变量 X 按照向量 dir 进行增加或者减少,得到 X_left 和 X_right,通过判断 X_left 和 X_right 对应的目标函数的值,判断参数自变量 X 下一步应当走的方向。

2　基于天牛须的改进极限学习机(BAS-ELM)

利用天牛须算法对 ELM 训练过程中随机产生的输入层与隐含层之间的权值与阈值进行优化,在确定 ELM 的隐含层神经元数量后,其优化过程如下:

(1)对天牛须优化算法的参数进行初始化,需要初始化的参数分别有衰减率 Δ、比率 c、最大起始步长 step,迭代次数 n 等。

(2)初始化 N 维参数自变量 X,N 由神经元的个数与输入量的维度决定,其计算公式如(5)所示。通过目标函数的定义,求取其对应的函数值 $F(X)$。

(3)以正态分布的方式获得每一维自变量 x_i 在每次迭代的过程中变化的方向向量 dir。

(4)X 向量通过利用第 3 步获得的 dir 向量实现“向左迈进一小步”。

$$X_{\mathrm{left}}=X+dir\times\frac{step}{c} \tag{5}$$

其对应的函数值为 $F(X_{\mathrm{left}})$。

(5)X 向量通过利用第 3 步获得的 dir 向量实现“向右迈进一小步”。

$$X_{\mathrm{right}}=X-dir\times\frac{step}{c} \tag{6}$$

其对应的函数值为 $F(X_{\mathrm{right}})$。

(6)比较 $F(X_{\mathrm{left}})$ 和 $F(X_{\mathrm{right}})$ 的大小,并以此来判断 X 应当往某一方向走一大步。公式如下:

如果 $F(X_{\mathrm{left}})$ 大于 $F(X_{\mathrm{right}})$:

$$X=X-step\times dir \tag{7}$$

如果 $F(X_{\mathrm{left}})$ 小于 $F(X_{\mathrm{right}})$:

$$X=X+step\times dir \tag{8}$$

(7)按照迭代次数 n,重复步骤 3 到步骤 6,求取最优解。

3　改进 ELM 在多维力解耦中的应用

3.1　应用背景

多维力传感器可以同时测量多个方向的力与力矩。由于其弹性体一体化结构设计不足、制造工艺和贴片水平的限制,当某个方向的力被加载到传感器上时,其他方向也有一定的耦合输出。这种耦合问题难以通过结构优化而实现,软件解耦相对于结构优化解耦而言实用性更高。

由于力传感器各维度之间的结构耦合呈现出严重的非线性,对机器学习的模型及其优化方法要求较高,普通的模型难以取得良好的效果。

3.2　评价方法

本文以文献[12]中所述的误差率和预测结果的损失函数为主要评价指标,误差率的定义如下:

$$error\_rate=\left|\frac{F_{act}-F_{pre}}{F_{\max}}\right| \tag{9}$$

式中:F_{act} 为实际加载到传感器上的各方向力与力矩的大小,F_{pre} 为解耦算法运算得到的力与力矩的值,$F_{\max}$ 为满量程值。

本文使用的预测结果的损失函数的定义为:

$$J(w,b)=\frac{1}{N}\sum_{i=1}^{N}\|y-a_i\|^2 \tag{10}$$

式中:$a_i=f(w\cdot x+b)$:x 是输入值、w 为网络权值、b 为网络参数、$f(z)$ 是激活函数,$J(w,b)$ 反映的是均方误差(Mean-Square Error,MSE)。

4　解耦实验

4.1　解耦数据的获取

本文的解耦数据由团队开发的六维力/力矩传感器标定实验获得。通过标定实验,可以获得大量六维力/力矩传感器在受力状态下,输入力/力矩大

小与输出电压的对应样本。本文共获得 354 个数据样本,将这些数据样本进行训练集与测试集的划分,共获得训练集 300 个,测试集 54 个。

4.2 算法参数的选取

4.2.1 ELM 算法参数的选取

本文通过测试集在 ELM 处于不同神经元个数时,损失函数的变化,寻找 ELM 的过拟合点。

由图 2 可知,当 ELM 算法神经元大于 130 个时,损失函数不再下降,甚至由于过拟合存在上升波动。因此本文选择神经元个数为 130。

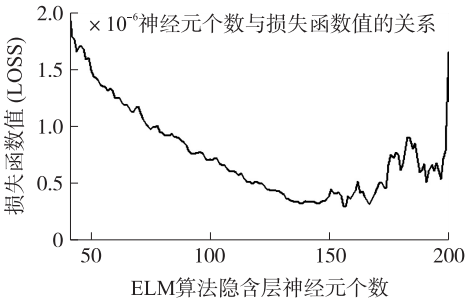

图 2 ELM 神经元个数与损失函数的关系

4.2.2 PSO-ELM 算法参数的选取

在 PSO-ELM 算法中,按照经验,本文将个体学习率 c_1 和社会学习率 c_2 设置为 2,每个粒子群的大小 ParticleSize 设置为 30,最大速度 V_{max} 设置为 5,惯性 w 设置为 0.8。

在 GA-ELM 算法中,将交叉和变异概率设置为 0.5 和 0.01,种群大小设置为 30。

在 BAS-ELM 算法中,将衰减率设置为 0.997(在经过 300 次迭代后,步长变为原来的 0.406 倍),比率设置为 5,最大起始步长设置为 1。

对于优化算法的迭代次数而言,其与训练时间相关,次数过多会导致训练时间过长;次数过少会导致训练不完全,精度低。本文通过训练集的损失函数随迭代次数的变化,得到各个优化算法的最佳迭代次数。

由图 3 可知,当 PSO-ELM、GA-ELM、BAS-ELM 迭代次数分别大于 60、40、200 时,损失函数不再明显下降,由此确定各个算法的迭代次数。

4.3 实验结果

将各类改进的 ELM 在测试集上进行解耦测试,得到的测试结果的Ⅰ、Ⅱ类误差、损失函数和解耦时间,并通过这些参数来比较各类改进 ELM 的优缺点。

当某一方向力单向加载时,利用各类改进解耦方法对测试集进行测试,每个方向的误差率如表 2 所示。

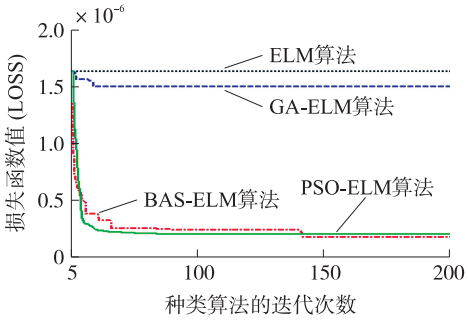

图 3 PSO-ELM 迭代次数与损失函数的关系

表 2 各解耦方法在单向加载时的最大误差率

解耦方法	加载方向	F_x	F_y	F_z	M_x	M_y	M_z
ELM	F_x	1.397	0.411	0.010	0.030	0.006	0.123
	F_y	0.121	0.692	0.017	0.008	0.007	0.124
	F_z	0.037	0.086	0.018	0.004	0.005	0.123
	M_x	0.387	0.175	0.016	0.007	0.010	0.123
	M_y	0.035	0.030	0.004	0.005	0.004	0.123
	M_z	0.151	0.132	0.007	0.013	0.009	0.236
解耦方法	加载方向	F_x	F_y	F_z	M_x	M_y	M_z
PSO-ELM	F_x	0.028	0.025	0.003	0.005	0.007	0.032
	F_y	0.028	0.025	0.002	0.015	0.007	0.032
	F_z	0.036	0.035	0.008	0.021	0.007	0.032
	M_x	0.007	0.118	0.023	0.014	0.057	0.044
	M_y	0.009	0.025	0.002	0.003	0.007	0.032
	M_z	0.005	0.025	0.003	0.009	0.007	0.032
解耦方法	加载方向	F_x	F_y	F_z	M_x	M_y	M_z
GA-ELM	F_x	1.004	0.409	0.004	0.014	0.009	0.093
	F_y	0.126	0.538	0.011	0.005	0.015	0.068
	F_z	0.026	0.025	0.002	0.003	0.002	0.068
	M_x	0.088	0.103	0.008	0.032	0.005	0.110
	M_y	0.022	0.024	0.002	0.003	0.002	0.068
	M_z	0.036	0.071	0.003	0.011	0.003	0.194
解耦方法	加载方向	F_x	F_y	F_z	M_x	M_y	M_z
BAS-ELM	F_x	0.072	0.025	0.003	0.004	0.002	0.007
	F_y	0.025	0.025	0.002	0.006	0.001	0.007
	F_z	0.025	0.025	0.002	0.003	0.001	0.007
	M_x	0.026	0.025	0.002	0.027	0.033	0.007
	M_y	0.025	0.025	0.002	0.003	0.001	0.007
	M_z	0.025	0.025	0.001	0.003	0.002	0.007

根据表 2 可以得到某方向力单向加载时,各方向Ⅰ类误差最大值和各方向Ⅱ类误差最大值,如表 3、表 4 所示。

由表 3 可知,普通的 ELM 算法在各个方向上的Ⅰ类误差得到了一定的控制,保持在 1.4% 以内;GA-ELM 算法相对于普通的 ELM 算法,性能有一定

的提升,各方向Ⅰ类误差保持在 1.1%以内;PSO-ELM 算法和 BAS-ELM 算法相对与其他两种算法,解耦性能优秀,各方向Ⅰ类误差均保持在 0.1%以内。

表 3　各方向Ⅰ类误差最大值　　单位:%

方法	F_x	F_y	F_z	M_x	M_y	M_z
ELM	1.398	0.692	0.018	0.030	0.010	0.236
PSO-ELM	0.028	0.025	0.008	0.014	0.007	0.032
GA-ELM	1.004	0.539	0.002	0.032	0.003	0.194
BAS-ELM	0,072	0.025	0.002	0.027	0.002	0.007

表 4　各方向Ⅱ类误差最大值　　单位:%

方法	F_x	F_y	F_z	M_x	M_y	M_z
ELM	0.411	0.124	0.123	0.387	0.123	0.151
PSO-ELM	0.032	0.032	0.036	0.118	0.032	0.025
GA-ELM	0.409	0.126	0.068	0.110	0.068	0.071
BAS-ELM	0.025	0.025	0.025	0.033	0.025	0.025

由表 4 可知,普通的 ELM 算法在各个方向上的Ⅱ类误差保持在 0.5%以内;在Ⅱ类误差的控制上,GA-ELM 算法相对于普通的 ELM 算法有一定提升,但不明显,Ⅱ类误差同样保持在 0.5%以内,各方向Ⅰ类误差保持在 1.1%以内;PSO-ELM 算法和 BAS-ELM 算法相对与其他两种算法,解耦性能更优,其中 PSO-ELM 的Ⅱ类误差保持在 0.12%以内,BAS-ELM 的Ⅱ类误差保持在 0.05%以内。

表 5　各类方法的最小损失函数值

方法	最小损失函数值
ELM	2.79×10^{-7}
PSO-ELM	3.34×10^{-9}
GA-ELM	2.04×10^{-7}
BAS-ELM	1.89×10^{-9}

由表 5 可知,GA-ELM 算法的性能相对于普通 ELM 算法有一定提升,但效果不明显。PSO-ELM 算法和 BAS-ELM 算法相对于其他算法有较为明显的提升,在最小损失函数上 BAS-ELM 算法表现略优于 PSO-ELM。各类解耦方法对应的训练时间如表 6 所示。

表 6　各类解耦方法的训练时间

方法	解耦时间(S)
ELM	0.095
PSO-ELM	0.35
GA-ELM	1.22
BAS-ELM	0.34

由表 6 可知,ELM 算法的解耦时间非常快。在利用优化算法对 ELM 进行优化后,GA-ELM 训练时间较长,其训练时间长与其基因需要用二进制编码导致基因长度较长有关。PSO-ELM 算法使用粒子种群进行运算,运算量较大。相对于其他优化 ELM 算法,BAS-ELM 解耦算法的训练时间较短。

4.4　实验结果分析

从表 7 的结果对比并结合上文内容,可知:

(1)极限学习机及其优化算法具有运算时间短,解耦性能高的特点。

(2)GA-ELM 解耦算法训练时间长,性能相对普通 ELM 有一定提升但提升有限。

(3)PSO-ELM 算法性能表现极好,但解耦时间相对于 BAS-ELM 和普通极限学习机有一定的上升。

(4)BAS-ELM 算法在保持优良性能的情况下,解耦时间也得到了一定的控制,实现过程相对于其他改进算法更加简单。

表 7　实验结果分析

解耦方法	优点	缺点	训练速度	解耦精度
ELM	运算速度快、训练时间短;具有一定的误差控制能力。	难以确定隐含层神经元数量,太少会导致训练效果差,太多会导致过拟合。	快	一般
PSO-ELM	性能好,误差控制能力强。	实现复杂;训练时间较长。	较慢	高
GA-ELM	相对于普通 ELM 有一定提升。	实现复杂;训练时间长;性能表现一般	慢	较高
BAS-ELM	性能好,误差控制能力强;在保持良好性能的情况下,解耦时间较短;实现简单。	训练时间较普通 ELM 长	较快	高

5　结论

本文在基于粒子群算法和遗传算法的改进极限学习机基础之上,提出了基于天牛须算法的改进极限学习机算法(BAS-ELM),并将其应用于智能机器人多维力/力矩传感器的解耦实验中。实验结果表明,GA-ELM 解耦算法训练时间长,性能提升有限;PSO-ELM 解耦算法性能表现极好,但训练时间相对 ELM 和 BAS-ELM 较长;BAS-ELM 解耦算法在保持优良性能的前提下,缩短了训练时间,同时实现过程相对其他算法简单,具有实际的应用价值。

参考文献:

[1]　Liang Qiaokang, Zou Kunlin, Long Jianyong, el al. Multi-

Component FBG-Based Force Sensing Systems by Comparison with Other Sensing Technologies: A Review[J]. 2018,18(18):7345-7357.
[2] 曹会彬,孙玉香,刘利民,等. 多维力传感器耦合分析及解耦方法的研究[J]. 传感技术学报,2011,24(8):1136-1140.
[3] 韩彬彬. 压电式六维力/力矩传感器非线性解耦算法的研究[D]. 济南:济南大学,2017.
[4] 石中盘,赵铁石,厉敏,等. 大量程柔性铰六维力传感器静态解耦的研究[J]. 仪器仪表学报,2012,33(5):1062-1069.
[5] 李婉华,陈羽中,郭昆,等. 基于改进粒子群优化的并行极限学习机[J]. 模式识别与人工智能,2016,29(9):840-849.
[6] 律方成,刘怡,亓彦珣,等. 基于改进遗传算法优化极限学习机的短期电力负荷预测[J]. 华北电力大学学报(自然科学版),2018,45(6):1-7.
[7] 林春伟,郭永洪,何金龙. 改进鲸鱼算法优化核极限学习机在水质光谱分析中的应用[J]. 半导体光电,2019,40(1):112-118.
[8] 郭一君,周杰,王时龙,等. 基于改进人工蜂群算法和极限学习机的刀具磨损监测[J]. 重庆大学学报,2018,41(6):1-8.
[9] 邵良杉,兰亭洋,李臣浩. 基于改进花授粉算法的极限学习机[J/OL]. 计算机工程:1-11[2019-05-12].
[10] 曹祥红,刘磊,杨鹏,等. 利用多源信息和极限学习机的人体运动意图识别[J]. 传感技术学报,2017,30(8):1171-1177.
[11] 邵良杉,韩瑞达. 基于天牛须搜索的花朵授粉算法[J]. 计算机工程与应用,2018,54(18):188-194.
[12] Liang Qiaokang, Long Jianyong, Gianmarc Coppola, el al. Novel Decoupling Algorithm Based on Parallel Voltage Extreme Learning Machine(PV-ELM) for Six-Axis F/M Sensors, Robotics and Computer Integrated Manufacturing,57(6):303-314,2019.

徐家琪(1997-),男,浙江杭州人,汉族,硕士研究生,研究方向为机器人传感器,人工智能及其应用;

梁桥康(1982 年-),男,湖南涟源人,汉族,副教授,博士生导师,博士,研究方向:机器人传感器,人工智能及其应用,qiaokang@ hnu.edu.cn。

(上接第 1482 页)

[13] Madgwick S O H, Harrison A J L, Vaidyanathan A. Estimation of IMU and MARG Orientation Using a Gradient Descent Algorithm [J]. IEEE International Conference on Rehabilitation Robotics: [proceedings]. 2011,5975346.
[14] 张栋,焦嵩鸣,刘延泉. 互补滤波和卡尔曼滤波的融合姿态解算方法[J]. 传感器与微系统,2017,36(3):62-65,69.

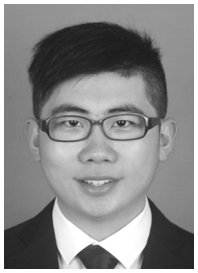

孙利成(1994-),男,江苏盐城人,现为东南大学仪器科学与工程学院硕士研究生,研究方向为车轮力传感器姿态解耦研究,sun_licheng@ foxmail.com;

王　东(1986-),男,东南大学讲师,江苏扬州人,研究方向为信号处理,传感器技术和系统控制,kingeast16@ seu.edu.cn;

张为公(1959-)男,东南大学教授,博士生导师,研究方向为从事汽车电子与测控技术及机电仪一体化,zhangwg1023@ qq.com;

许　瞳(1993-),男,安徽桐城人,现为东南大学仪器科学与工程学院博士研究生,研究方向为信号处理,传感器技术和系统控制,928087776@ qq.com。