

DOI:10.19651/j.cnki.emt.2208772

舵机异常检测模型的设计与研究^{*}

杨瑞峰 王伟丽 郭晨霞 秦浩

(中北大学仪器与电子学院 太原 030051)

摘要:针对舵机测试数据量大且样本不均衡问题,提出了一种使用灰狼优化算法(GWO)优化深度神经网络(DNN)并与逻辑回归分类器(LRC)相结合的舵机异常检测模型(GWO-DNN-LRC)。模型的构建有效地解决了舵机测试数据中小样本难以被准确分类的问题,适用于舵机测试数据的深度特征提取与多故障分类。该方法的准确度达到99.261%,相较于LRC、DNN、GWO-DNN分别提高了4.931%、0.205%、0.087%,精确度、召回率、F-score达到98.417%、98.062%、98.217%。在不同类别分类准确度对比中,6种小样本的类别能够达到100%。实验结果表明,该方法充分提高了舵机异常检测的性能,是深度学习技术在舵机测试数据中的有效应用。

关键词:舵机;异常检测;GWO-DNN-LRC模型;不均衡数据分析

中图分类号: TP183 文献标识码: A 国家标准学科分类代码: 520.2060

Model design and research on abnormal detection of steering gear

Yang Ruiseng Wang Weili Guo Chenxia Qin Hao

(School of Instrumentation and Electronics, North University of China, Taiyuan 030051, China)

Abstract: Aiming at the problem of large amount of the steering gear test data and unbalanced samples, an anomaly detection model is proposed that uses the grey wolf optimization (GWO) to optimize the deep neural networks (DNN) and combines it with the logistic regression classification (GWO-DNN-LRC). The construction of the model effectively solves the problem that small samples in the steering gear test data are difficult to be accurately classified, and is suitable for the deep feature extraction and multi-fault classification of the steering gear test data. The accuracy of this method reaches 99.261%, which is 4.931%, 0.205%, and 0.087% higher than LRC, DNN, and GWO-DNN, respectively. The precision, recall, and F-score reach 98.417%, 98.062%, and 98.217%. In the comparison of classification accuracy of different categories, the categories of 6 small samples can reach 100%. Experimental results show that this method fully improves the performance of anomaly detection of steering gear, and is an effective application of deep learning technology in steering gear test data.

Keywords: steering gear; abnormal detection; GWO-DNN-LRC model; unbalanced data analysis

0 引言

舵机是一种广泛应用于航空航天领域的高精度位置伺服驱动器^[1],它接收来自飞行控制系统的控制信号,进而驱动舵面偏转,实现飞行姿态和轨迹的控制,其性能直接决定着飞行器飞行过程的动态品质^[2]。为保证舵机的精确控制,需要在生产过程中对舵机的静态参数和动态参数进行测试分析。然而,大量的舵机参数测试结果仍采用人工处理的方法进行分析,导致异常检测的准确性和高效性难以保证。随着自动化技术的不断发展,对舵机测试数据的自动化分析有了进一步需求。因此,舵机自动化异常检测方

法分析是一项顺应发展趋势且具有实际意义的研究。

目前,针对舵机测试数据分析的研究较少。文献[3]利用随机森林算法(random forest, RF)解决了舵机多维性能参数数据挖掘和分类建模问题,但并未考虑小样本的分类效果。文献[4]利用支持向量机分类器(support vector machine, SVM),虽考虑了舵机测试数据的不均衡性,但未进行分析处理,且分类效果有待提高。近年来,深度学习(deep learning, DL)技术广泛应用于工业、农林、医学等领域^[5-8],适合处理和分析各种类型数据。在智能诊断方面,深度神经网络(deep neural networks, DNN)已成为热门算法之一。文献[9]使用DNN对电力系统配电网的故障进

收稿日期:2022-01-05

*基金项目:山西省重点研发计划项目(201903D121060)资助

行分类。文献[10]使用 DNN 对旋转机械数据进行故障特征挖掘和健康状况分类。由此可见,DNN 在数据提取和分类方面效果显著,为舵机测试数据的异常检测提供了新方向。

利用灰狼优化算法(grey wolf optimization,GWO)构建 DNN 网络,完成舵机测试数据的特征提取。将 DNN 网络提取出来的特征向量送入逻辑回归分类器(logistic regression classification,LRC),克服 LRC 无法筛选数据特征的缺点,实现对舵机状态的精确分类。构建的 GWO-DNN-LRC 模型与 LRC、DNN 和 GWO-DNN 模型进行分类性能对比,确定所建模型的有效性。针对舵机测试数据样本不均衡,小样本难以被准确分类的问题,设计实验验证不同舵机状态被分类的情况。

1 基本理论背景

1.1 逻辑回归算法

逻辑回归是机器学习中的一种监督学习,以回归的思想来解决分类问题。该算法的原理是使用最大似然函数来拟合基于后验概率的输入变量和结果之间的线性函数。

为了解决逻辑回归算法对不均衡数据敏感且无法进行数据特征提取这两方面的问题,实验通过 DNN 网络对舵机测试数据进行特征提取,再将特征提取后的数据输入到 LRC 中。该方法既解决了数据特征提取问题,又能提高小样本分类的准确性。

1.2 深度神经网络

DNN 具有包含多个隐藏层的深层架构,每个隐藏层执行从上一层到下一层的非线性转换。DNN 使用 ReLU 或 Tanh 等传输函数模拟神经元对激励的响应,在训练算法上使用反向传播算法(back propagation,BP)。

众所周知,神经网络的性能直接依赖于其超参数,而人为设计的超参数并不能达到最好的网络结构,因此本实验采用 GWO 算法对 DNN 隐藏层节点数进行寻优,完成网络的构建,以达到最佳的分类效果。

1.3 灰狼优化算法

GWO 优化过程主要包括社会等级分层、包围猎物、狩猎、攻击猎物和搜索猎物。该算法可以实现参数的寻优^[11-13]。

社会等级分层:为了设计 GWO,建立了灰狼社会等级的数学模型。其中,最优解为 Alpha(α)。同样,第 2 个和第 3 个最优解称为 Beta(β)和 Delta(δ)。其余的候选解被命名为 Omega(ω)。算法优化过程以 Alpha、Beta 和 Delta 为主。

包围猎物:灰狼中各搜索代理的包围行为数学模型如下。灰狼的位置由式(1)和(2)更新。

$$\vec{D} = |\vec{C} \cdot \vec{X}_\beta(t) - \vec{X}(t)| \quad (1)$$

$$\vec{X}(t+1) = \vec{X}_\beta(t) - \vec{A} \cdot \vec{D} \quad (2)$$

其中, t 表示当前迭代, \vec{A} 和 \vec{C} 是系数向量, \vec{X}_β 是猎物

的位置向量, \vec{X} 表示灰狼的位置向量。

向量 \vec{A} 和 \vec{C} 由式(3)和(4)给出:

$$\vec{A} = 2\vec{a} \cdot \vec{r}_1 - \vec{a} \quad (3)$$

$$\vec{C} = 2\vec{r}_2 \quad (4)$$

其中, \vec{a} 在迭代过程中从 2 线性减少到 0, \vec{r}_1 和 \vec{r}_2 是 $[0,1]$ 中的随机向量。

狩猎:将 α 、 β 和 δ 设置为 3 个最优解。然后根据 α 、 β 和 δ 的位置信息更新 ω 等其他灰狼的位置。这种行为的数学模型可以表示如下:

$$\vec{D}_\alpha = |\vec{C}_\alpha \cdot \vec{X}_\alpha - \vec{X}| \quad (5)$$

$$\vec{D}_\beta = |\vec{C}_\beta \cdot \vec{X}_\beta - \vec{X}| \quad (6)$$

$$\vec{D}_\delta = |\vec{C}_\delta \cdot \vec{X}_\delta - \vec{X}| \quad (7)$$

$$\vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \cdot \vec{D}_\alpha \quad (8)$$

$$\vec{X}_2 = \vec{X}_\beta - \vec{A}_2 \cdot \vec{D}_\beta \quad (9)$$

$$\vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \cdot \vec{D}_\delta \quad (10)$$

$$\vec{X}(t+1) = (\vec{X}_1 + \vec{X}_2 + \vec{X}_3)/3 \quad (11)$$

其中, \vec{X}_α 、 \vec{X}_β 和 \vec{X}_δ 分别表示 α 、 β 和 δ 的位置向量; \vec{X} 表示灰狼的位置向量; \vec{D}_α 、 \vec{D}_β 和 \vec{D}_δ 表示当前候选灰狼与 α 、 β 和 δ 之间的距离。

攻击猎物和搜索猎物:根据式(3)可知, \vec{a} 的减少会引起 \vec{A} 的波动。当 \vec{A} 在 $[-1,1]$ 区间时,搜索代理的下一个位置可以在灰狼和它的猎物之间的任何位置。当 $|A| < 1$, 迫使灰狼攻击猎物。当 $|A| > 1$, 迫使狼与猎物分离, 寻找更合适的猎物。

GWO 算法流程如图 1 所示。

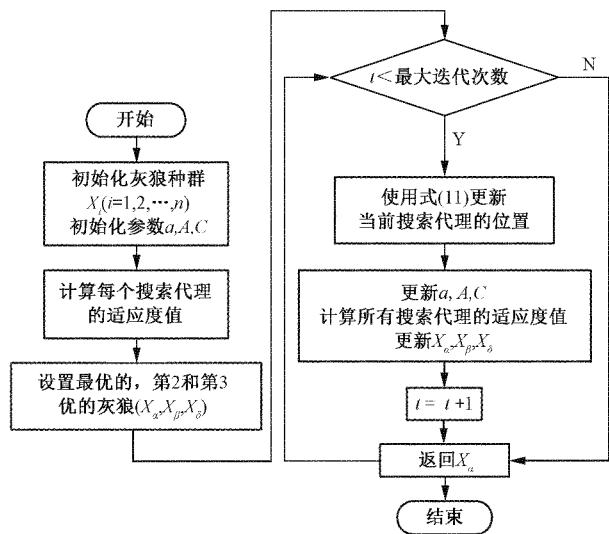


图 1 GWO 算法流程

2 实验方法设计

2.1 舵机测试设备

舵机自动化测试设备主要由工控机、采集卡、信号调理

电路、驱动、气动舵机和电池单元组成。舵机自动化测试的简要流程如图 2 所示。工控机发出三角波、正弦波等舵控信号,信号经采集卡后进行 A/D 转换进入信号调理电路,信号调理电路的输出电压作用于驱动器,驱动器驱动气动舵机,舵机传输出的舵反馈电压经信号调理电路和 D/A 转换传回到采集卡中,最后采集卡将采集到的舵反馈信号传回工控机。

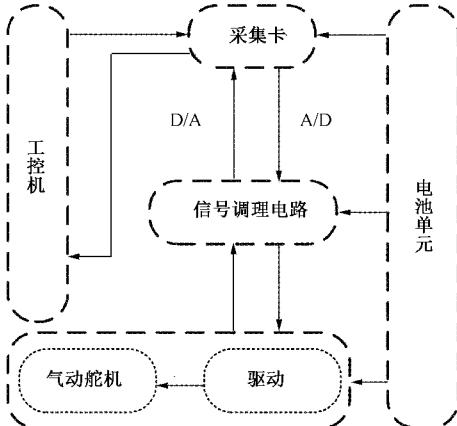


图 2 舵机自动化测试组成原理

测试设备可同时加载 4 套舵机,这种设计大大提高了测试系统的效率。舵机在使用前必须进行评估,以确保所有参数都处于正常状态,如果参数异常,需要立即进行分析和调整,这直接关系到舵机的性能。然而,庞大的数据量给数据分析增加了难度。因此,引入机器学习方法来分析从测试设备收集到的海量复杂数据。计算机辅助诊断不仅节省了人力和时间,而且提高了异常检测的准确性以及自动化程度。

2.2 数据集简介

实验使用了 19 490 条测试数据。每条舵机测试数据包含 10 个特征点,分别对应 10 种不同的测试参数:电气行程、频带宽度、过渡过程时间、超调量、稳态误差、迟滞特性等。这些参数反映了气动舵机的动静态特性,是评价舵机性能的综合指标。舵机测试数据的分析将舵机分为 11 类状态:合格状态(Q)和异常状态(FA-FJ)。

2.3 实验设置

为了训练 DNN 网络,将数据集以 8 : 2 的比例划分为训练集和测试集,即 15 592 条数据用以训练网络,3 898 条数据用以测试网络的性能。神经网络训练一次所选取的样本数量称为批量大小,将其设置为 512。DNN 网络训练选用 Adam 算法,迭代次数设置为 200。

为获得最合适的 DNN 网络构架,使用 GWO 算法对 DNN 网络的超参数进行微调。GWO 算法的适应度设置为 DNN 网络的准确度,算法的参数设置如下:种群数量设置为 10,最大迭代次数设置为 20,网络迭代次数设置为 200。

2.4 模型构建

1) 网络层次分析

为分析网络隐藏层数对舵机测试数据分类准确性的影晌,实验分析了含有 1~5 个隐藏层的 DNN 网络(Dense- i , $i=1,2,\dots,5$)。不同网络层次分别进行了 5 次重复实验,以确保结果的可靠性。对比结果如表 1 所示,含有 3 个隐藏层的 DNN 网络表现最佳,相比于其他 4 类网络,平均准确度分别高出 1.227%、0.246%、0.318% 和 0.498%。

表 1 隐藏层层数对分类准确度的影响 %

实验序列号	Dense-1	Dense-2	Dense-3	Dense-4	Dense-5
1	97.845	98.846	99.102	98.897	98.230
2	97.896	98.923	99.076	98.871	98.666
3	97.819	98.846	99.000	98.358	98.615
4	97.922	98.717	99.025	98.923	98.743
5	97.665	98.717	99.076	98.640	98.538
平均值	97.829	98.810	99.056	98.738	98.558

由实验结果分析,DNN 网络隐藏层数的增加可以提高模型的特征提取能力,学习得到的特征对数据有着更加本质的刻画。但与此同时,层数的过度增加也会引起模型的复杂度增加,准确度下降。

2) 超参数寻优

经过对网络层次的分析,得知含有 3 个隐藏层的 DNN 最适合舵机测试数据,但每个隐藏层的节点数($n_i, i = 1, 2, 3$)难以准确选择,这关系到 DNN 网络特征提取的效果。实验利用 GWO 算法对 3 个节点数进行微调。寻优范围和寻优结果如表 2 所示。由结果可知,DNN 模型的第一隐藏层节点数为 95,第二隐藏层节点数为 163,第三隐藏层节点数为 92。此时,GWO 算法适应度值最高,即 DNN 网络准确度值最佳。

表 2 DNN 的超参数寻优

	n_1	n_2	n_3
寻优范围	[10, 200]	[10, 200]	[10, 200]
寻优结果	95	163	92

3) 分类器的选取

选取 Softmax 作为 DNN 网络输出层的激活函数(Softmax 层),可将输入的舵机测试数据经过隐藏层特征提取后进行多类别分类。LRC 在数据分类方面有广泛的应用^[14-15]。目前,将神经网络与传统分类器相融合已经受到了极大的关注^[16]。本文实验选取 LRC 替代 DNN 的 Softmax 层,以增强分类器的性能,提高 DNN 的泛化能力。

最终,确定了本实验所构建的舵机异常检测模型:GWO-DNN-LRC,如图 3 所示,即利用 GWO 算法优化 DNN 网络的超参数,利用 LRC 替代 DNN 的 Softmax 层进行舵机状态分类。舵机异常检测数据以 10×1 的形式输入

到模型, 经过分别为 95、163、92 个节点数的 3 个隐藏层对数据进行深度特征提取。特征提取后的数据以 92×1 的形

式被输入到 LRC, 分类器将数据分为 11 类, 即得到 11 类分类结果, 实现舵机测试数据的异常检测。

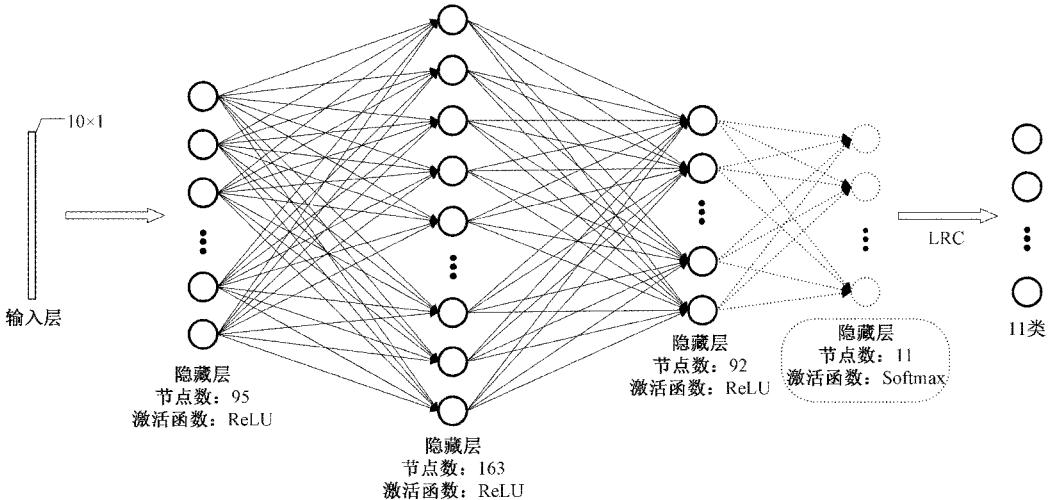


图 3 舵机异常检测模型

3 仿真结果分析

3.1 评价指标

舵机的异常检测本质上为数据多分类问题^[17]。使用准确性(Accuracy)、精确度(Precision)、召回率(Recall)和 F-score 来评估所提模型的分类性能。这 4 种评价指标如下:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (12)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (13)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (14)$$

$$F\text{-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (15)$$

其中, TP 、 TN 、 FP 、 FN 分别代表真阳性、真阴性、假阳性和假阴性。具体来讲, TP 指归类为正常的正常类别, TN 指归类为异常的正常类别。反之, 归类为正常类别的异常类别称为 FP , 归类为异常类别的异常类别称为 FN 。

3.2 不同模型分类性能验证

为了广泛评估所提出的舵机异常检测模型性能, 将 GWO-DNN-LRC 模型与 LRC 模型、未进行优化的 DNN 模型、使用 DNN 模型中 Softmax 层进行分类的 GWO-DNN 模型进行对比分析。

在 DNN 网络模型训练和测试时, 将损失函数(Loss)进行了可视化处理, 如图 4 所示。训练集和测试集的交叉熵损失函数值在迭代 200 次后基本趋于平稳, 说明 DNN 网络和 GWO-DNN 网络在训练和测试时均在不引起过度拟合的情况下收敛, 也就是说该网络是有效的, 且经过 GWO 算法优化后的 DNN 网络收敛速度有所提高。

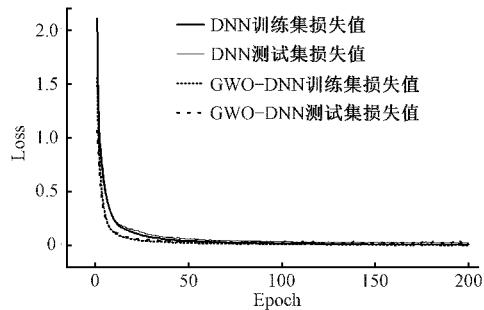


图 4 损失函数曲线

分别通过 5 次重复实验得出不同模型的准确度、精确度、召回率和 F-score。为了直观分析出同样的特征提取数据送入不同的分类器中的分类性能, 将 5 次实验均体现在如表 3 所示的表格中。所提出的舵机异常检测模型(GWO-DNN-LRC)的平均准确度、精确度、召回率、F-score 分别为 99.261%、98.417%、98.062%、98.217%。

均使用逻辑回归分类器的情况下, 所提模型的准确度相比 LRC 模型提高了 4.931%, 说明数据经过 DNN 网络进行特征提取后再送入分类器中能显著提高分类性能。均为 3 个隐藏层的 DNN 网络, 通过 GWO 算法对网络隐藏层节点数寻优能够提高 0.118% 的分类准确度, 说明网络隐藏层节点数影响分类效果, 且相比于人为设置节点数, 利用算法寻优能更准确构建网络模型。数据经 GWO-DNN 提取特征后, 送入 LRC 相比送入 DNN 的 Softmax 层分类准确度提高了 0.087%, 从 5 次重复实验可以更明确的分析得出, 虽同一实验特征提取的效果均相同, 但所提模型 5 次实验的分类准确度都高于 GWO-DNN 模型。在精确度、召回率和 F-score 性能对比中, 除所提模型在精确度对比中略低于 GWO-DNN 模型外, 其余对比结果均最佳。

表 3 不同模型分类性能对比

评价指标	模型						%
		1	2	3	4	5	
准确度	LRC	94.330	94.330	94.330	94.330	94.330	94.330
	DNN	99.102	99.076	99.000	99.025	99.076	99.056
	GWO-DNN	99.179	99.153	99.179	99.205	99.153	99.174
精确度	GWO-DNN-LRC	99.307	99.230	99.205	99.333	99.230	99.261
	LRC	88.579	88.579	88.579	88.579	88.579	88.579
	DNN	97.477	97.749	98.404	98.593	98.688	98.182
召回率	GWO-DNN	98.871	97.358	98.749	99.177	98.660	98.563
	GWO-DNN-LRC	98.514	98.256	98.311	98.776	98.226	98.417
	LRC	78.493	78.493	78.493	78.493	78.493	78.493
F-score	DNN	97.685	96.814	96.963	97.572	96.674	97.142
	GWO-DNN	97.372	99.104	97.269	97.192	97.398	97.667
	GWO-DNN-LRC	98.019	98.254	97.921	98.136	97.980	98.062
F-score	LRC	83.232	83.232	83.232	83.232	83.232	83.232
	DNN	97.556	97.224	97.639	98.040	97.605	97.613
	GWO-DNN	98.049	98.040	97.969	98.092	97.990	98.028
F-score	GWO-DNN-LRC	98.242	98.243	98.096	98.426	98.078	98.217

3.3 不同类别分类性能验证

通过实验得知, GWO-DNN-LRC 模型在总体评价绩效指标中表现良好。为了进一步分析每个类别的分类情况, 在表 4 中绘制了每一类别的准确度。表中 Q 表示舵机状态为合格, FA~FJ 表示舵机的单一故障(故障 A~故障 J)。舵机状态为 Q 的样本量大, 其余状态样本量均很小, 样本的不均衡性显著。为了验证所提模型对小样本的分类性能, 实验将 4 种模型进行了比较验证。值

得注意的是, LRC 受到数据不均衡性影响较大, 对 FE、FF、FG 和 FJ 这 4 种舵机异常状态分类效果较差, 特别是 FF 和 FJ 类, 准确度小于 50%, 无法达到分类效果。数据经过 DNN 特征提取后的 3 种模型分类准确度都有大幅度提升, 且几乎不受小样本数据的影响。其中, GWO-DNN-LRC 模型在 FA、FB、FC、FF、FH、FI 类别中分类准确度能达到 100%, 说明对于小样本, 该模型仍能准确分类。

表 4 不同类别分类准确度对比

类别	训练集样本量	测试集样本量	准确度/%			
			LRC	DNN	GWO-DNN	GWO-DNN-LRC
Q	12 549	3 120	99.39	99.49	99.71	99.65
FA	604	154	98.70	100	99.35	100
FB	151	45	93.33	97.78	100	100
FC	169	50	100	98.00	100	100
FD	615	155	98.71	98.71	99.35	98.71
FE	242	55	69.09	94.55	81.82	89.09
FF	269	71	30.99	97.18	98.59	100
FG	240	56	73.21	92.86	96.43	96.43
FH	170	43	100	100	100	100
FI	182	35	100	100	100	100
FJ	401	114	0	92.11	93.86	95.61

4 结论

针对舵机的自动化异常检测, 提出了一种适用于舵机测试数据的 GWO-DNN-LRC 模型。该模型解决了 LRC

受数据样本量影响显著的问题, 以及 DNN 超参数选择问题。模型性能评估中, 5 次重复实验的平均准确度、精确度、召回率和 F-score 分别达到 99.261%、98.417%、98.062%、98.217%, 且分类性能几乎不受样本不均衡的

影响,综合性能优于LRC、DNN、GWO-DNN模型。

GWO-DNN-LRC模型的构建,简化了人工工作,使用计算机代替人脑进行数据分析和决策,是深度学习技术在舵机异常检测领域的有效应用。

参考文献

- [1] 赵志俊,孟祥喆,郑浩.舵机带宽测试系统设计与试验方法研究[J].电子测量技术,2019,42(1):63-67.
- [2] 王莉.电动舵系统参数优化方法研究[D].太原:中北大学,2012.
- [3] CHANG B L, YANG R F, GUO CH X, et al. A new application of optimized random forest algorithms in intelligent fault location of rudders[J]. IEEE Access, 2019, 7: 94276-94283.
- [4] LI L M, YANG R F, GUO CH X, et al. A novel application of intelligent algorithms in fault detection of rudder system[J]. IEEE Access, 2019, 7: 170658-170667.
- [5] 李云朋,熊柳景,牛刚.嵌入式轴承故障诊断系统的设计与实现[J].国外电子测量技术,2019,38(11):147-152.
- [6] NALINI S, KRISHNARAJ N, JAYASANKAR T, et al. Paddy leaf disease detection using an optimized deep neural network [J]. Computers, Materials & Continua, 2021, 68(1): 1117-1128.
- [7] 章黎明,贾智伟,谢俊力,等.近四年胶囊内镜图像病灶的深度学习识别研究进展[J].电子测量与仪器学报,2019,33(8):69-77.
- [8] 陈志强,陈旭东,OLIVIRA J V D,等.深度学习在设备故障预测与健康管理中的应用[J].仪器仪表学报,2019,40(9):206-226.
- [9] 薛太林,耿杰.基于优化深度神经网络的配电网单相接地故障诊断[J].电气自动化,2021,43(1):88-91.
- [10] JIA F, LEI Y G, LIN J, et al. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data[J]. Mech Syst Signal Proc, 2016, 72-73: 303-315.
- [11] 杨晓敏.改进灰狼算法优化支持向量机的网络流量预测[J].电子测量与仪器学报,2021,35(3):211-217.
- [12] 刘勇智,李杰,鄯成龙.开关磁阻电机最优分数阶PID^a控制器设计[J].电子测量与仪器学报,2020,34(1):105-110.
- [13] 田东雨,何玉珠,宋平.基于灰狼优化算法的SVM的图像噪声识别[J].电子测量技术,2019,42(4):90-94.
- [14] KUO D E, WEI M M, KNICKELBEIN J E, et al. Logistic regression classification of primary vitreoretinal lymphoma versus uveitis by interleukin 6 and interleukin 10 levels[J]. Ophthalmology, 2020, 127(7): 956-962.
- [15] GUAN Y, LI X. Multilabel text classification with incomplete labels: a safe generative model with label manifold regularization and confidence constraint[J]. IEEE Multimedia, 2020, 27(4): 38-47.
- [16] NIU X X, SUEN C Y. A novel hybrid CNN-SVM classifier for recognizing handwritten digits [J]. Pattern Recognition, 2012, 45(4): 1318-25.
- [17] 吴彬.基于模型的故障诊断技术及其在电动舵机上的应用[D].湘潭:湘潭大学,2008.

作者简介

杨瑞峰(通信作者),教授,主要研究方向为自动化测试与控制技术。

E-mail:yangruifeng@nuc.edu.cn