

# 基于图像识别的接触器接线缺陷检测

苏煜<sup>1,2</sup>, 王卓涵<sup>1</sup>, 顾玲榕<sup>1</sup>, 常虹<sup>1</sup>

<sup>1</sup>华东理工大学信息科学与工程学院, 上海

<sup>2</sup>华东理工大学机械与动力工程学院, 上海

收稿日期: 2023年12月9日; 录用日期: 2024年1月15日; 发布日期: 2024年1月22日

## 摘要

接触器是自动控制系统中的重要元件之一, 负责接通和切断电路, 起到低电压释放保护作用。考虑到控制系统的复杂性, 若存在接线故障的接触器被投入使用, 不仅有出现电力事故的风险, 也增加了检修难度。因此, 接触器生产制造过程中对其接线正确性的检测工作尤为重要。传统的器件表面缺陷检测主要是以人工检验和物理损伤检测为主, 检验过程耗时费力, 占用大量人力资源。为解决上述问题, 本文采用SVM算法建立基于图像识别的接触器接线缺陷检测模型, 同时, 在检测模型前增加自编码器检测异常图像, 提高SVM检测模型的识别率。通过与KNN、决策树等传统模型的检测结果对比, 验证了本文检测模型的识别效果达到100%的准确率。为满足实际工程需求, 本文将建好的缺陷检测模型部署至树莓派系统, 实现工程应用的小型化和便利化。

## 关键词

缺陷检测, 图像检测, 自编码器, 支持向量机, 树莓派

# Contacting Wiring Defect Detection Based on Image Recognition

Yu Su<sup>1,2</sup>, Zhuohan Wang<sup>1</sup>, Lingrong Gu<sup>1</sup>, Hong Chang<sup>1</sup>

<sup>1</sup>School of Information Science and Engineering, East China University of Science and Technology, Shanghai

<sup>2</sup>School of Mechanical and Power Engineering, East China University of Science and Technology, Shanghai

Received: Dec. 9<sup>th</sup>, 2023; accepted: Jan. 15<sup>th</sup>, 2024; published: Jan. 22<sup>nd</sup>, 2024

## Abstract

The contactor is one of the most important components of the automatic control system, which is responsible for switching the circuit on and off and plays the role of low-voltage trip protection. Given the complexity of the control system, a contactor with wiring faults not only poses a risk of

electrical accidents, but also makes maintenance more difficult. It is therefore particularly important to check the correctness of the wiring when the contactors are manufactured. Conventional surface defect detection is mainly based on manual inspection and physical damage detection, and the inspection process is time-consuming, labor-intensive and requires a lot of manpower. In order to solve the above problems, an SVM algorithm is used in this work to build an image recognition-based model for detecting defects in contactor wiring. By comparing the detection results with those of traditional models such as KNN and decision tree, it is proved that the detection effect of the detection model in this paper achieves 100% accuracy. In order to meet the actual technical requirements, the developed fault detection model is used on the Raspberry Pi system in this paper to achieve the miniaturization and convenience of technical applications.

## Keywords

Defect Detection, Image Detection, Self-Encoder, Support Vector Machine, Raspberry Pi

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



## 1. 引言

智能制造是我国制造强国建设的主攻方向，其发展程度直接关乎我国制造业的质量水平[1]。在此背景下，各行业对于机械设备生产自动化、生产效率和质量的要求都有所提高。对于多种系统装备，接触器可以频繁开闭大电流来控制电路，在装备中作为配电开关，广泛应用于较高电压设备的自动控制系统中[2]。在大规模生产中，接触器接线缺陷往往通过人工筛查，并在发现缺陷后再进行分类处理。人工方法工作量大、成本高，同时受人工工作时长影响，筛查时间受限、效率低下、易出现漏检现象。

目前，机器视觉在表面缺陷检测中的研究逐渐广泛，可使用机器学习算法对识别得到的特征进行分类，从而达到视线缺陷检测的目的，如 SVM 和各类神经网络模型[3] [4]。与传统金属器件的缺陷检测相比，接触器接线部分图像采集难度不高，对光线要求不严格，色彩明显，图像特征突出，接线缺陷部分形态相对固定且特征明显，只包含错接漏接两种类型，非常适合利用机器学习算法采用图像识别技术进行缺陷检测。

本文采用 SVM 算法[5]建立基于图像识别的接触器接线缺陷检测模型，对接触器两种主要接线缺陷漏接和错接进行检测，并将该模型的检测结果与基于 KNN [6]、决策树[7]和 VGG-16 [8] [9]的检测结果进行对比，验证本文模型的检测效率。为降低图像目标检测受到的样本局限性影响，进一步提高泛化能力，利用 Imageio 和 Imgaug 对原始数据集图像进行扩展和增强，以得到精度更高的模型。同时利用自编码器添加异常状态检测，使得模型能够及时对异常输入做出报警。通过对比多种模型在仿真实验中的检测精度，验证模型鲁棒性。

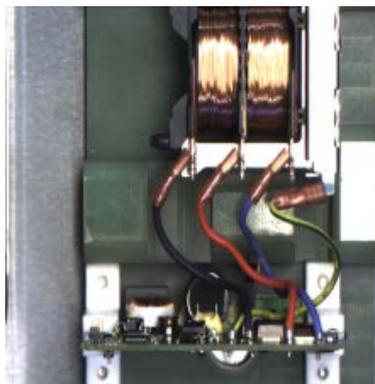
## 2. 接触器接线缺陷图像预处理

基于缺陷检测模型的需要，在对在生产线上的接触器架设摄像机后进行图像采集，建立接触器接线状况数据集，含有两种缺陷类型。数据集中包含固定角度拍摄、不同光照变化下的接触器图片。对缺陷检测模型进行训练，使其可以用于实地检测生产中的接触器接线缺陷。

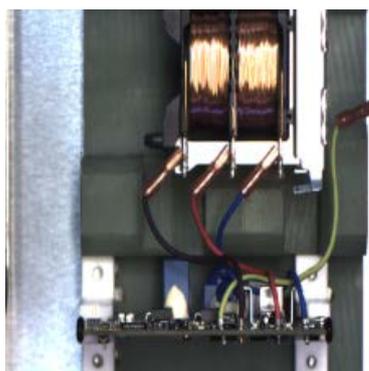
### 2.1. 原始数据集

本文接触器接线缺陷数据来源于某品牌接触器产线的实拍图像，共收集图像数据 161 张。接触器常

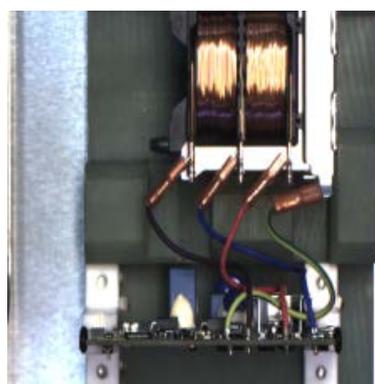
见接线缺陷共两种类型：错接和漏接。原始数据集根据是否有缺陷将图像简单的分为无缺陷(OK)和有缺陷(NG)，代表性原始图像如图 1、图 2、图 3 所示。原始图像数据按 120:31:10 的比例划分为训练集、验证集、测试集。



**Figure 1.** Category I-no defects-OK  
**图 1.** 无缺陷-OK



**Figure 2.** Category II-Defective-NG-Wiring not connected  
**图 2.** 有缺陷-NG (漏接)



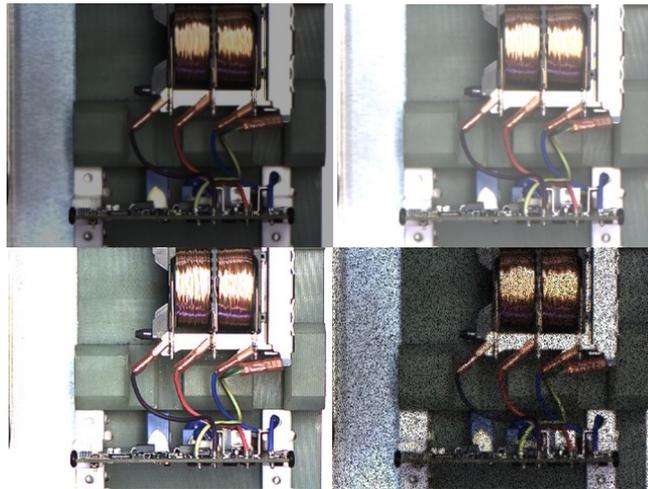
**Figure 3.** Category III-Defective-NG-Incorrect wiring sequence  
**图 3.** 有缺陷-NG (错接)

## 2.2. 图像预处理模型

小样本图像识别任务需要机器学习模型在少量标注数据上进行训练和学习[10]。本文建立的原始数据

集共 161 张，具有缺陷特征的图像共 29 张。为了使用少量样本对模型进行充分训练，需要使用伪数据补充标注不足的小样本数据，并引入充当噪声的辅助数据。

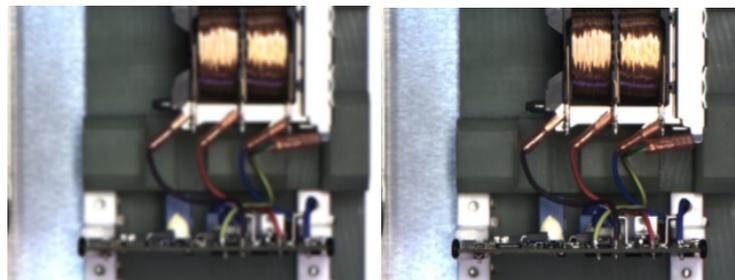
根据文献[11][12]提供的思想，与复杂图像相比接触器图像需要体现的变化形式较少，故将提取特征添加噪声的过程简化为将多种图像增强方式相结合，通过重复处理得到具有更多特性的样本。本文采用高斯变换、均值变换、中值模糊、灰度变换、浮雕处理等 25 种图像处理方法，并利用 `iaa.Sequential()` 和 `iaa.SomeOf()` 函数对上述 25 种处理方法进行部分混合和随机搭配，再生成 15 种增强处理方法，最终实现对每张原始图像 40 次图像增强操作，将 120 张原始训练集扩充至 4800 张，加原始图像 120 张，本文训练集共计 4920 张样本，验证集和测试集不做处理，保持为原始图像。部分经处理后的样本实例如图 4 所示。



**Figure 4.** Samples processed with image enhancement  
**图 4.** 经过图像增强处理的样本

针对图像样本可能存在的问题，如环境噪声、曝光等对图像质量的影响，对图像信号进行恰当的增强和优化处理，增强轮廓和纹理特点，可以使图像特征更加明显，易于识别，从而提升训练效果。

在处理实际生产问题时，图像在拍摄、传输过程中常受到拍摄环境影响或相机性能限制，容易产生噪声干扰。为抑制噪声和改善图像质量，本文采用高斯滤波对整幅图像进行加权平均，在满足图像识别需求对样本减噪的同时可以使模型得到更好的结果，高斯滤波去噪效果实例如图 5 所示。



**Figure 5.** Gaussian filter denoising effect  
**图 5.** 高斯滤波去噪效果

### 3. 基于 SVM 的接触器缺陷检测模型

支持向量机由 Cortes 和 Vapnik 于 1995 年提出[5]，主要用于求解分类和回归问题。但 SVM 具有很强

的适应性和泛化性,接触器接线图像训练样本数据规模小,特征明显,适合使用 SVM 算法进行图像分类。

### 3.1. 参数确定

SVM 模型需要对核函数及其具体参数进行选择。核函数具体分为四项: linear, poly, rbf, sigmoid [13] [14],不同的核函数采用不同的计算方法和不同参数。选择的原则大体可以根据样本和特征的数量进行选择(如特征数量少而样本数量大可以选择高斯核函数,特征数量大到和样本数量差不多可以选用线性核函数),但根据训练样本的结果显示进行选择是最佳方案。

所有核函数中均包括惩罚因子 C 这个可调节的参数。当 C 值过大时,容易出现过拟合;C 值过小时,会出现欠拟合现象。通过网格搜索方法确定支持向量机的最优参数选择。

如图 6 所示,在训练样本上,除了 sigmoid 核函数表现不佳,当惩罚系数为 10 或 100 时,线性核(linear)、多项式核(poly)与高斯核(rbf)精度相似,但两者在验证集上精度下滑,出现不同程度的过拟合现象,高斯核精度更高,故选择高斯核和相应的惩罚系数。

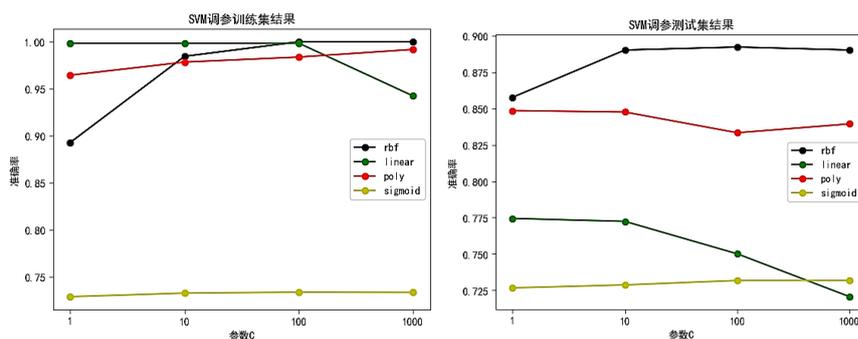


Figure 6. Accuracy of SVM with different kernel functions and penalty coefficients  
图 6. 不同核函数和惩罚系数下 SVM 的训练、测试精度

在高斯核函数中还有一个参数  $\gamma$  需要调节。当  $\gamma$  值过大时,支持向量的辐射范围非常小,将会导致模型过拟合;当  $\gamma$  值过小时,任何一个支持向量都会影响到整个数据集,导致模型类似于具有一组超平面的线性模型,即严重的欠拟合。故最终选择  $C = 100$ ,  $\gamma = 0.0001$  的高斯核作为 SVM 模型的参数,如图 7 所示。

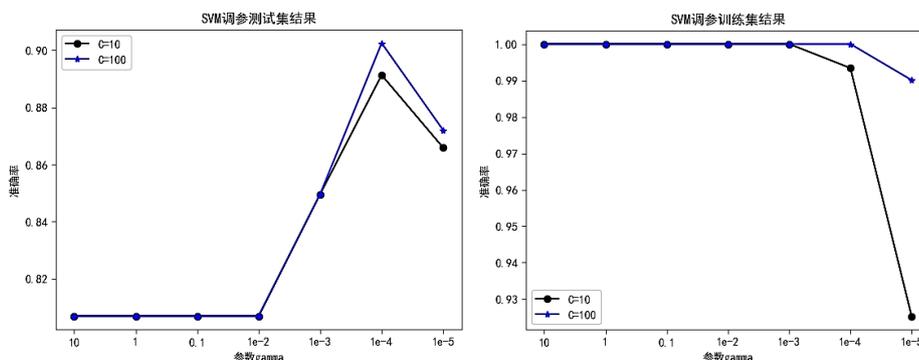


Figure 7. Tuning SVM hyperparameters, training and testing results  
图 7. SVM 调参训练、测试结果

### 3.2. 精度指标

本文所使用的针对目标检测模型的评价指标为准确率(Accuracy, ACC)、均方误差(Mean Squared Error,



续表

OK	1	1	1	1
OK	1	1	1	1
OK	1	1	1	1
OK	1	1	1	1
OK	1	1	1	1
OK	1	1	1	1
OK	1	1	1	1
OK	1	1	1	1
OK	1	1	1	1
OK	1	1	1	1
OK	1	1	1	1
OK	1	1	1	1
OK	1	1	0	1
OK	1	1	0	1
OK	1	1	1	0



Figure 8. Defect detection results

图 8. 缺陷识别结果

#### 4. 图像状态异常检测模型

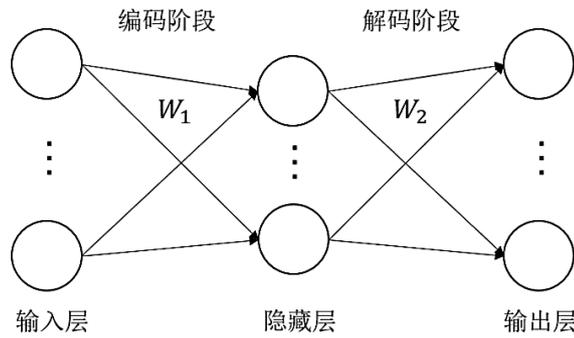
在实际生产线上,可能出现摄像头遮挡或被碰撞后位置歪斜的情况,导致接触器拍摄不全或拍入其他无关场景图像。对于这类图像,SVM模型由于缺乏训练,会将这些样本按接触器有缺陷或无缺陷进行分类,而不会做出混入了非检测器图像的提示。

此时,如果影响没有被排除,那么未来一段时间内传入的图像都是无关场景,即没有拍摄到接触器的图像,显示的分类结果也是SVM模型针对这些图像产生的分类结果,而在这段时间内经过流水线的接触器实际上均未被正确检测,可能导致漏检或误检。

为了解决这类情况,本文在SVM模型之前添加了图像异常检测模型,目的是在识别缺陷之前对图像进行初步筛查,对异常图像做出报警处理,以避免出现上述现象。

由于错误图像的数据类型无法统计,无法使用分类模型,故选择自编码器进行训练,在数据处理阶段直接保留张量,将所有训练集打包为dataloader。

自编码器[15]采用一个含三个隐藏层的神经网络,神经元数分别为10,3,10,统一使用Leak-Relu函数作为激活函数。图9中W1和W2分别为编码阶段和解码阶段的权重,在传统自编码器[16]中分别单独训练。



**Figure 9.** Conventional Self-Encoder Network Diagram  
**图 9.** 传统自编码器网络结构图

自编码器进行故障检测的原理是：对于输入信息  $X$ ，首先通过神经网络进行压缩降维，提取出数据的重要特征，然后再将其解压，得到数据  $Y$ ，再通过对比  $X$  与  $Y$  求出预测误差进行反向传递，逐步提升自编码器模型的准确性。

在模型训练完成后，使用测试集进行在线测试，通过计算测试集原样本和经过模型复原的样本的误差，与训练集的复原误差进行比较，确定控制限，最后进行误报率和漏报率的计算。

设定训练轮次为 200，学习率 0.001，最终得到最大误差与最小误差分别为 0.349 和 0.045，将其作为模型的阈值。

测试集包含 5000 张非目标检测对象图像和 10 张目标检测对象图像，测试结果如表 3 所示，非目标检测对象识别结果如图 10 所示。

**Table 3.** Image anomaly state detection model test results

**表 3.** 图像异常状态检测模型测试结果

	FNR	FPR	ACC
采用前	0	0.84	0.17
采用后	0	0	1



**Figure 10.** Non-detectable object recognition results

**图 10.** 非目标检测对象识别结果

在未采用图像异常状态检测模型的情况下，正确率仅有 0.17，误报率为 0.84，即有 84% 的错误图像被归类至正确类别；采用图像异常状态检测模型后，模型的分类正确率达到 1，所有异常图像均被剔除。

这表明加入图像异常状态检测模型后，系统更加适应实际应用时复杂多变的工况，能够大大提升整个识别系统的可用性和灵活性。

## 5. 模型部署

为实现灵活部署和迅速投入使用，对模型进行封装非常必要。将其部署在树莓派 4B 中，大大增加了灵活性，更能满足生产需要。

### 5.1. 硬件配置

本文选择 Linux raspberrypi 6.1.21 系统，使用树莓派 4 代主板，配置显示屏，可以随时单独使用，也可以通过 VNC 使用 PC 端远程控制操作，硬件系统的外观如图 11 所示。



Figure 11. Hardware equipment used to deploy the system  
图 11. 部署采用的硬件设备

### 5.2. 模型部署和可视化

使用移动存储将模型移植到树莓派上，配置相关环境调试后模型正常运行。通过设置 VNC，可使用同一 wifi 下的 PC 机进行远程连接，如图 12 所示。

通过选择文件进行识别，识别结果会记录在右侧表格中，同时显示图像文件名称、识别时刻和接线正误。

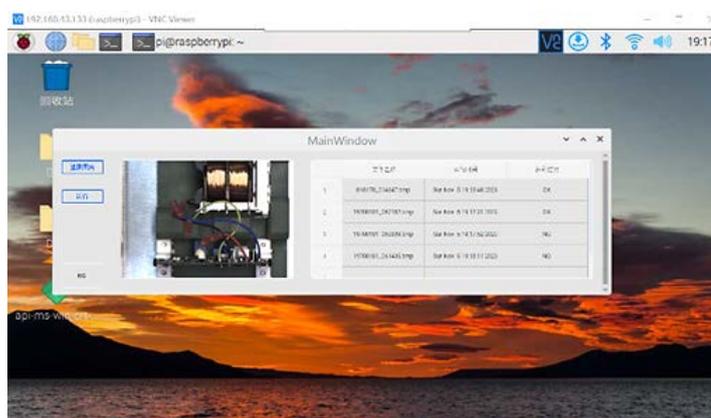


Figure 12. Controlling Raspberry Pi via VNC  
图 12. 通过 VNC 控制树莓派

使用 PC 远程控制树莓派，对模型进行测试。随机选取 4 张图片进行测试，准确率 100%，UI 界面显示正常。

在树莓派系统上对模型进行二次测试，测试结果如表 4 所示。

**Table 4.** Repeat test results  
**表 4.** 重复测试结果

	检测有缺陷	检测无缺陷
实际有缺陷	3	0
实际无缺陷	0	7

## 6. 结语

本文提出一种基于图像识别的接触器接线缺陷检测方法。通过建立接触器接线数据集，将接触器图像划分为有无缺陷两类。

为提升图像识别准确率，对图像进行增强处理，同时利用多种增强方法扩充数据集，在小样本条件下完成模型的训练并验证其鲁棒性。为了处理非目标检测对象，引入自编码器对图像进行筛查，使模型能够处理各种输入情况，及时对非正常输入做出报警，对各类复杂条件下的接触器图像进行缺陷检测。将调试后的模型部署到嵌入式系统上，更加灵活便捷，更符合生产需求。后续将进一步细化缺陷类型，使模型能够更精准地判断接触器接线缺陷类型并给出修改建议，扩充数据集以适应多变的实地检测环境，使缺陷检测能够保持高精度的同时获得更加详细有效的信息。

## 参考文献

- [1] 国务院. “十四五”推进国家政务信息化规划[EB/OL]. [https://www.gov.cn/zhengce/zhengceku/2022-01/06/content\\_5666746.htm](https://www.gov.cn/zhengce/zhengceku/2022-01/06/content_5666746.htm), 2021-12-24.
- [2] 毕德林. 接触器发展方向初探[J]. 机电元件, 2021, 41(1): 57-60.
- [3] Song, K. and Yan, Y. (2013) A Noise Robust Method Based on Completed Local Binary Patterns for Hot-Rolled Steel Strip Surface Defects. *Applied Surface Science*, **285**, 858-864. <https://doi.org/10.1016/j.apsusc.2013.09.002>
- [4] Niskanen, M. and Silvn, O. (2002) Real-Time Aspects of SOM-Based Visual Surface Inspection. *Proceedings of SPIE - The International Society for Optical Engineering*, Singapore, 19-25 January 2002, 123-134. <https://doi.org/10.1117/12.460189>
- [5] Cortes, C. and Vapnik, V. (1995) Support-Vector Networks. *Machine Learning*, **20**, 273-297. <https://doi.org/10.1007/BF00994018>
- [6] Cover, T.M. and Hart, P.E. (1953) Nearest Neighbor Pattern Classification. *IEEE Transactions on Information Theory*, **13**, 21-27. <https://doi.org/10.1109/TIT.1967.1053964>
- [7] Hunt, E.B., Marin, J. and Stone, P.J. (1966) Experiments in Induction. America Press, New York.
- [8] Simonyan, K. and Zisserman, A. (2014) Very Deep Convolutional Networks for Large-Scale Image Recognition. *Computer Science*, **9**, 1409-1556.
- [9] Girshick, R. (2015) Fast R-CNN. 2015 *IEEE International Conference on Computer Vision (ICCV)*, Santiago, 7-13 December 2015, 169. <https://doi.org/10.1109/ICCV.2015.169>
- [10] 刘颖, 等. 基于小样本学习的图像分类技术综述[J]. 自动化学报, 2021, 47(2): 297-315.
- [11] Schwartz, E., et al. (2018) Delta Encoder: An Effective Sample Synthesis Method for FewShotObject Recognition. *Advances in Neural Information Processing Systems*, **31**, 2850-2860.
- [12] 葛轶洲, 等. 小样本困境下的深度学习图像识别综述[J]. 软件学报, 2022, 33(1): 193-210.
- [13] Ajzerman, M.A., Braverman, E.M. and Rozonoehr, L.I. (1964) Theoretical Foundations of the Potential Function Method in Pattern Recognition Learning. *Automation and Remote Control*, **25**, 917-936.
- [14] Broomhead, D.S. and Lowe, D. (1988) Multivariable Functional Interpolation and Adaptive Networks. *Complex Systems*, **2**, 321-355.
- [15] 袁非牛, 章琳, 史劲亭, 等. 自编码神经网络理论及应用综述[J]. 计算机学报, 2019, 42(1): 203-230.
- [16] Kasun, Liyanaarachchi Lekamalage Chamara, et al. (2016) Dimension Reduction with Extreme Learning Machine. *IEEE Transactions on Image Processing*, **25**, 3906-3918. <https://doi.org/10.1109/TIP.2016.2570569>