

# 一种新型半监督极限学习机及其在防震锤锈蚀检测中的应用



王红星<sup>1</sup> 陈玉权<sup>1</sup> 沈杰<sup>1</sup> 张欣<sup>1</sup> 黄祥<sup>1</sup> 于滨<sup>2</sup>

1 江苏方天电力技术有限公司 南京 210036

2 北京航空航天大学 北京 100191

**摘要** 基于机器学习的视觉探伤技术已经被广泛地应用于包括锈蚀检测在内的工业领域。针对已有算法存在的复杂度高、依赖大量人工标注等问题,文中提出了一种新型半监督极限学习机 HyLap-S3ELM,用于防震锤锈蚀缺陷检测。其具有以下优点:模型参数存在封闭解,因此可以直接计算得到,对运算资源的依赖性较小;引入了超图拉普拉斯矩阵,可以更好地描述数据的平滑性,以提升半监督分类的精度;引入了风险正则化项,当数据平滑性假设不准确或者有标注样本存在偏移时,能够提升半监督分类器的稳定性。最后,通过大量实验证明了所提方法的有效性与优越性。

**关键词:**视觉探伤;极限学习机;防震锤;锈蚀检测

**中图分类号** TM734

## Novel Semi-supervised Extreme Learning Machine and its Application in Anti-vibration Hammer Corrosion Detection

WANG Hong-xing<sup>1</sup>, CHEN Yu-quan<sup>1</sup>, SHEN Jie<sup>1</sup>, ZHANG Xin<sup>1</sup>, HUANG Xiang<sup>1</sup> and YU Bin<sup>2</sup>

1 Jiangsu Fangtian Electric Power Technology Co. Ltd, Nanjing 210036, China

2 Beihang University, Beijing 100191, China

**Abstract** Visual inspection based on machine learning has been widely used in industrial fields including rust detection. In view of the existing problems of high complexity and relying on a large number of manual annotation, a new semi-supervised Extreme Learning Machine named HyLap-S3ELM is proposed in this paper and applied to the detection of corrosion defects of shock hammer. Model parameters have closed solutions, so they can be calculated directly and have little dependence on operation resources. A hypergraph Laplacian matrix is introduced to better describe the smoothness of data, so as to improve the accuracy of semi-supervised classification. The risk regularization term is introduced to improve the stability of semi-supervised classifier when the assumption of data smoothness is inaccurate or there is deviation of marked samples. Finally, the effectiveness and superiority of the proposed method are proved by a large number of experiments.

**Keywords** Visual crack detection, ELM(Extreme Learning Machine), Anti-vibration hammer, Corrosion detection

高压架空线路上,靠近绝缘子两侧的导线上常挂一个小锤,这种小锤叫作防振锤,用于减少导线因风力扯起的振动。防振锤安装以后,能产生与导线振动相位相反的运动,从而使导线振动消除或减弱。然而,由于防震锤长时间暴露在空气中,因此其金属锈蚀是一个必须被考虑的问题。相比而言,钢铁材料的锈蚀是不可避免的且在短期内不会产生灾难性的影响。然而,随着时间的推移,锈蚀会愈发严峻,进而导致设备性能的降低甚至失效。如果能及早发现锈蚀并主动采取措施,则可以尽可能地降低成本并消除潜在威胁。由于高压输电线路防震锤距地面较高且常常布设在不方便行动的野外地区,因此无法采用人工采图的手段。目前,市面上已经出现了大量的电力巡检无人机,可以沿着高压输电线飞行并利用机载设备采集图像。通过对航拍图像的识别,我们可以将防震

锤从图像序列中检测出来并评价其锈蚀程度。

锈蚀检测隶属于智能探伤领域。近年来,智能探伤在很多方面都得到了广泛的研究。Choi等<sup>[1]</sup>使用无人机自动收集建筑物外墙图像,然后根据采集到的图像与构造的正射影像之间的几何关系,自动提取高分辨率的感兴趣区域,并最终实现高效的建筑构件视觉检测。Modarres等<sup>[2]</sup>提出了一种基于卷积神经网络(CNN)的方法来识别结构损伤的存在和类型,并通过复合夹层板的脱粘损伤数据进行了实验,验证了CNN在图像尺度、位置和噪声影响的稳健性。Li等<sup>[3]</sup>在结合深度可分卷积、特征金字塔和YOLOv3网络的基础上,提出了YOLOv3-lite网络,可用于机身、发动机叶片等飞机结构的表面损伤检测。结果表明,在几乎不损失检测精度的情况下,YOLOv3-lite的检测速度比YOLOv3快50%以上。Ai

到稿日期:2020-05-19 返修日期:2020-07-08 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:江苏方天电力技术有限公司科技项目(KJ201915)

This work was supported by the Jiangsu Fangtian Electric Power Technology Co. Ltd Research Program(KJ201915).

通信作者:王红星(wanghxf@163.com)

等<sup>[4]</sup>提出了一种基于多尺度邻域信息和像素强度的路面损伤像素级自动检测方法。他们利用像素强度信息,提出了一种基于概率生成模型(PGM)的方法来计算每个像素的裂纹概率,与一种基于支持向量机(SVM)的概率图计算方法,并最终将通过 PGM 和 SVM 两种方法得到的多个概率图融合到一个融合图中,实现了比任何原始概率图更高精度的损伤检测。Bohnenkamp 等<sup>[5]</sup>利用地面车辆和无人机两个测量平台获取植物的高光谱图像,进而实现了对小麦黄锈病的检测与量化。相关的研究较多,文献[6-9]展示了更多的基于外观的智能视觉探伤方法。

类似于已有的智能探伤技术,由于锈蚀可以从外表观测发现,因此我们也可以采用机器视觉技术实现智能锈蚀检测。Son 等<sup>[10]</sup>提出了一种用于机器人维修系统的钢桥表面锈蚀区域的快速自动测定方法,其包含 3 个步骤:颜色空间转换、基于决策树算法的腐蚀区域分类以及锈蚀区域显示。该研究利用 RGB 到 HSI 颜色空间的颜色空间变换和像素级分类来检测锈蚀区域。在像素级分类方面,采用了包括支持向量机(SVM)、反向传播神经网络(BPNN)、决策树(J48)、Naive-Bayes (NB)、逻辑回归(LR)、K 近邻(KNN)在内的多种方法。Hoang 等<sup>[11]</sup>提出了一种基于图像处理的管道锈蚀检测自动化方法,该方法利用图像颜色统计测量、灰度共生矩阵、灰度运行长度等图像纹理提取管道表面特征,然后利用差分花传粉优化的支持向量机,构造一个能够识别腐蚀和完整管道表面的决策边界,分类精度可达 92% 以上。Ma 等<sup>[12]</sup>采用支持向量机(SVM)实现了管道腐蚀的速率预测,并针对 SVM 超参数难以确定的问题,引入了粒子群算法(PSO)进行参数寻优以得到最佳的 SVM 模型。Chen 等<sup>[13]</sup>通过对腐蚀图像依次进行灰度化、亮度增强、小波分割等操作,实现了特征的人工提取,并采用支持向量机(SVM)实现了 CO<sub>2</sub> 腐蚀类型的准确识别。

传统的机器学习需要手动提取特征,因此依赖于专家知识的可靠性。深度神经网络的出现避免了手动特征提取的风险,能够从图像中自动提取具有区分性的高层抽象特征,进而实现更加准确、可靠的目标分类。近几年,锈蚀检测领域也开始出现基于深度学习的检测技术。Atha 等<sup>[14]</sup>研究了不同的卷积神经网络方法在金属表面锈蚀预测中的应用效果,并对不同的颜色空间、滑动窗口大小和卷积神经网络体系结构对结果的影响进行了讨论。Bastian 等<sup>[15]</sup>提出了一种基于计算机视觉的管道锈蚀检测方法,提出了一种轻量化的 CNN,其具有更少的参数,能够有效区分锈蚀管道图像和没有锈蚀但有与锈蚀管道相似图案的图像,分类精度可达 98% 以上。他们还提出了一种基于递归区域法的局部化算法,可以有选择地识别出给定图像中的锈蚀区域。Ma 等<sup>[16]</sup>基于卷积神经网络提出了一种鲁棒的锈蚀特征提取方法,可以在图像中存在大量噪声的情况下准确识别锈蚀区域。Yuan 等<sup>[17]</sup>提出了一种基于 RPN-FCN 的新型锈病检测方法,其利用 RPN 生成区域建议,并对锈蚀的语义分割进行全卷积。实验结果表明,与其他神经网络相比,该方法能显著提高铁锈检测的准确性。

虽然已经出现了锈蚀检测的相关研究,但它们共同存在以下问题。

(1)计算复杂度较高。由于锈蚀检测往往要在无人机上实现,因此采用神经网络会占用大量的运算资源;同时,由于无人机是电池供电的,因此在占用运算资源的同时,也会增加无人机的耗电量,缩短其持续运行时间。

(2)需要大量人工标注。由于模型的训练是基于数据的,因此无人机采集的图像需要人工标注。传统的模型,特别是深度神经网络的训练依赖于大量的有标注样本,这就对人工标注提出了极大的要求,显著增加了人员的工作量。

因此,本文提出了一种基于 HyLap-S<sup>3</sup> ELM 的防震锤锈蚀缺陷检测方法,该方法的全名为超图拉普拉斯-半监督极限学习机(Hypergraph Laplacian Safe Semi-Supervised Extreme Learning Machine, HyLap-S<sup>3</sup> ELM),其创新点如下:

(1)基于极限学习机(ELM)开发的分类器,由于 ELM 的参数存在封闭解,因此可以直接计算得到,其对运算资源的依赖性较小;

(2)引入了超图拉普拉斯矩阵,可以更好地描述数据的平滑性,以提升半监督分类的精度;

(3)引入了风险正则化项,当数据平滑性假设不准确或者有标注样本存在偏移时,能够提升半监督分类器的稳定性。

## 1 超图拉普拉斯-半监督极限学习机

本文系统流程图如图 1 所示。对于每张图像,采用一种或几种固定大小的窗口对其进行随机分割,以得到一系列子图,且期望每个子图中尽可能仅包含一种物体。图 1 中,蓝色箭头表示训练过程,红色箭头都表示在线预测过程。对于每张子图,利用 SIFT 等局部描述子提取图像的特征点。由于生成非常多的特征点,因此一般会利用 K-Means 聚类等方法将特征点分成  $K$  类。这里的每个类称为一个词(word)或者一个特征(feature)。通过这样的操作,我们可以将每个图像转换成  $K$  维的特征向量。

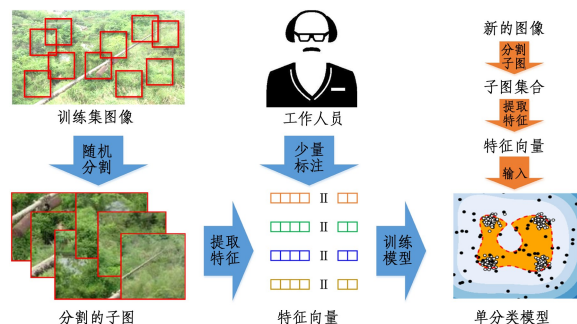


图 1 系统流程图(电子版为彩色)

Fig. 1 Illustration of system workflow

### 1.1 极限学习机

极限学习机由 Huang 教授提出,下面给出了 ELM 的基本思路<sup>[18]</sup>。考虑一个有  $N$  个样本的训练集的监督学习问题,  $\{\mathbf{X}, \mathbf{Y}\} = \{\mathbf{x}_i, \mathbf{y}_i\}_{i=1}^N$ , 其中,  $\mathbf{x}_i \in \mathbb{R}^n$ 。在多元分类任务中  $\mathbf{y}_i$  是一个  $n_c$  维的二进制向量,在回归任务中  $\mathbf{y}_i \in \mathbb{R}^n$ 。其中,  $n_i$  和  $n_o$  分别是输入和输出的维度。ELM 旨在学习基于训练数据的决策规则或近似函数。

一般而言,ELM 的训练分为两个阶段。第一步是使用固

定数量的随机生成的映射神经元构建隐含层,映射神经元可以是任意的非线性分段连续函数,如 Sigmoid 函数和 Gaussian 函数。

$$g(\mathbf{x};\theta) = \frac{1}{1 + \exp(-(\mathbf{a}^T \mathbf{x} + b))}$$

$$g(\mathbf{x};\theta) = \exp(-b \|\mathbf{x} - \mathbf{a}\|)$$

其中,  $\theta = \{\mathbf{a}, b\}$  为映射函数的参数。

ELM 的一个显著特征是输入层到隐藏层的映射函数参数可以根据任何连续概率分布随机生成,因此 ELM 有别于传统的前馈神经网络和支持向量机。唯一需要优化训练的参数是隐藏层到输出层的输出权重,而其求解过程相当于解决一个正则化最小二乘问题,因此构造 ELM 模型相比神经网络的反向传播学习具有极高的效率。

我们用  $h(\mathbf{x}_i) \in \mathbb{R}^{n_h \times n_h}$  表示输入  $\mathbf{x}_i$  时隐藏层的输出,  $\boldsymbol{\beta} \in \mathbb{R}^{n_h \times n_o}$  表示隐藏层到输出层的权重,进而 ELM 模型可以表示为:

$$f(\mathbf{x}_i) = h(\mathbf{x}_i) \boldsymbol{\beta}, i = 1, \dots, N$$

接着,通过最小化预测误差损失与模型复杂度来求解输出权值,具体如下:

$$\min_{\boldsymbol{\beta} \in \mathbb{R}^{n_h \times n_o}} \frac{1}{2} \|\boldsymbol{\beta}\|^2 + \frac{C}{2} \sum_{i=1}^N \|\mathbf{e}_i\|^2$$

$$\text{s. t. } h(\mathbf{x}_i) \boldsymbol{\beta} = \mathbf{y}_i^T - \mathbf{e}_i^T, i = 1, \dots, N$$

其中,第一项目标函数用于防止过拟合,  $\mathbf{e}_i \in \mathbb{R}^{n_o}$  为  $\mathbf{x}_i$  的预测误差,系数  $C$  为惩罚系数。通过将上式中的约束项带入目标函数中,我们可以得到以下等价的无约束优化问题:

$$\min_{\boldsymbol{\beta} \in \mathbb{R}^{n_h \times n_o}} L_{ELM} = \frac{1}{2} \|\boldsymbol{\beta}\|^2 + \frac{C}{2} \|\mathbf{Y} - \mathbf{H}\boldsymbol{\beta}\|^2$$

其中,  $\mathbf{H} = [h(\mathbf{x}_1)^T, \dots, h(\mathbf{x}_N)^T]^T \in \mathbb{R}^{N \times n_h}$ 。进而,令  $L_{ELM}$  的相对于  $\boldsymbol{\beta}$  的梯度为 0,即:

$$\nabla L_{ELM} = \boldsymbol{\beta} - \mathbf{C}\mathbf{H}^T(\mathbf{Y} - \mathbf{H}\boldsymbol{\beta}) = 0$$

进而,我们可以得到最优  $\boldsymbol{\beta}$  的闭环解。如果  $\mathbf{H}$  的行数大于列数且为列满秩,此时训练样本多余隐藏神经元数,则上述方程为超定方程,有:

$$\boldsymbol{\beta}^* = (\mathbf{H}^T \mathbf{H} + \frac{\mathbf{I}_{n_h}}{C})^{-1} \mathbf{H}^T \mathbf{Y}$$

其中,  $\mathbf{I}_{n_h}$  为  $n_h$  维的单位阵。如果训练样本的数量小于隐藏神经元的数量,则  $\mathbf{H}$  的列数将大于行数,则上述方程为欠定方程。在这种情况下,  $\boldsymbol{\beta}$  的解不是唯一的。我们限制  $\boldsymbol{\beta}$  在  $\mathbf{H}$  行向量的线性组合上,因此可得:

$$\boldsymbol{\beta}^* = \mathbf{H}^T (\mathbf{H}\mathbf{H}^T + \frac{\mathbf{I}_N}{C})^{-1} \mathbf{Y}$$

其中,  $\mathbf{I}_N$  为  $N$  维的单位矩阵。

### 1.2 半监督极限学习机 ( $S^2$ ELM)

在半监督的情况下,标记数据较少而未标记数据较多。我们将训练集中的有标注数据表示为  $\{X_l, Y_l\} = \{\mathbf{x}_i, \mathbf{y}_i\}_{i=1}^l$ , 无标注数据表示为  $X_u = \{\mathbf{x}_i\}_{i=1}^u$ , 其中  $l$  和  $u$  分别表示有标注数据和无标注数据的数量。

本文中  $S^2$  ELM 采用流形正则化来利用未标记数据,以提高有标注数据不足时的分类精度。容易得到  $S^2$  ELM 为:

$$\min_{\boldsymbol{\beta} \in \mathbb{R}^{n_h \times n_o}} \frac{1}{2} \|\boldsymbol{\beta}\|^2 + \frac{1}{2} \sum_{i=1}^l C_i \|\mathbf{e}_i\|^2 + \frac{\lambda}{2} \text{tr}(\mathbf{F}^T \mathbf{L} \mathbf{F})$$

$$\text{s. t. } h(\mathbf{x}_i) \boldsymbol{\beta} = \mathbf{y}_i^T - \mathbf{e}_i^T, i = 1, \dots, l,$$

$$f_i = h(\mathbf{x}_i) \boldsymbol{\beta}, i = 1, \dots, l+u$$

其中,  $\mathbf{L} \in \mathbb{R}^{(l+u) \times (l+u)}$  是超图 Laplacian 拉斯矩阵,  $\mathbf{F} \in \mathbb{R}^{N \times n_o}$  为网络的输出矩阵,其行向量为  $f(x_i)$ ,  $\lambda$  为权衡系数。考虑到类不平衡的特性,在上式中我们引入了  $C_i$  对不同的训练样本的预测误差进行加权,  $C_i = \frac{C_0}{N_{y_i}}$ , 其中  $C_0$  为人工定义的参数,  $N_{y_i}$  为样本  $\mathbf{x}_i$  对应的  $\mathbf{y}_i$  的样本数量。这样,训练的模型就不会过度拟合多数类的数据,也不会忽略少数类的数据。

将上式中的约束项带入到目标函数中,我们可以得到以下等价的无约束优化问题:

$$\min_{\boldsymbol{\beta} \in \mathbb{R}^{n_h \times n_o}} L_{S^2 ELM} = \frac{1}{2} \|\boldsymbol{\beta}\|^2 + \frac{1}{2} \|\mathbf{C}^{\frac{1}{2}}(\bar{\mathbf{Y}} - \mathbf{H}\boldsymbol{\beta})\|^2 + \frac{\lambda}{2} \text{tr}(\boldsymbol{\beta}^T \mathbf{H}^T \mathbf{L} \mathbf{H} \boldsymbol{\beta})$$

其中,  $\bar{\mathbf{Y}} \in \mathbb{R}^{N \times n_o}$  的前  $l$  行等于  $\mathbf{Y}$ , 后  $u$  行等于 0,  $\mathbf{C}$  为  $N \times N$  的对角阵,其前  $l$  个对角元素为  $C_i$ , 后  $u$  个对角元素为 0。进而,令  $L_{S^2 ELM}$  相对于  $\boldsymbol{\beta}$  的梯度为 0,即:

$$\nabla L_{S^2 ELM} = \boldsymbol{\beta} + \mathbf{H}^T \mathbf{C}(\bar{\mathbf{Y}} - \mathbf{H}\boldsymbol{\beta}) + \lambda \mathbf{H}^T \mathbf{L} \mathbf{H} \boldsymbol{\beta} = 0$$

进而,我们可以得到最优  $\boldsymbol{\beta}$  的闭环解。如果训练样本多余隐藏神经元数,则上述方程为超定方程,有:

$$\boldsymbol{\beta}^* = (\mathbf{I}_{n_h} + \mathbf{H}^T \mathbf{C} \mathbf{H} + \lambda \mathbf{H}^T \mathbf{L} \mathbf{H})^{-1} \mathbf{H}^T \mathbf{C} \bar{\mathbf{Y}}$$

其中,  $\mathbf{I}_{n_h}$  为  $n_h$  维的单位矩阵,否则:

$$\boldsymbol{\beta}^* = \mathbf{H}^T (\mathbf{I}_N + \mathbf{C} \mathbf{H} \mathbf{H}^T + \lambda \mathbf{L} \mathbf{H} \mathbf{H}^T)^{-1} \mathbf{C} \bar{\mathbf{Y}}$$

其中,  $\mathbf{I}_N$  为  $N$  维的单位矩阵。

### 1.3 安全半监督极限学习机 ( $S^3$ ELM)

由于半监督机制的引入可能会导致精度下降,因此本文引入风险正则化项  $\mathcal{R}$  来提升分类模型的安全性。修改  $L_{S^2 ELM}$  可以得到:

$$\min_{\boldsymbol{\beta} \in \mathbb{R}^{n_h \times n_o}} L_{S^3 ELM} = \frac{1}{2} \|\boldsymbol{\beta}\|^2 + \frac{1}{2} \|\mathbf{C}^{\frac{1}{2}}(\bar{\mathbf{Y}} - \mathbf{H}\boldsymbol{\beta})\|^2 + \frac{\lambda_1}{2} \text{tr}(\boldsymbol{\beta}^T \mathbf{H}^T \mathbf{L} \mathbf{H} \boldsymbol{\beta}) + \frac{\lambda_2}{2} \mathcal{R}$$

其中,  $\mathcal{R} = \sum_{j=1}^u s_j \|\hat{\mathbf{y}}_j - \check{\mathbf{y}}_j\|^2$ ,  $\hat{\mathbf{y}}_j$  为 ELM 的输出向量,  $\check{\mathbf{y}}_j$  为  $S^2$  ELM 的输出向量。当 ELM 与  $S^2$  ELM 的预测值不同时,则  $s_j = 1$ , 否则  $s_j = 0$ 。进而,  $\mathcal{R}$  可以重写为:

$$\mathcal{R} = (\mathbf{H}_u \boldsymbol{\beta} - \mathbf{H}_u \hat{\boldsymbol{\beta}})^T \mathbf{S} (\mathbf{H}_u \boldsymbol{\beta} - \mathbf{H}_u \hat{\boldsymbol{\beta}})$$

其中,  $\mathbf{H}_u$  是  $\mathbf{X}_u$  的隐藏层输出,  $\hat{\boldsymbol{\beta}}$  为 ELM 的输出权重向量,  $\mathbf{S} = \text{diag}(s_1, \dots, s_u)$ 。令  $L_{S^3 ELM}$  相对于  $\boldsymbol{\beta}$  的梯度为 0,即:

$$\nabla L_{S^3 ELM} = \boldsymbol{\beta} + \mathbf{H}^T \mathbf{C}(\bar{\mathbf{Y}} - \mathbf{H}\boldsymbol{\beta}) + \lambda_1 \mathbf{H}^T \mathbf{L} \mathbf{H} \boldsymbol{\beta} + \lambda_2 \mathbf{H}_u \mathbf{S} (\mathbf{H}_u \boldsymbol{\beta} - \mathbf{H}_u \hat{\boldsymbol{\beta}}) = 0$$

进而,我们可以得到最优  $\boldsymbol{\beta}$  的闭环解。如果训练样本多余隐藏神经元数,则上述方程为超定方程,有:

$$\boldsymbol{\beta}^* = (\mathbf{I}_{n_h} + \mathbf{H}^T \mathbf{C} \mathbf{H} + \lambda_1 \mathbf{H}^T \mathbf{L} \mathbf{H} + \lambda_2 \mathbf{H}_u^T \mathbf{S} \mathbf{H}_u)^{-1} (\mathbf{H}^T \mathbf{C} \bar{\mathbf{Y}} + \lambda_2 \mathbf{H}_u^T \mathbf{S} \mathbf{H}_u \hat{\boldsymbol{\beta}})$$

其中,  $\mathbf{I}_{n_h}$  为  $n_h$  维的单位矩阵,否则:

$$\boldsymbol{\beta}^* = \mathbf{H}^T (\mathbf{I}_N + \mathbf{C} \mathbf{H} \mathbf{H}^T + \lambda_1 \mathbf{L} \mathbf{H} \mathbf{H}^T + \lambda_2 \bar{\mathbf{S}} \mathbf{H} \mathbf{H}^T)^{-1} (\mathbf{C} \bar{\mathbf{Y}} + \lambda_2 \bar{\mathbf{S}} \mathbf{H} \hat{\boldsymbol{\beta}})$$

其中,  $\mathbf{I}_N$  为  $N$  维的单位矩阵,  $\bar{\mathbf{S}}$  为  $N \times N$  的对角矩阵,其前  $l$  个对角元素为 0, 后  $u$  个对角元素为  $\mathbf{S}$ 。

### 1.4 超图拉普拉斯矩阵 (HyLap)

本小节将介绍超图 Laplacian 矩阵的获取方法。在机器

学习问题中,我们通常假设数据之间是两两关系,一个被赋予两两关系的数据集可以被认为是一个图,图形可以是无向的,也可以是定向的。然而,在一些问题中,仅仅使用简单的图来表示样本之间的关系是不完整的。超图学习则解决了这个问题。与传统图相比,超图通过连接3个或多个顶点的超边来表示数据中的复杂关系。

定义  $V$  为顶点(样本)的集合,  $E$  为  $V$  子集的一个簇且满足  $\bigcup_{e \in E} e = V$ , 这样就形成了一个超图  $G(V, E)$ 。将每个超边  $e$  的权值表示为  $w(e)$ , 每个顶点  $v$  的度定义为  $d(v) = \sum_{e \in E | v \in e} w(e)$ , 每个超边  $e$  的度定义为  $\delta(e) = |e|$ 。用一个  $|V| \times |E|$  大小的矩阵表示事件矩阵  $Q$ , 如果  $v \in e$ , 则  $q(v, e) = 1$ , 否则  $q(v, e) = 0$ 。

$$d(v) = \sum_{e \in E} w(e)q(v, e)$$

$$\delta(e) = \sum_{v \in V} q(v, e)$$

设  $D_v$  为包含顶点度数的对角矩阵,  $D_e$  为各超边度数的对角矩阵,  $W$  为边权的对角矩阵, 然后定义超图 Laplacian 矩阵。目前有许多方法来建立超图的 Laplacian 矩阵, 第一类方法是在原始超图的基础上构造一个简单的图, 然后利用谱聚类技术对顶点进行划分; 第二类方法使用简单图的 Laplacian 矩阵的类比来定义超图 Laplacian 矩阵。

$$L = I - D_v^{-1/2} H W D_e^{-1} H^T D_v^{-1/2}$$

如果将超图的邻接矩阵表示为:

$$W = H W H^T - D_e$$

将  $D_e$  表示为  $2I$ , 就可以得到简单图的 Laplacian 矩阵:

$$L = I - \frac{1}{2} D_v^{-1/2} H W H^T D_v^{-1/2} = \frac{1}{2} (I - D_v^{-1/2} W D_v^{-1/2})$$

## 2 实验

本文从无人机巡检视频中提取出了 20 000 张图片, 有 1 043 张图片出现了防震锤, 有 728 张图片出现了不同程度的锈蚀情况, 按照锈蚀的程度可以分为严重锈蚀、中度锈蚀与轻度锈蚀。实验数据概况如表 1 所列, 由表可知数据是严重不均衡的。如果不引入加权机制提高对小类别样本训练损失的权重, 分类器可能无法识别含有防震锤的图片, 从而将所有图片都归类为无关图片。

表 1 实验数据概况

Table 1 Outline of experiment data

|      | 样本数量  | 样本比例/% |
|------|-------|--------|
| 严重锈蚀 | 105   | 0.52   |
| 中度锈蚀 | 236   | 1.18   |
| 轻度锈蚀 | 387   | 1.94   |
| 无锈蚀  | 315   | 1.58   |
| 无关   | 18957 | 94.78  |

本文从每类中取出 20% 作为测试集, 将剩下的 80% 作为训练集。采用随机抽取的方式建立测试集, 一共随机抽取 10 次。在训练集与测试集固定以后, 每次进行半监督实验时, 随机抽取一定比例的数据作为有标注数据, 并在同一标注比例下随机抽取 10 次。因此, 在同一标注比例下, 同一算法需要进行 100 次实验。由于 5 个类别的样本数量极不均衡, 因此本文采用每类的正确率的平均值 Acc 来评价算法的性能。我们观察 100 次实验中的最低精度 AccL、最高精度 AccH 与

平均精度 AccM。其中, 平均精度反映了算法的分类精度, 最低最高精度反映了算法的稳定性。实验设备为台式计算机, 拥有 Core7 处理器、3.4 GHz 主频与 8GB 的 RAM。编程语言为 Python, 集成编译环境为 Spyder。模型参数设定如下:  $C = 10^{-2}$ ,  $\lambda_1 = 10^{-6}$ ,  $\lambda_2 = 10^{-1}$ ,  $N_h = 1 000$ 。众所周知, ELM 作为一种三层神经网络, 其输入层到隐藏层的参数是随机生成的, 且隐藏层到输出层的参数是解析的, 因此 ELM 具有极高的运算效率。相比已有的基于深度学习的方法, ELM 具有较低的算法复杂度。因此, 为了体现本文算法的优越性, 我们选择两种监督学习算法(SVM 与 ELM)以及两种半监督学习算法(LapSVM 和 LapELM)进行比较实验。

在标注样本为 10% 的情况下, 各种算法的最低精度、最高精度与平均精度如表 2 所列。显然, 作为两种半监督学习算法, LapSVM 与 LapELM 的稳定性并不理想。在最坏情况下, 半监督学习方法的最低精度有可能会低于监督学习方法。为了体现本文算法的稳定性, 我们将 Lap-S<sup>3</sup> ELM 与 Lap-S<sup>2</sup> ELM(即 LapELM)进行比较。容易看出: 引入了风险正则化项之后, 虽然平均精度与最高精度几乎持平(这是由于风险正则化项会一定程度上引入保守性), 但是其最低精度得到了显著提升。因此, 本文方法的安全性得到了验证, 其稳定性高于已有的算法。进一步引入超图 Laplacian 矩阵后, 分类精度再次得到提升。各种算法的平均训练时间如表 3 所列。从表 3 中可以观察到, 基于 ELM 设计的算法往往比 SVM 消耗更短的训练时间, 本文所提出的 HyLap-S<sup>3</sup> ELM 的训练时间相比已有算法并不会显著增加, 一定程度上保证了实时性。

表 2 各种算法的最低精度、最高精度与平均精度

Table 2 AccL, AccH and AccM of different algorithms

(单位: %)

| 算法                       | 平均精度 | 最高精度 | 最低精度 |
|--------------------------|------|------|------|
| SVM                      | 59.3 | 63.5 | 54.7 |
| ELM                      | 61.9 | 66.8 | 51.3 |
| LapSVM                   | 75.6 | 82.8 | 45.3 |
| LapELM                   | 76.2 | 86.3 | 44.6 |
| Lap-S <sup>3</sup> ELM   | 76.8 | 84.4 | 70.5 |
| HyLap-S <sup>3</sup> ELM | 80.4 | 92   | 74.3 |

表 3 各种算法的平均训练时间

Table 3 Mean training time of different algorithms

(单位: s)

| 算法                       | 平均训练时间 |
|--------------------------|--------|
| SVM                      | 12.63  |
| ELM                      | 9.98   |
| LapSVM                   | 15.29  |
| LapELM                   | 13.21  |
| HyLap-S <sup>3</sup> ELM | 15.36  |

图 2 给出了部分结果, 我们采用了两种大小的正方形窗口来获取候选子图。从图 2(a)能够看出, 当无人机摄像头距离传输线较远时, 两种大小窗口均可以捕捉到锈蚀的防震锤。在图 2(b)中, 摄像头距离防震锤较近, 因此我们仅仅展示了大窗口捕获的结果。由图 2 可知, 锈蚀部分基本能够被准确识别, 但防震锤下方的水洼也被误识别为防震锤的一个部分, 因此一定程度上提高了虚警率。




图2 部分结果展示

Fig. 2 Partial results presentation

**结束语** 本文提出了一种基于 HyLap-S<sup>3</sup> ELM 的防震锤锈蚀缺陷检测方法。该方法应用了极限学习机(ELM)作为原型分类器进行了二次开发,显著降低了系统对运算资源的依赖性,提升了训练速度;引入了超图 Laplacian 矩阵,可以更好地描述数据的平滑性,能够显著提升半监督分类的精度;同时,引入了风险正则化项,当数据平滑性假设不准确或者有标注样本存在偏移时,能够显著提升半监督分类器的稳定性。在未来的研究中,可以考虑引入自编码器来自动提取更为有效的特征,以进一步提升分类精度。

### 参 考 文 献

- [1] CHOI J, YEUM C, DYKE S, et al. Computer-aided approach for rapid post-event visual evaluation of a building facade[J]. *Sensors*, 2018, 18(9):3017.
- [2] MODARRES C, ASTORGA N, DROGUETT E L, et al. Convolutional neural networks for automated damage recognition and damage type identification[J]. *Structural Control and Health Monitoring*, 2018, 25(10):e2230. 1-e2330. 17.
- [3] LI Y, HAN Z, XU H, et al. YOLOv3-Lite: A Lightweight Crack Detection Network for Aircraft Structure Based on Depthwise Separable Convolutions[J]. *Applied Sciences*, 2019, 9(18):3781.
- [4] AI D, JIANG G, KEI L S, et al. Automatic pixel-level pavement crack detection using information of multi-scale neighborhoods[J]. *IEEE Access*, 2018, 6:24452-24463.
- [5] BOHNENKAMP D, BEHMANN J, MAHLEIN A K. In-Field Detection of Yellow Rust in Wheat on the Ground Canopy and UAV Scale[J]. *Remote Sensing*, 2019, 11(21):2495.
- [6] OLIVERI G, DING P P, POLI L. 3-D crack detection in anisotropic layered media through a sparseness-regularized solver[J]. *IEEE Antennas and Wireless Propagation Letters*, 2014, 14:1031-1034.
- [7] LIU K, LIU Z G, CHEN J W. Crack Detection of Messenger Wire Supporter in Catenary Support Devices of High-speed Railway Based on Faster R-CNN[J]. *Journal of the China railway Society*, 2019, 41(7):43-49.
- [8] LANDSTROM A, THURLEY M J. Morphology-based crack detection for steel slabs[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2012, 6(7):866-875.
- [9] CHEN F C, JAHANSHAHIM R. NB-CNN: deep learning-based crack detection using convolutional neural network and Naive Bayes data fusion[J]. *IEEE Transactions on Industrial Electronics*, 2017, 65(5):4392-4400.
- [10] SON H, HWANG N, KIM C, et al. Rapid and automated determination of rusted surface areas of a steel bridge for robotic maintenance systems[J]. *Automation in Construction*, 2014, 42:13-24.
- [11] HOANG N D, TRAN V D. Image Processing Based Detection of Pipe Corrosion Using Texture Analysis and Metaheuristic-Optimized Machine Learning Approach[J/OL]. *Computational Intelligence and Neuroscience*, 2019. [https://www.researchgate.net/publication/334050676\\_Image\\_Processing\\_Based\\_Detection\\_of\\_Pipe\\_Corrosion\\_Using\\_Texture\\_Analysis\\_and\\_Metaheuristic-Optimized\\_Machine\\_Learning\\_Approach](https://www.researchgate.net/publication/334050676_Image_Processing_Based_Detection_of_Pipe_Corrosion_Using_Texture_Analysis_and_Metaheuristic-Optimized_Machine_Learning_Approach).
- [12] MA G, LI J F, BAI R, et al. Prediction of Corrosion Rate in Oil and Gas Pipelines Based on PSO-SVM Model[J]. *Surface Technology*, 2019, 48(5):43-48.
- [13] CHEN G J, JIA C Y, ZOU L Q, et al. Study on CO<sub>2</sub> Corrosion Recognition Method Based on SVM[J]. *Chemical Engineering & Machinery*, 2014, 41(6):742-745.
- [14] ATHA D J, JAHANSHAHI M R. Evaluation of deep learning approaches based on convolutional neural networks for corrosion detection[J]. *Structural Health Monitoring*, 2018, 17(5):1110-1128.
- [15] BASTIAN B T, JASPREETH N, RANJITHS K, et al. Visual inspection and characterization of external corrosion in pipelines using deep neural network[J]. *NDT & E International*, 2019, 107:102134. 1-102134. 11.
- [16] MA Y, YANG Y, YAO Y, et al. Image-based corrosion recognition for ship steel structures[C]// *Smart Structures and NDE for Industry 4.0*. International Society for Optics and Photonics, 2018:106020U. 1-106020U. 7.
- [17] YUAN J, XUE B, ZHANG W, et al. RPN-FCN based Rust detection on power equipment[J]. *Procedia computer science*, 2019, 147:349-353.
- [18] HUANG G B, ZHU Q Y, SIEWC K. Extreme learning machine: theory and applications[J]. *Neurocomputing*, 2006, 70(1/2/3):489-501.



**WANG Hong-xing**, born in 1974, master, professor level senior engineer, member of electromagnetic interference special committee of Chinese Society for Electrical Engineering. Research directions include intelligent inspection technology of UAV for transmission line, automatic path planning of UAV, etc.