

基于秩正则几何变换的无监督字符缺陷检测

苗相彬,罗建桥,李柏林

(西南交通大学 机械工程学院,四川 成都 610031)

摘要:针对基于几何变换(GT)的异常检测忽略了特征紧凑性,难以准确区分高度相似的合格与缺陷字符的问题,定义秩正则损失鼓励紧凑特征表达,提出基于秩正则几何变换(RRGT)的字符缺陷检测算法。无监督异常检测仅使用正常样本(合格字符)作为训练集,RRGT对训练样本进行不同类型的几何变换。定义秩正则损失训练网络模型识别正常样本的变换类型。秩正则迫使同类变换的特征矩阵具有较小的秩,从而鼓励特征紧凑性。推理阶段使用网络预测施加在新样本上的变换类型。由于网络未使用异常样本(缺陷字符)训练,网络对异常样本的预测不确定性高,由不确定性可以检出异常样本。在旺旺牛奶盒喷点字符上的实验表明:相比GT,RRGT大幅提升了网络对缺陷字符预测不确定性的识别能力,缺陷检测的AUC值提高了4.8%。

关键词:字符缺陷检测;无监督异常检测;几何变换;卷积神经网络;秩正则

中图分类号:TP391.41 **文献标志码:**A **文章编号:**1671-5276(2023)05-0127-07

Unsupervised Character Defect Detection Based on Rank-regularized Geometric Transformations

MIAO Xiangbin, LUO Jianqiao, LI Bailin

(School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031, China)

Abstract: To overcome the difficulty in distinguishing highly similar qualified and defective characters by anomaly detection method based on geometric transformations (GT), which neglects feature compactness, by defining a rank-regularized loss function to encourage compact feature expression, proposes a character defect detection algorithm based on rank-regularized geometric transformation (RRGT). In unsupervised anomaly detection, only normal samples (qualified characters) is applied as training sets, and different types of geometric transformations are imposed on training samples in RRGT. The rank-regularized loss is defined to train a network model that can recognize the transformation type imposed on normal samples. The rank regularization enforces the feature matrix of the same geometric transformation to be low-rank, which encourages feature compactness. At inference stage, the network is used to predict the transformation type imposed on unseen samples. Since the network is never trained on the anomaly (defective characters), the network outputs high prediction uncertainty for the anomaly. Thus, the anomaly can be identified according to the uncertainty. The experiments on the dot characters printed on WANG WANG milk boxes show that compared to GT, RRGT obviously enhances the network's ability to identify the prediction uncertainty for defective characters, and the AUC for defect detection is improved by 4.8%.

Keywords: character defect detection; unsupervised anomaly detection; geometric transformation; convolutional neural network; rank regularization

0 引言

商品外观上的喷点字符记录了商品生产日期、批次、产地等重要信息,高质量的外观需要保证喷印位置和方向合理,每个字符完整、清晰。图1展示了日常生活中旺旺牛奶盒上的喷点字符^[1],箱体抖动、纸板褶皱等因素将导致字符缺陷。从图1(a)中分割出单个字符属于普通的光学字符识别任务,可以借助成熟的目标检测网络实现^[2]。然而,目标检测无法识别出如图1(b)所示的字符缺陷,字符缺陷检测属于异常检测问题^[3-4]。异常检测的原理是通过计算异常分数区分正常样本(又称为分布内样本)和异常样本(又称为分布外样本)。如图1(b)所示,缺陷图像中字符依然

完整,因而异常样本属于接近正常样本的近邻分布样本。这种近邻分布样本是目前异常检测算法面临的重要挑战^[5-6]。因此,字符缺陷检测的难点是准确区分分布内样本和近邻分布样本。本文研究对象是分割后的单个字符。




图1 旺旺牛奶盒上的喷点字符及其缺陷

基金项目:四川省科技计划重点研发项目(2021YFN0020)

第一作者简介:苗相彬(1994—),男,河南周口人,硕士研究生,研究方向为机器视觉、模式识别,blili62@swjtu.edu.cn。

异常样本难以大量搜集,无监督异常检测方法仅在正常样本上完成模型训练,相比监督学习的方式具有天然优势^[4-6]。目前流行的无监督异常检测方法主要基于深度学习,分为3种:基于重构误差的方法^[4,7-8]、基于支撑向量的方法^[9-10]以及基于几何变换(geometric transformations, GT)的方法^[3,5]。其中,前两种方法的流程繁琐,计算开销大,普遍需要借助复杂的卷积自编码器学习正常样本的分布流形^[8,10](例如结构信息),从而实现特征学习和样本重构;GT方法流程相对简单,计算代价低,仅通过预测样本的几何变换即可捕捉样本结构信息^[3,5]。具体地讲,GT方法^[3]源于自监督学习机制^[5],将施加在正常样本上的不同几何变换(例如旋转)视作伪标签,然后构造卷积神经网络(convolutional neural network, CNN)学习施加在样本上的几何变换类型。由于准确预测变换类型意味着CNN捕捉了正常样本的空间结构信息^[11-13],因此网络能以高置信度“确定地”预测正常样本的几何变换,对异常样本的预测置信度则较低。将置信度作为异常分数可以区分正常和异常样本。然而,现有GT方法仅采用Softmax损失函数鼓励不同变换类型的可分性,忽略了相同变换时特征表达的紧凑性。这就导致同类变换的样本特征散度较大,容易与近邻分布样本混淆,误导CNN以高置信度预测缺陷字符的几何变换类型,造成缺陷字符漏检。

针对现有GT方法忽略特征紧凑性,难以准确区分合格与缺陷字符的问题,设计秩正则损失函数,提出基于秩正则几何变换(rank-regularized geometric transformation, RRGT)的异常检测算法,算法框架如图2所示。秩正则损失将核范数施加在深度特征组成的矩阵上,包括两项:第一项强迫相同变换的特征矩阵具有较小的秩,从而鼓励同类变换的紧凑性;为避免特征矩阵退化成0矩阵,第二项强迫不同变换特征组成的矩阵具有较大的秩,从而保持不同变换的区分性。秩正则损失与Softmax损失共同引导网络训练。




图2 所提RRGT的算法框架

RRGT创新之处在于:

1) 相比GT方法仅采用Softmax损失区分几何变换^[3],RRGT通过学习几何变换的低秩特征表达,增强网

络对正常样本几何变换的识别能力,识别能力增强意味着网络更加充分地捕捉了正常样本的空间结构信息,有利于区分正常和异常样本;

2) 相比GT方法仅根据网络正确预测样本真实变换的概率计算异常分数^[6],RRGT将预测概率分布的信息熵作为异常分数,从本质上反映了预测结果的不确定性。

1 旺旺牛奶盒喷点字符缺陷检测

本文工程背景是成都旺旺食品有限公司乳制品生产日期喷点字符检测,检测内容包括字符识别和缺陷检测。字符识别流程是:1)从图中定位字符区域;2)在字符区域中分割出单个字符;3)对每个字符类型进行分类。图3给出了旺旺牛奶盒俯视图以及字符识别结果,图3(b)中第一行第一个识别结果“C 1.00”表示字符类型为“C”,识别置信度为1.00。字符识别可以借助目前流行的深度目标检测网络实现^[14-16],检测网络能够同时完成字符的定位、分割及分类。近年来,目标检测网络被广泛用于字符检测,大幅提高了字符识别精度^[1,2,14-16]。字符识别给出了每个字符的位置和类型,却无法判断喷印字符是否存在图1(b)所示的缺陷。因此,需要进一步检测字符缺陷,用于剔除不合格产品。不同于关注字符识别的字符检测方法^[1,2,14-16],本文所提方法可在单个字符识别结果的基础上检测缺陷字符。




图3 旺旺牛奶生产日期喷点字符识别

本文研究目标是通过无监督异常检测区分合格与缺陷字符,在不使用缺陷字符作训练样本的条件下获得能够检测缺陷字符的CNN。检测字符缺陷属于异常检测问题,目的是找出不同于正常样本的异常样本。异常检测分为有监督和无监督两种方式,前者使用人工标注的正常类和异常类样本训练分类器,缺点在于异常数据出现概率小,难以搜集数量充分、类型完备的异常样本^[4-6]。相比而言,无监督方式仅使用正常样本建立检测模型,具有更强的实用性。典型的无监督异常检测主要基于模板匹配完成^[17-19]。例如,文献[17]使用合格字符生成的模板检测缺陷字符。因为有效匹配的前提是模板数据和待检测数据精准对齐,匹配效果受光照强度、拍照角度等因素干扰较大,正常样本容易被误检。近期出现了基于深度学习的无监督异常检测^[7-10],这种方式通过自动学习特征表达显著提高了检测性能。为准确区分高度相似的合格与缺陷字符,本文定义新的损失函数,进一步增强GT方法中的特征表达。

2 基于秩正则几何变换的异常检测

所提RRGT进行字符缺陷检测的流程如图4所示。

训练阶段,首先对训练样本施加几何变换构造自标注数据集,然后使用秩正则损失和 Softmax 损失训练预测样本变换类型的 CNN。检测阶段,使用 CNN 预测新样本变换类型的概率分布,异常分数根据概率分布的信息熵计算,分数高则为缺陷字符。




图4 所提 RRGT 检测字符缺陷的流程

2.1 基于几何变换的异常检测

GT 方法的基本假设是一个能够有效识别正常样本几何变换类型的网络,无法“确定地”预测异常样本的几何变换^[3,6]。因此,可以根据网络预测样本几何变换的不确定性计算异常分数。GT 方法的实现过程如下。

首先,构造正常样本的自标注数据集。令 X 为正常训练样本组成的集合, x 为一个样本, $x \in X$ 。 $T_j(x)$ 表示对 x 进行第 j 种几何变换后的图像。若共有 J 种变换,自标注数据集 S_T 的定义为

$$S_T = \{ (T_j(x), j) \mid x \in X, j \in [1, J] \} \quad (1)$$

式中: $T_j(x)$ 是几何变换后的样本图像, j 是样本标签。在字符缺陷检测任务中 RRGT 设计的几何变换如表 1 所示。

表1 RRGT 中的几何变换

变换类型	标签值	几何变换方式
$T_1(x)$	1	保持不变
$T_2(x)$	2	左转 90°, 向上平移 0.3H 像素
$T_3(x)$	3	左转 180°, 向下平移 0.3H 像素
$T_4(x)$	4	左转 270°, 向右平移 0.3W 像素

注: W 、 H 分别为输入字符图像的宽度和高度。

相比于文献[3, 5, 11]中仅以图像旋转作为几何变换,RRGT 加入了平移变换,这是为了避免对称结构的字符(如“8”)造成的歧义性。例如,字符图像“8”和左转 180°后的“8”高度相似。

然后,训练一个预测几何变换类型的网络。分类损失函数 L_{cls} 采用 Softmax 函数,如式(2)所示。

$$L_{cls}(T_j(x), j; \Theta) = -\ln p(j \mid T_j(x), \Theta) \quad (2)$$

式中: Θ 为网络参数; $p(j \mid T_j(x), \Theta)$ 表示网络预测样本 $T_j(x)$ 真实变换类型 j 的概率。

最后,计算新样本的异常分数。由于网络无法以高置信度预测异常样本的几何变换类型,可以根据新样本 $\hat{x}$ 真实变换类型的概率 $p(j \mid T_j(\hat{x}))$ 计算异常分数。GT 方法中异常分数 S_0 的计算公式为

$$S_0 = -\frac{1}{J} \sum_{j=1}^J \ln p(j \mid T_j(\hat{x})) \quad (3)$$

2.2 秩正则损失函数

所提秩正则损失函数的原理是通过优化对不同几何变换的特征表达和识别能力,增强异常检测能力。训练网络学习不同几何变换相当于捕捉了正常样本的空间结构信息^[11, 13],因而 GT 方法能够检测异常样本。相应地,提高网络对几何变换的识别能力可以增强异常检测能力^[3, 5]。为准确检测与合格字符高度相似的缺陷字符,本文构造秩正则损失函数提升对几何变换的识别能力。

如图 2 所示,令一个批次的训练样本在网络最后一个全连接层之前的深度特征所组成的矩阵为 $Z_0 \in R^{d \times N_0}$, d 是特征维度, N_0 是批量值。将 Z_0 按列重写为 $Z_0 = [Z_1, Z_2, \dots, Z_j, \dots, Z_J]$, Z_j 代表第 j 种几何变换样本的深度特征所组成的矩阵, $Z_j \in R^{d \times N_j}$, N_j 是第 j 种变换的样本数量, $N_0 = \sum_{j=1}^J N_j$ 。由于矩阵的求秩运算不便求导,采用核范数 $\|\cdot\|_*$ 作为求秩运算的凸替代^[20],定义式(4)所示的秩正则损失函数 L_{rr} 。

$$L_{rr}(Z_0; \Theta) = \left(\sum_{j=1}^J \|Z_j\|_* \right) - \|Z_0\|_* \quad (4)$$

式(4)右侧第一项迫使同类几何变换的特征矩阵 Z_j 具有较小的秩,作用是鼓励同类特征的紧凑性,提高网络对几何变换的识别能力。式(4)右侧第二项迫使不同几何变换的特征矩阵具有较大的秩,作用是保证不同变换类型的可分性。

使用 L_{rr} 训练 CNN 需要计算梯度 $\partial L_{rr} / \partial Z_0$ 。核范数的求导可以通过奇异值分解获得^[21], Z_j 的导数可写为 $\partial \|Z_j\|_* / \partial Z_j = U_{j,p} V_{j,p}^T$ 。 $U_{j,p}$ 和 $V_{j,p}$ 分别是 Z_j 的列主元和行主元, $U_{j,p} \in R^{d \times n}$, $V_{j,p} \in R^{N_j \times n}$ 。 n 是主元数量,本文以 1.0×10^{-4} 为阈值根据 Z_j 的奇异值确定主元数量^[20-21]。梯度 $\partial L_{rr} / \partial Z_0$ 可写为式(5)。

$$\begin{aligned} \partial L_{rr} / \partial Z_0 = & (U_{1,p} V_{1,p}^T, \theta) + (\theta, U_{2,p} V_{2,p}^T, \theta) + \dots + (\theta, U_{j,p} V_{j,p}^T, \theta) + \dots \\ & (\theta, U_{j,p} V_{j,p}^T) - U_{0,p} V_{0,p}^T = (U_{1,p} V_{1,p}^T, \dots, U_{j,p} V_{j,p}^T, \dots, \\ & U_{j,p} V_{j,p}^T) - U_{0,p} V_{0,p}^T \end{aligned} \quad (5)$$

其中:全 θ 矩阵 θ 用于将矩阵维度扩充成 $d \times N_0$,使梯度 $\partial L_{rr} / \partial Z_0$ 与特征 Z_0 的维度保持一致。

最终, L_{rr} 作为正则项,与式(2)所示的分类损失 L_{cls} 共同用于网络训练,式(6)为总的损失函数 L_{all} 。

$$L_{all} = L_{cls} + \lambda L_{rr} \quad (6)$$

式中 λ 为平衡系数。

2.3 异常分数

所提 RRGT 将网络预测分布的信息熵作为样本异常分数。对于异常样本,网络无法准确识别样本的几何变换类型,预测分布的不确定性高,信息熵大;反之,网络对正常样本几何变换的预测不确定性低,信息熵小。可以根据新样本 $\hat{x}$ 预测结果的信息熵计算异常分数 S_1 ,计算公式如式(7)所示。

$$S_1 = -\frac{1}{J} \sum_{j=1}^J \sum_{i=1}^I p(i|T_j(\hat{x})) \ln p(i|T_j(\hat{x})) \quad (7)$$

图5展示了合格和缺陷字符“2”图像的异常分数 S_1 。可以看出,合格字符 S_1 大,缺陷字符 S_1 小,使用异常分数阈值可以区分出缺陷字符。




图5 正常和异常样本的异常分数 S_1

使用 RRGT 进行字符缺陷检测包括训练和检测两个阶段,以下分别给出了对应的算法逻辑。

训练阶段所提 RRGT 的算法逻辑:

输入:由正常样本组成的训练集 X ;

输出:预测样本几何变换类型的 CNN。

1) 建立自标注数据集 S_T 。按表(1)对训练样本进行几何变换,按式(1)建立自标注数据集。

2) 初始化一个预测样本几何变换类型的 CNN,按设定回合数循环迭代步骤 a)~步骤 d):

a) 将 S_T 中的样本输入 CNN;

b) CNN 输出预测概率 $p(j|T_j(x), \Theta)$ 和样本特征 Z_0 ;

c) 计算式(6)所示的损失函数。其中,分类损失 L_{cls} 按式(2)计算,秩正则损失 L_r 按式(4)计算;

d) 利用损失函数的梯度更新 CNN 网络参数 Θ 。

3) 保存训练完成的 CNN。

检测阶段所提 RRGT 的算法逻辑:

输入:待检测的字符样本图像 $\hat{x}$,训练完成的 CNN;

输出:新样本的异常分数 S_1 ,缺陷检测结果。

①按训练阶段的算法逻辑对样本进行几何变换;

②将变换后的样本输入 CNN,CNN 输出样本几何变换类型的概率分布 $p(i|T_j(\hat{x}))$;

③按式(7)计算样本的异常分数 S_1 ;

④ S_1 高于设定阈值则为缺陷字符,否则为合格字符。

3 实验与结果分析

首先,与目前无监督异常检测方法对比,验证 RRGT

的字符缺陷检测性能;然后,展示样本特征和网络预测,验证 RRGT 假设的合理性。

3.1 实验设置

实验样本来自生产线上采集的旺旺牛奶盒顶部喷点字符图像,样本图像如图1(a)所示。采用文献[2]的方法从整幅图像中分割、识别出单个字符,字符类型包括“0”~“9”,“C”,“L”共12种。训练集由1200张合格字符组成,其中每种字符100张。测试集包含12000张合格字符和1000张缺陷字符,其中每类字符的合格图像1000张,缺陷图像49~216张。图像尺寸有轻微波动,宽度为60~80像素,高度为110~140像素。图像尺寸被统一为64×64像素。实验分别对每种字符进行缺陷检测,即为每种字符单独训练网络模型,测试时缺陷图像和合格图像中的字符类型相同。实验属于难度较大的近邻分布样本检测,而不是简单的一对一任务[6]。

RRGT 中的主干网络采用预训练的 VGG16[22] 网络结构,使用随机梯度下降微调网络,迭代回合、批量、动量和权重衰减分别为50、128、0.9、0.0005。初始学习率为0.001,当总的损失函数值停止下降时学习率乘以0.1。算法基于python3.5和Pytorch1.0实施,在 GTX 1080ti 显卡上运行。实验发现,式(6)中的平衡系数 λ 在区间[0.1, 0.9]内变化时,异常检测性能稳定,因此取 $\lambda = 0.1$ 。

评价指标采用所有字符类型的平均 AUC (area under curve) 值。直观判断样本异常的方式是定义一个固定的分数阈值。然而,使用固定阈值获得的检测结果并不能客观反映算法性能。较小的阈值可以检出所有异常样本,较大的阈值则能够保证所有正常样本不会被误检。因此,异常检测领域中,通常不使用固定阈值评价算法性能,而是计算 ROC (receiver operating curve) 曲线[23]下的面积,即 AUC 值。如图6所示,ROC 曲线的横坐标为假阳率 (false positive rate, FPR),表示将合格字符判为缺陷字符的误检率;纵坐标为真阳率 (true positive rate, TPR),表示真实缺陷字符的检出率。AUC 值越大,表示同等误检率条件下异常样本的检出率更高,算法检测性能更强。




图6 RRGT 和 GT 方法的 ROC 曲线对比

3.2 缺陷字符检测性能

为验证所提 RRGT 的缺陷字符检测性能,与近期流行的无监督异常检测方法对比,具体如下。

1) 基于重构误差的方法一:深度自编码高斯混合模型 (deep auto-encoding Gaussian mixture model,

DAGMM)^[7]。主干网络选用 VGG16,以样本重构误差和编码特征计算异常分数。

2) 基于重构误差的方法二:基于对抗生成网络的异常检测(anomaly detections using generative adversarial network, Ano-GAN)^[8]。按照文献[8]实施 Ano-GAN,以单个字符图像作为图像块,融合重构样本和判别器特征计算重构误差(即异常分数)。

3) 基于支持向量的方法一:深度单类分类方法(deep features for one-class classification, DFOC)^[24]。以 CIFA100 数据集作为辅助增强数据集,采用 VGG16 网络学习样本特征,将特征送入单类支持向量机训练分类器,由分类器给出异常检测结果。

4) 基于支撑向量的方法二:单类支持向量数据描述(deep support vector data description, Deep SVDD)^[9]。使用文献[9]的方法实施 Deep SVDD,将样本和正常样本特征中心的距离作为异常分数。

5) GT 方法^[3]。为公平与 RRGT 对比,GT 方法采用表 1 所列的几何变换,使用式(6)计算异常分数。

6) RRGT₋。为对比不同异常分数计算方式,将 RRGT 中的异常分数计算公式(6)替换为式(3),方法记为 RRGT₋。

表 2 列出了不同方法的字符缺陷检测结果,从表 2 可以看出下列现象。

a) DAGMM、DFOC、Deep SVDD 的 AUC 值较低。虽然这些方法在一对所有任务^[3, 6]中表现良好,但缺陷字符与正常字符高度相似,属于难以检测的近邻分布样本^[5]。因此,这些方法的检测性能较低。

b) GT 方法的 AUC 值(0.935)略低于 Ano-GAN(0.951),但明显高于其他基于重构误差或基于支撑域的方法,说明了 GT 方法在字符缺陷检测任务上的优势。

c) 相比 GT 方法,RRGT 在 AUC 值上提升了 0.48,说明使用秩正则损失 L_r 优化网络对几何变换的特征表达和识别能力,能够明显增强缺陷字符检测性能。为更直观对比 RRGT 和 GT 方法,图 6 绘制了两种方法对字符“2”进行缺陷检测时获得的 ROC 曲线。图 6 中,误检率(FPR)相同时,RRGT 对缺陷字符的检出率(TPR)更高。例如,当误检率为 0.1 时,RRGT 检出率为 1.0,这时 RRGT 识别出了所有缺陷字符。图 6 表明 RRGT 区分合格与缺陷字符的能力更强。

d) 相比 RRGT,RRGT₋的 AUC 值略有下降,这说明使用信息熵衡量网络预测的不确定性有助于增强异常检测性能。

表 2 不同异常检测方法的结果对比

序号	方法	基础网络	AUC
1	DAGMM	VGG16	0.718
2	Ano-GAN	—	0.951
3	DFOC	VGG16	0.854
4	Deep SVDD	VGG16	0.897
5	GT	VGG16	0.935
6	RRGT	VGG16	0.983
7	RRGT ₋	VGG16	0.972

为直观分析所提 RRGT 区分合格与缺陷字符的效果,图 7 给出了所提 RRGT 在字符“5”和“8”上计算出的异常分数 S_1 。可以看出,合格字符的异常分数较低,例如合格字符“5”的异常分数低于 0.71。在正常样本上训练的 CNN 能够准确预测合格字符的几何变换类型,预测不确定性小,因而异常分数低。相比而言,缺陷字符的异常分数较高,例如缺陷字符“5”的分数高于 1.3。RRGT 仅在正常样本上训练,错位、底纹等缺陷改变了图中字符的空间结构,CNN 无法准确预测缺陷字符的几何变换类型,预测不确定性大,因而异常分数高。实验表明,RRGT 对样本几何变换类型的预测不确定性能够有效区分合格与缺陷字符。




图 7 RRGT 在合格与缺陷字符上的异常分数

3.3 可视化

所提 RRGT 的原理是,构造秩正则损失 L_r 优化网络对正常样本几何变换的特征表达和识别能力,通过优化的网络提升对异常样本不确定性的识别能力。为验证 RRGT 的原理,图 8(a)展示了正常样本(合格字符)不同几何变换的特征,图 8(b)展示了正常样本和异常样本(缺陷字符)第三种几何变换的特征。图 8 中样本来自字符“2”的测试集,网络倒数第二个全连接层输出的深度特征经过 TSNE(t-distributed stochastic neighbor embedding)^[25]降维后变成二维特征点。图 8(a)中,RRGT 对相同几何变换的特征表达更加紧凑,例如圈出的第三种几何变换 $T_3(\hat{x})$,这说明学习低秩的特征表达鼓励了特征紧凑性;同时,使用 RRGT 时不同几何变换相距较远,例如箭头标出的几何变换后样本 $T_3(\hat{x})$ 和 $T_1(\hat{x})$ 之间的距离,这说明 RRGT 对不同几何变换的识别能力更强。图 8(b)中,使用 RRGT 时合格字符的特征更加紧凑,合格与缺陷字符特

征的距离更远,说明学习低秩特征表达有利于区分正常和异常样本。




图8 几何变换特征分布对比

为分析网络对异常样本的预测不确定性,图9画出了缺陷字符的预测概率。图9的样本为176张字符“2”的缺陷图像,样本经历了4种几何变换,样本总数为 $176 \times 4 = 704$ 。图9中,具有相同几何变换的样本被连续排列在一起,图形越接近块对角形式,正确预测的置信度越高,不确定性越低。图9(a)中,GT方法预测的概率分布更接近块对角,即多数样本的几何变换被正确地预测,说明GT方法对缺陷字符的不确定性低。相比而言,使用RRGT时错误预测的概率值更高,概率分布更加混乱,这说明RRGT对缺陷字符具有更高不确定性的识别能力。




图9 网络对缺陷字符的预测概率

4 结语

针对缺陷字符与合格字符高度相似,难以被准确检测的问题,提出基于秩正则几何变换的无监督字符缺陷检测算法RRGT。RRGT首先构造秩正则损失函数引导网络学习正常样本几何变换的低秩特征表达,然后采用信息熵计

算网络对新样本几何变换的预测不确定性。实验表明,相比GT方法,秩正则损失迫使相同几何变换的特征表达更紧凑,网络对正常样本几何变换的识别能力更强。RRGT对缺陷字符几何变换预测不确定性的识别能力更高,明显提高了字符缺陷检测的AUC值。未来将围绕字符缺陷检测,设计特异性的几何变换,进一步提高检测性能。

参考文献:

- [1] 曹泽卫,欧阳,林冬婷,等. 基于CNNs识别反馈的点阵字符检测方法[J]. 电子测量与仪器学报, 2020, 34(8): 159-166.
- [2] 肖振远,王逸涵,罗建桥,等. 基于部分加权损失函数的RefineDet[J]. 计算机应用, 2021, 41(7): 1928-1932.
- [3] GOLAN I, EL - YANIV R. Deep anomaly detection using geometric transformations[EB/OL]. (2018-05-28) [2021-02-04]. <https://arxiv.org/abs/1805.10917>.
- [4] ZAVRTANIK V, KRISTAN M, SKOČAJ D. Reconstruction by inpainting for visual anomaly detection[J]. Pattern Recognition, 2021, 112: 107706.
- [5] DAN H, MANTAS M, SAURAV K, et al. Using self-supervised learning can improve model robustness and uncertainty[C]. The 33rd Conference on Neural Information Processing Systems (NIPS), Vancouver, Canada: [s.n.], 2019: 15637-15638.
- [6] VYAS A, JAMMALAMADAKA N, ZHU X, et al. Out-of-distribution detection using an ensemble of self supervised leave-out classifiers[C]. The 15th European Conference on Computer Vision(ECCV), Cham: Springer International Publishing, 2018: 560-574.
- [7] ZONG B, SONG Q, MARTIN M, et al. Deep auto-encoding Gaussian mixture model for unsupervised anomaly detection[C]. The 6th International Conference on Learning Representations (ICLR), Vancouver, Canada: [s.n.], 2018.
- [8] SCHLEGL T, SEEBÖCK P, WALDSTEIN S M, et al. F-AnoGAN: fast unsupervised anomaly detection with generative adversarial networks[J]. Medical Image Analysis, 2019, 54: 30-44.
- [9] PHILIPP L, LUKAS R, ROBERT A, et al. Explainable deep one-class classification[C]. The 9th International Conference on Learning Representations (ICLR), [S. I.]: s.n., 2021.
- [10] ZHOU Y, LIANG X M, ZHANG W, et al. VAE-based deep SVDD for anomaly detection[J]. Neurocomputing, 2021, 453: 131-140.
- [11] SPYROS G, PRAVEER S, NIKOS K. Unsupervised representation learning by predicting image rotations[C]. The 6th International Conference on Learning Representations (ICLR), Vancouver, Canada: [s.n.], 2018.
- [12] ZHAO H, LI Y X, HE N J, et al. Anomaly detection for medical images using self-supervised and translation-consistent features[J]. IEEE Transactions on Medical Imaging, 2021, 40(12): 3641-3651.
- [13] BAEK K, LEE M, SHIM H. PsyNet: self-supervised approach to object localization using point symmetric transformation[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 10451-10459.
- [14] 吉训生, 李建明. 一种改进的Faster-RCNN电路板字符检测方法[J]. 小型微型计算机系统, 2020, 41(6): 1291-1295.
- [15] 王志明, 刘志辉, 黄洋科, 等. 基于深度学习的高效火车号识别[J]. 工程科学学报, 2020, 42(11): 1525-1533.
- [16] 刘杰, 朱旋, 宋密密. 改进YOLOv2的端到端自然场景中文

- 字符检测[J]. 控制与决策, 2021, 36(10): 2483-2489.
- [17] 孙晓娜, 刘继超, 高国华. 基于视觉的乳品包装日期喷码缺陷检测技术[J]. 食品与机械, 2018, 34(10): 100-103, 108.
- [18] 周阳, 沈婷婷, 席志远, 等. 基于 Halcon 的日化瓶瓶底喷码质量检测算法研究[J]. 仪表技术与传感器, 2020(11): 101-104, 110.
- [19] 尚玉廷. 包装箱型号标记缺陷检测系统设计与实现[J]. 包装工程, 2021, 42(1): 214-223.
- [20] LIU G C, LIN Z C, YAN S C, et al. Robust recovery of subspace structures by low-rank representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(1): 171-184.
- [21] RECHT B, FAZEL M, PARRILO P. Guaranteed minimum-rank solutions of linear matrix equations via nuclear norm minimization[J]. SIAM Rev., 2007(52): 471-501.
- [22] KAEREN S, ANDREW Z. Very deep convolutional networks for large-scale image recognition. [C]. The 3rd International Conference on Learning Representations (ICLR), San Diego, USA: [s.n.], 2015.
- [23] JESSE D, MARK G. The relationship between precision-recall and ROC curves [C]. The 23rd International Conference on Machine Learning (ICML), Pittsburgh, USA: [s.n.], 2006: 233-240.
- [24] PERERA P, PATEL V M. Learning deep features for one-class classification[J]. IEEE Transactions on Image Processing: a Publication of the IEEE Signal Processing Society, 2019, 28(11): 5450-5463.
- [25] MAATEN L, HINTON G. Visualizing data using t-SNE [J]. Journal of Machine Learning Research, 2008, 9: 2579-2605.

收稿日期: 2022-04-01


(上接第 118 页)

根据仿真结果可以看出,在 $T=10\text{ s}$ 时,优化后的自适应 PID 控制均具有稳定的升温速率控制,升温速率标准差分别为 0.091、0.128、0.304、0.413、0.430,满足控制要求。


3.3 运行工况测试

在 Simulink 仿真与模拟机 NuSIM 仿真过程中,主要模拟的是预热阶段,熔盐-熔盐换热器与熔盐-空气换热器处于关闭状态,熔盐管道模块没有外部热源,可将所有

模块的温度视为相同。但是在热态运行阶段存在堆芯衰变热,假设堆芯供热不足,自适应 PID 控制一直处于稳速升温状态,积分环节不断增大,容易产生超调。因此在运行工况切换为运行阶段时,低于 $550\text{ }^{\circ}\text{C}$ 的加热通过无积分的自适应 PID 控制实现。所以需要验证在预热阶段达到稳态后,切换到运行阶段,然后改变温度至 $460\text{ }^{\circ}\text{C}$,测试控制系统在不同工况之间切换的运行状态是否符合控制需求。仿真结果如图 8 所示。



(a) 升温曲线对比图



(b) 升温速率对比图

图 8 切换工况的仿真结果

根据仿真结果可以看出,达到稳态之后,切换工况的升温速率稳定,且达到控制目标时不会产生超调,因此该温控系统满足控制需求。

4 结语

在分析了实验堆熔盐管道温度控制系统原理的基础上,设计了一种自适应 PID 控制器。首先在 Simulink 仿真分析,并在工程模拟机上进行验证与优化,最后在控制需求的范围内进行功能测试。结果表明:相比工业常用的控制方法,自适应 PID 控制在实验堆熔盐管道温度控制的升温速率稳定性好,超调量最小,并且在控制系统要求的升温速率、工况之间均有满足控制系统需求的控制效果。

参考文献:

- [1] 王丽丽, 辛玲. 改进的模型参考自适应 PID 新风温度控制研究[J]. 自动化仪表, 2021, 42(12): 51-55.
- [2] JIANG W, YIN P, CAO L T. On fuzzy self-tuning PID MATLAB simulation for central heating [C]//2007 Chinese Control Conference. Zhangjiajie, China: IEEE, 2007: 425-429.
- [3] 闫秀英, 任庆昌, 孟庆龙. 一种自校正 PID 控制器设计与仿真研究[J]. 系统仿真学报, 2006, 18(增刊 2): 753-756.
- [4] 申玉鹏, 张耿毓. 基于改进 PID 算法的加热炉炉温控制系统设计与实现[J]. 电子测量技术, 2019, 42(15): 24-28.
- [5] 金愿, 程进辉, 王坤, 等. 几种典型熔盐冷却剂的热物性研究[J]. 核技术, 2016, 39(5): 83-91.
- [6] 李劲涛, 贾祥, 后接. 熔盐堆回路伴热保温模块自适应 PID 控制系统设计[J]. 仪器仪表用户, 2021, 28(12): 25-29.

收稿日期: 2022-03-14