

# 用于小样本 PTC 质量智能诊断的 AoT-DCGAN 和 P-CNN 混合深度学习模型<sup>①</sup>



李文哲, 李浩然, 王 涛, 马梓瀚, 汪传磊, 郭丽雪

(中国石油西南油气田分公司 工程技术研究院, 成都 610017)

通信作者: 李浩然, E-mail: [lihaoran\\_2024@petrochina.com.cn](mailto:lihaoran_2024@petrochina.com.cn)

**摘 要:** 气密封螺纹连接 (PTC) 上扣质量的智能诊断对于确保油管在高温、高压、酸性气体条件下的稳固性和密封性至关重要. 准确的诊断依赖于分析不同工况下的 PTC 曲线以反映上扣质量, 但在实际工业检测中获取大量有效数据面临挑战. 本文提出了一种端到端分类模型, 它结合了异步优化的二维深度卷积生成对抗网络 (AoT-DCGAN) 和用于 PTC 曲线诊断的二维卷积神经网络 (P-CNN), 旨在提高小样本下的分类性能. 本文提出的方法首先利用 AoT-DCGAN 来识别真实样本的分布模式, 并生成合成样本. 随后利用 P-CNN 模型在扩增的数据集上进行训练, 实现 PTC 曲线的智能诊断. 同时, 本文使用了一种新颖的权重优化策略, 即异步优化 (AO), 用来缓解生成器优化阶段的梯度消失问题. 本文提出的方法基于不同数据扩增比率下的召回率、特异性、F1 分数、精确度和混淆矩阵进行了性能评估, 结果表明, 随着数据集规模的扩增, 模型的分类能力也在增强, 在数据集规模达到 1200 张时分类效果最佳. 此外, 在相同的训练集中, P-CNN 模型的表现优于传统的机器学习和深度学习模型, 在 AC、ATI 和 NDT 曲线上的最佳分类准确率分别达到了 95.9%、95.5% 和 96.7%. 最后, 研究证实在 DCGAN 的训练过程中使用异步优化会使损失函数更稳定地下降.

**关键词:** 气密封螺纹连接; 卷积神经网络; 生成对抗网络; 小样本; 异步优化

引用格式: 李文哲, 李浩然, 王涛, 马梓瀚, 汪传磊, 郭丽雪. 用于小样本 PTC 质量智能诊断的 AoT-DCGAN 和 P-CNN 混合深度学习模型. 计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/9802.html>

## Hybrid Deep Learning Model of AoT-DCGAN and P-CNN for Intelligent Diagnosis of PTC Quality on Small Sample

LI Wen-Zhe, LI Hao-Ran, WANG Tao, MA Zi-Han, WANG Chuan-Lei, GUO Li-Xue

(Research Institute of Engineering Technology, Petro China Southwest Oil & Gasfield Company, Chengdu 610017, China)

**Abstract:** The intelligent diagnosis of premium threaded connections (PTC) is crucial for ensuring the stability and sealing of oil pipes under high temperature, high pressure, and acidic gas conditions. Accurate diagnosis relies on analyzing PTC curves under different operating conditions to reflect the quality of the buckling, but obtaining a large amount of valid data in actual industrial inspections is challenging. This study introduces an end-to-end classification model that combines asynchronous optimized 2D deep convolutional generative adversarial network (AoT-DCGAN) and 2D convolutional neural network (P-CNN), aiming to improve classification performance with small sample sizes. The proposed method first utilizes AoT-DCGAN to identify the distribution pattern of original samples and generate corresponding synthetic samples. At the same time, a novel weight optimization strategy, asynchronous optimization (AO), is implemented to alleviate the gradient vanishing problem during the generator optimization phase. Subsequently, a novel P-CNN model is designed and trained on an expanded dataset to achieve automatic classification of PTC curves.

<sup>①</sup> 基金项目: 海相碳酸盐岩油气规模增储上产与勘探开发技术研究 (2023ZZ16)

收稿时间: 2024-09-03; 修改时间: 2024-09-24; 采用时间: 2024-10-23; csa 在线出版时间: 2025-04-01

The method is evaluated based on *recall*, *specificity*, *F1 score*, *precision*, and confusion matrix under different data augmentation ratios. The results indicate that as the dataset size increases, the model's classification ability improves, peaking at a dataset size of 1 200. In addition, within the same training set, the performance of the P-CNN model outperforms traditional machine learning and deep learning models, achieving optimal classification accuracies of 95.9%, 95.5%, and 96.7% on the AC, ATI, and NDT curves, respectively. Finally, research confirms that applying asynchronous optimization during the training process of DCGAN results in a more stable decrease in the loss function.

**Key words:** premium threaded connection (PTC); convolutional neural network (CNN); generative adversarial network (GAN); small sample; asynchronous optimization

## 1 引言

气密封螺纹连接 (premium threaded connection, PTC) 在防止油管中高温、高压和含硫化氢气体泄漏方面发挥重要作用<sup>[1-3]</sup>。螺纹之间的过盈配合可形成气密封,而这种密封的可靠性直接取决于上扣质量。上扣质量通常通过上扣过程中的扭矩曲线来反映,因为扭矩曲线能够展示连接过程中螺纹的受力情况,进而反映出气密性是否受到影响。若螺纹在运输过程中受到轻微损伤或连接不当,其上扣曲线通常会与标准曲线出现明显差异,从而提示气密封可能被破坏。然而,当前主要依赖人工检查扭矩曲线来判断上扣质量,这种方法高度依赖工程师的经验,缺乏客观性和量化标准<sup>[4-7]</sup>。为实现智能化诊断,需要自动分类和识别不同工况下的 PTC 上扣曲线,以评估上扣质量并确保气密性。

近年来,人工智能 (AI) 在各行各业的应用和研究大大提高了对 PTC 上扣质量的诊断能力。Ma 等人<sup>[8]</sup>提出了一种基于逻辑回归的机器学习方法,用于 PTC 曲线分类,通过将曲线分为合格和不合格两类,初步实现了智能识别能力。虽然这种方法能揭示不同工况下的统计和空间特征分布特征,但它在很大程度上依赖人工特征提取。然而,特征提取效果会严重影响模型分类结果。相比之下,通过多层神经网络进行深度学习能自动从原始数据中学习高级特征表征,省去了人工特征工程的繁琐过程<sup>[9]</sup>。因此,将深度学习应用于 PTC 曲线自动分类是解决当前问题的一个很有前景的方案。

最近,深度学习在医学、生物学和机械工程等领域目标分类及识别等任务中得到了大量研究和应用。卷积神经网络 (CNN) 因其独特的卷积运算和全局权重共享机制而受到特别关注,并取得了最先进的分类性能<sup>[10-14]</sup>。Peng 等人<sup>[15]</sup>提出一种基于深度学习的抽油杆井工况监测与诊断智能方法。该方法利用深度卷积神

经网络算法分析不同工况下电气数据与测功卡之间的关系,通过人工合成测功卡,并利用卷积神经网络对人工合成的测功卡进行自动诊断,预测准确率超过 95%。Zhang 等人<sup>[16]</sup>结合了卷积神经网络和迁移学习方法,预训练的网络模型在 10 种不同工况的测功机卡数据集上进行训练,从而实现了测功机卡工况的智能诊断,识别准确率达到 92.6%,优于一般全连接神经网络和浅层卷积神经网络。Tang 等人<sup>[17]</sup>应用卷积神经网络模型对齿轮箱的原始振动数据、频谱数据和时频数据进行分类和识别。结果表明,神经网络模型可以自动学习频域数据的关键特征,并对齿轮箱故障进行智能诊断。

然而,上述基于卷积神经网络的分类和识别任务研究通常都假设有充足的训练数据。在本研究中,重点是对不同连接工况下的 PTC 曲线进行分类,然而只有一小部分 PTC 可能会出现螺纹损伤或连接不当的情况,获取充足的异常 PTC 曲线具有一定困难。因此,开发一种能在样本量较小的情况下对 PTC 曲线进行有效分类的智能诊断方法具有重要意义。

解决训练数据集不足问题的一个可行方案是数据增强。一般来说,数据增强可以通过数据扭曲或超采样来人为扩增训练数据集<sup>[18]</sup>。数据扭曲是指对训练数据引入真实世界的扭曲,如弹性变形、随机裁剪、旋转和缩放。相比之下,超采样增强则是生成全新的样本来补充原始训练数据集。生成对抗网络 (GAN) 作为最具创新性的超采样增强技术之一,自 2014 年问世以来已获得了广泛关注<sup>[19]</sup>。与其他数据增强技术不同,GAN 可以学习训练数据集中样本的分布模式,并生成具有原始特征的合成实例。大量研究表明,GAN 在小样本故障诊断领域受到越来越多的关注,并取得了丰硕成果。杨等人<sup>[20]</sup>提出了一种用于图像数据增强的条件生成 GAN,用于解决图像方案中的小样本和多类别问题。

借用了注意力机制对特征进行校正,为回传梯度流提供了更多的信息,提高分类性能. Wang 等人<sup>[21]</sup>提出了增强型生成对抗网络 (E-GAN), 该网络采用深度卷积生成对抗网络 (DCGAN) 来平衡数据集, 并采用改进的 CNN 诊断模型进行故障分类.

受深度学习在各领域分类任务中取得的成功及其在数据扩增领域的潜力的启发, 本文提出了一种改进的 AoT-DCGAN 和 P-CNN 混合深度学习模型, 用于小样本 PTC 曲线的智能分类. 所提出的方法包括两个阶段: 数据生成和曲线分类. 第 1 阶段包括建立 AoT-DCGAN 模型, 从原始 PTC 曲线中学习特征分布, 并生成合成样本来扩增训练数据集. 第 2 阶段提出了 P-CNN 模型, 用于对 PTC 曲线进行分类, 该模型使用扩增数据集进行训练. 将结果和不同扩增比率的数据集与传统机器学习模型进行比较, 验证了所提方法在分类性能方面的优越性.

本文的主要贡献如下.

(1) 本文设计了一种用于 PTC 曲线自动分类的混合深度学习模型. 该模型在小样本下取得了良好的分类结果, 能够快速、定量地评估 PTC 上扣质量.

(2) 本文提出的 AoT-DCGAN 模型能够生成与真实 PTC 曲线非常相似的样本, 表现出高度的真实性和逼真性. 此外, 模型训练过程更加稳定, 有效解决了梯度消失问题.

(3) 本文介绍了一种用于 PTC 曲线分类的 P-CNN 模型, 与传统的机器学习和深度学习模型相比, 该模型具有更优越的分类性能.

本文第 1 节介绍了本文研究中所使用数据集的基本概念, 概述了所提出的 AoT-DCGAN 和 P-CNN 混合深度学习模型, 并详细介绍了一种新颖的权重优化策略. 第 2 节通过不同扩增比率下的分类性能与传统机器学习模型进行比较, 展示了所提模型的结果. 第 3 节对本文进行总结, 并探讨未来研究方向.

## 2 数据收集及模型设想

本节详细介绍了本研究所使用数据集的来源和特点. 此外, 我们还概述了所提出混合深度学习模型的结构和基本原理.

### 2.1 PTC 曲线

与 API 油管连接不同, PTC 独特的金属对金属密封设计和扭矩台肩显著提高了油管的气密封性能, 有

效降低了复杂载荷下气体泄漏的可能性<sup>[22]</sup>. PTC 的上扣扭矩曲线, 也称为 PTC 曲线, 是 PTC 是否正确可靠的重要指标. 它是通过记录和分析气密封螺纹连接上扣过程中的扭矩和圈数数据生成的. 随着螺纹管柱逐渐拧紧, 作用力和扭矩逐渐增加, 直到达到特定阻力. 图 1 直观展示了 PTC 的结构特征以及上扣过程中每个阶段的扭矩曲线.

在上扣初始阶段, 主要阻力来自螺纹间的摩擦, 形成如图 1(a) 所示的红色实线, 即“螺纹干涉段”. 若该阶段的曲线呈现平缓的逐渐上升趋势, 表明螺纹接合正常, 摩擦力处于合理范围内. 而若曲线在此阶段异常陡峭或波动过大, 可能预示螺纹存在错位、磨损或制造公差偏差等问题, 这将导致螺纹接触不充分或过度干涉, 影响上扣的紧密性和牢固性.

接下来如图 1(b) 中所示的红色实线为“金属对金属密封段”, 该阶段开始于所有螺纹完全接触后. 当金属对金属部分接触达到一定程度时, 扭矩肩启动以防止过度接触. 此时扭矩曲线迅速上升, 直至上扣过程完成. 若该阶段曲线上升缓慢或出现波动, 可能说明密封不完全或接触不良, 进而导致密封失效, 增加漏气或漏油的风险.

最后的“扭矩台肩段”如图 1(c) 中红色实线所示, 该阶段标志着金属接触已达到最大程度, 扭矩迅速上升直至上扣结束. 此时曲线是否达到预设的扭矩标准至关重要, 未达到标准可能意味着螺纹接触不充分或密封不足, 导致上扣质量不合格. 若曲线上升过快, 则表明扭矩过大, 可能引发过度紧固, 造成螺纹或金属损坏, 严重时甚至可能导致设备失效.

因此, 典型的上扣扭矩曲线表现出 3 个阶段: 逐渐上升 (螺纹干涉段)、显著上升 (金属对金属密封段) 和快速上升 (扭矩台肩段)<sup>[8]</sup>. 然而, 在实际操作过程中, 因螺纹错位或损伤, PTC 曲线可能出现异常, 如图 2(b) 和图 2(c) 所示. 本文的目标是通过自动识别这 3 类 PTC 曲线, 智能评估上扣质量.

### 2.2 提出的方法

本文介绍了一种适用于小样本分类任务的改进型 AoT-DCGAN 和 P-CNN 混合深度学习模型. 该模型融合了生成对抗网络 (DCGAN) 和卷积神经网络 (CNN). 首先, 利用 AoT-DCGAN 学习 PTC 曲线内的底层分布模式, 生成额外样本. 这是通过建立从噪声向量到真实数据分布的映射来实现的. 利用这种映射, 可以从随机噪声中生成更多人工曲线样本, 从而有效扩增数据集.

随后, P-CNN 从这些增强样本中提取特征并进行分类. 图 3 展示了这一混合模型的概况, 为其架构提供了直

观的表示. 在这个工作流程图中, 图 3(a) 表示数据生成过程, 图 3(b) 表示分类过程.

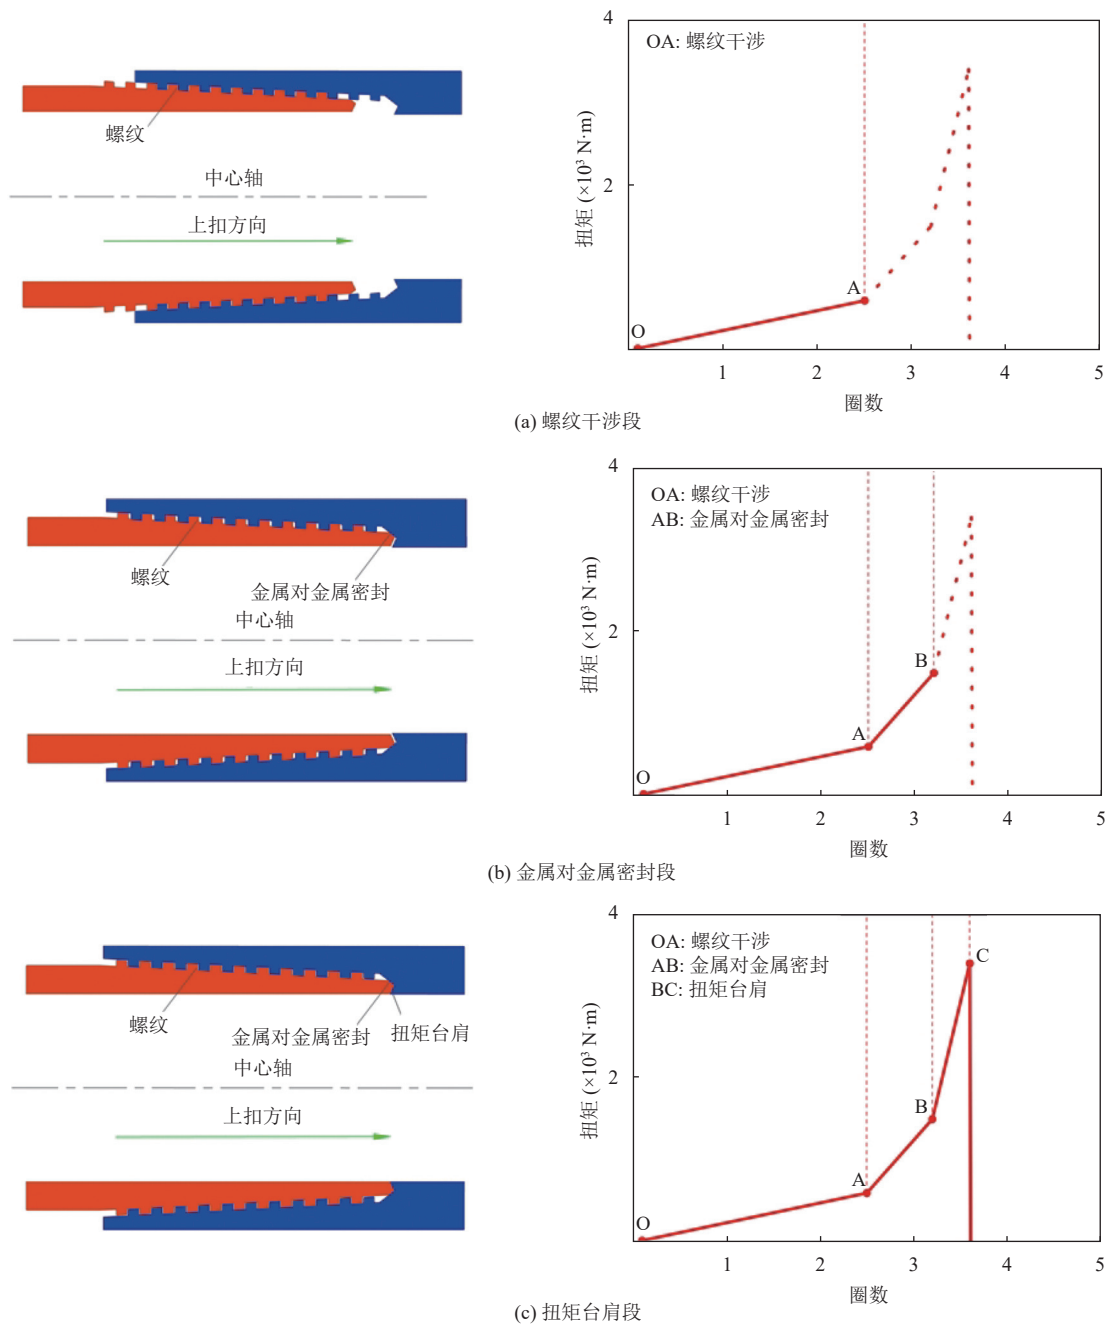


图 1 上扣阶段的 PTC 和相应扭矩曲线

(1) AoT-DCGAN 模型的结构

本研究中介绍了一种 AoT-DCGAN 模型, 它由二维 DCGAN 模型和异步优化 (AO) 策略组成. 如图 4 所示, AoT-DCGAN 的生成器包括 6 个二维转置卷积层, 而判别器则由 5 个二维卷积层组成. 生成器输入 1 个 100 维的随机噪声向量  $z$ , 然后通过一系列转置

卷积上采样将其放大, 生成与真实样本大小相同的数据. 判别器的过程类似于执行分类任务的卷积神经网络. 它从真实样本和合成样本中向下采样并提取特征, 输出层产生 1 个维度为 1 的标量, 表示输出样本是真实样本的概率. 输出值越接近 1, 说明样本越真实.






图2 不同上扣工况下的典型 PTC 曲线

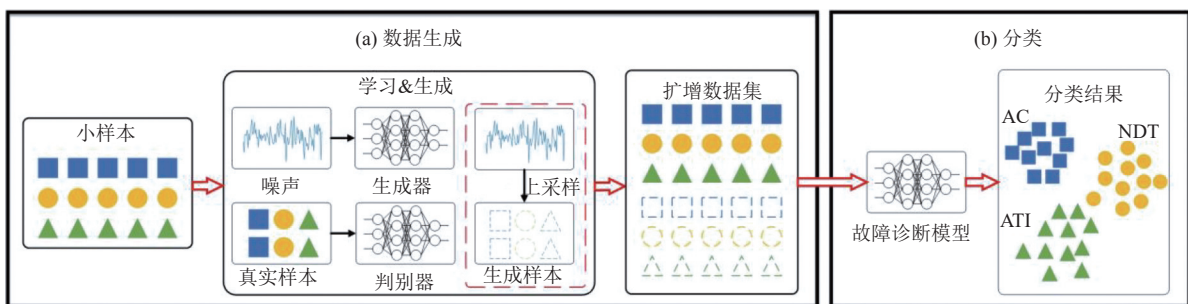


图3 混合深度学习模型的工作流程

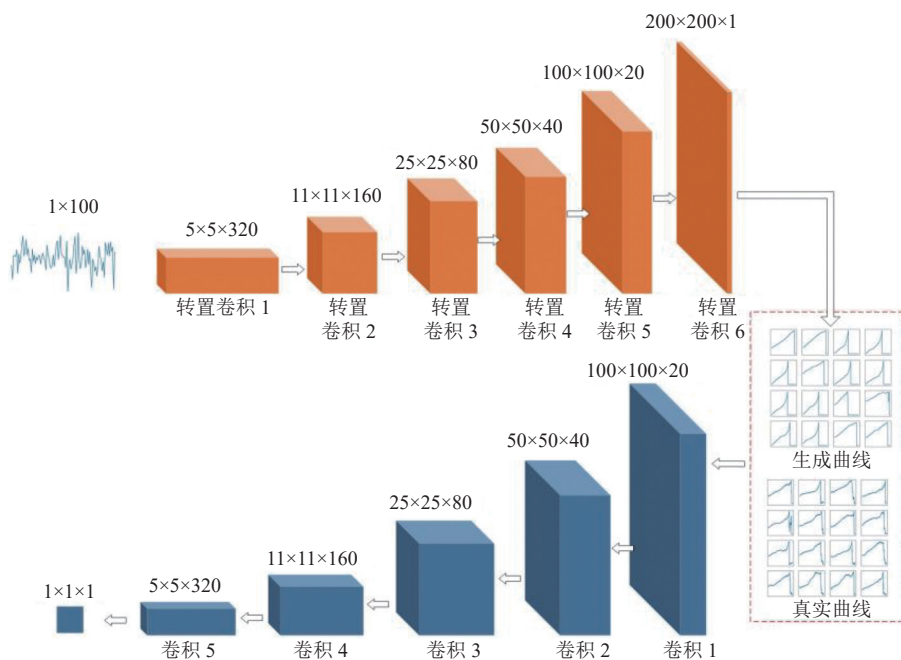


图4 AoT-DCGAN 的详细结构

为了使生成器和判别器达到纳什均衡状态,即生成器生成的样本是真实的,判别器无法将其与真实样本区分开,而生成器和判别器在区分生成的样本方面表现良好,生成器和判别器的权重需要使用不同算法

分别进行优化.如式(1)所示,判别器的目标是最小化使用二元交叉熵函数计算的真实样本和合成样本的损失函数.反之,生成器的目标是最小化被判别器分类为真实样本的假样本概率的负对数,如式(2)所示.在训

练过程中, 这些结果将通过反向传播来更新网络中相应神经元的权重.

$$L_D = -\log D(x) - \log(1 - D(G(z))) \quad (1)$$

$$L_G = -\log(D(G(z))) \quad (2)$$

其中,  $D$  和  $G$  分别代表判别器和生成器,  $L_D$  和  $L_G$  代表判别器和生成器的损失函数;  $x$  是训练数据集中的真实样本,  $z$  是随机噪声输入.  $G(z)$  表示将  $z$  映射到数据空间, 以符合真实样本的统计分布, 而  $D(x)$  则表示获取输入数据的概率.

然而, 在模型的初始训练阶段, 判别器可能会过度占据主导地位, 导致生成器难以获得有效的梯度信号来更新神经元的权重. 因此, 生成器可能会陷入局部最

优, 生成一组有限的样本, 而判别器无法识别这些样本, 无法覆盖整个数据分布. 为了缓解这些问题, 所提出的异步优化 (AO) 在反向传播过程的每次迭代中都会更新生成器的权重, 而判别器的权重则每 4 次迭代更新 1 次. 此外, 用于更新判别器的权重是通过周期内 4 次迭代的权重变化求平均值得到的. 判别器权重的具体优化方案如图 5 所示, 判别器的权重更新公式如下:

$$W_D = \frac{1}{n} \sum_{i=0}^n \frac{\partial \text{loss}_i}{\partial h_i} \quad (3)$$

其中,  $\partial \text{loss}_i$  表示第  $i$  次迭代中判别器的损失函数,  $\partial h_i$  表示第  $i$  次迭代中的权重参数. 变量  $n$  代表权重更新的迭代次数, 本研究将  $n$  设为 4.

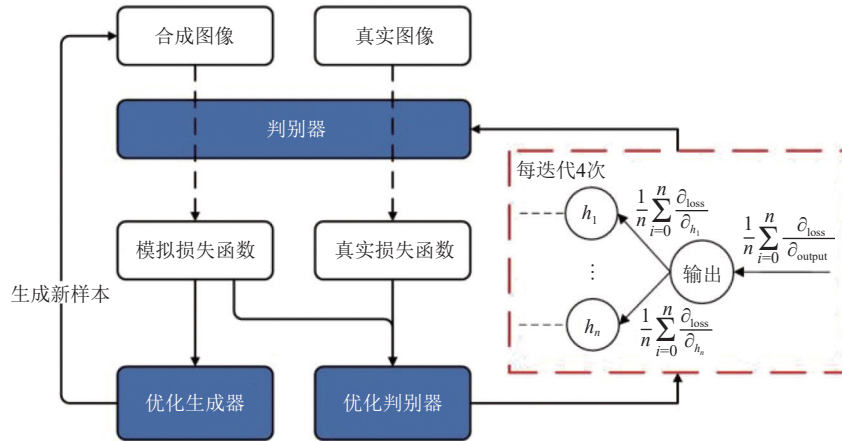


图 5 模型的异步优化方案

### (2) P-CNN 的结构

本文针对 PTC 曲线分类和识别任务构建了一种新型 P-CNN 模型架构. 模型构建过程基于一系列既定的设计原则<sup>[23]</sup>, 并根据实验结果对模型中的关键参数设置进行了调整, 包括卷积层数、卷积核大小、步长和随机失活参数等. 最终, 选择分类性能最佳的 P-CNN 模型配置作为最终的 PTC 曲线分类模型.

模型的具体结构如下: 输入层输入 AoT-DCGAN 生成的增强数据集. 特征提取层由 3 组堆叠卷积层组成, 每个卷积层后都应用最大池化. 在最后一个卷积层之后添加了 1 个“剔除”层, 以减少神经网络的过度拟合. 输出层由 1 个全连接层和 1 个 Softmax 层组成, 生成可能类别的概率分布. 具体来说, 卷积层使用 1 组可学习的卷积核进行卷积, 以提取 PTC 曲线的特征和细节. 最大池化层对特征图进行向下采样, 以减小其大小

并提高训练速度. 为防止过度拟合, 还采用一些技术, 包括用于特征图归一化的批量归一化层和随机丢弃部分神经元输出的“剔除”层. 图 6 展示了 P-CNN 的详细结构.

### 3 模型建立及实验分析

本节通过一系列对比实验来验证所提出的 AoT-DCGAN 和 P-CNN 混合深度学习模型在 PTC 曲线分类方面的优越性能. 实验还证实了所提 AoT-DCGAN 权重优化策略的有效性. 除了采用 t 分布随机邻域嵌入 (t-SNE) 和混淆矩阵等可视化技术外, 还使用了召回率和 F1 分数等各种指标进行评估, 以全面了解模型的性能. 图 7 是实验流程图. 具体实验流程如下.

(1) 数据采集: 通过气密封螺纹连接上扣实验生成原始 PTC 曲线.

(2) 数据集构建: 根据实验要求, 使用 AoT-DCGAN 对原始数据集进行扩增, 生成 4 组不同数量的数据集.

(3) 性能分析: 比较所提出的深度学习模型在不同数据扩增比率和分类模型下的性能. 此外, 还验证了本研究提出的权重优化策略的可靠性.

### 3.1 数据采集

本实验中使用的 PTC 曲线数据集是从一系列气

密封螺纹连接上扣实验中获得的. 图 8 展示了实验过程, 其中包括使用油管钳在油管上进行 PTC 的初始上扣, 然后使用智能扭矩仪记录在不同上扣工况下产生的 PTC 曲线. 具体的实验设备如图 9 所示. 扭矩仪以每转 50 个点的频率收集上扣过程中产生的扭矩值和相应的旋转圈数. 用于上扣的油管钳的最大上扣扭矩设定为 3500 N·m, 上扣速度为 30 转/min.

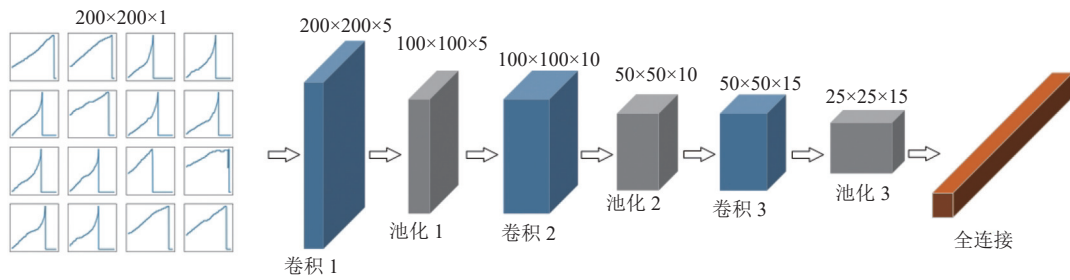


图 6 P-CNN 的详细结构




图 7 实验流程图

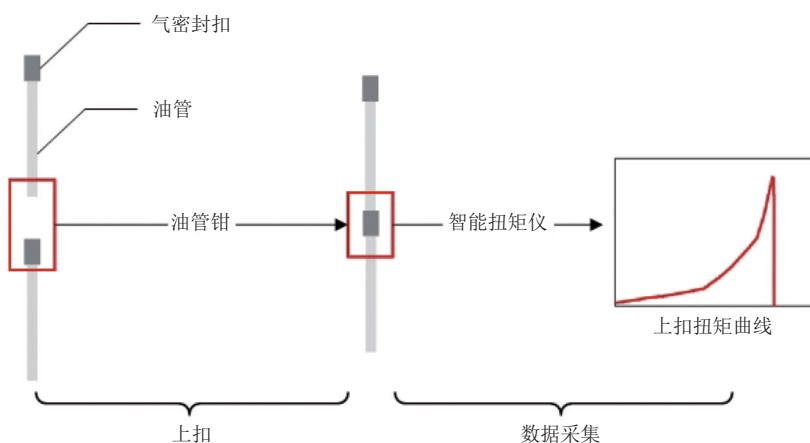


图 8 上扣和数据采集过程

本文模拟了 3 种上扣工况, 分别为标准上扣、螺纹损伤和螺纹错位. 根据不同工况的扭矩曲线特征, 质量诊断结果具体为: 标准上扣对应“合格 (AC)”, 螺纹损

伤对应“异常螺纹干涉 (ATI)”, 螺纹错位对应“无定义的扭矩 (NDT)”. 具体数据集信息详见表 1, 图 10 展示了 3 种工况下的上扣扭矩曲线示例.

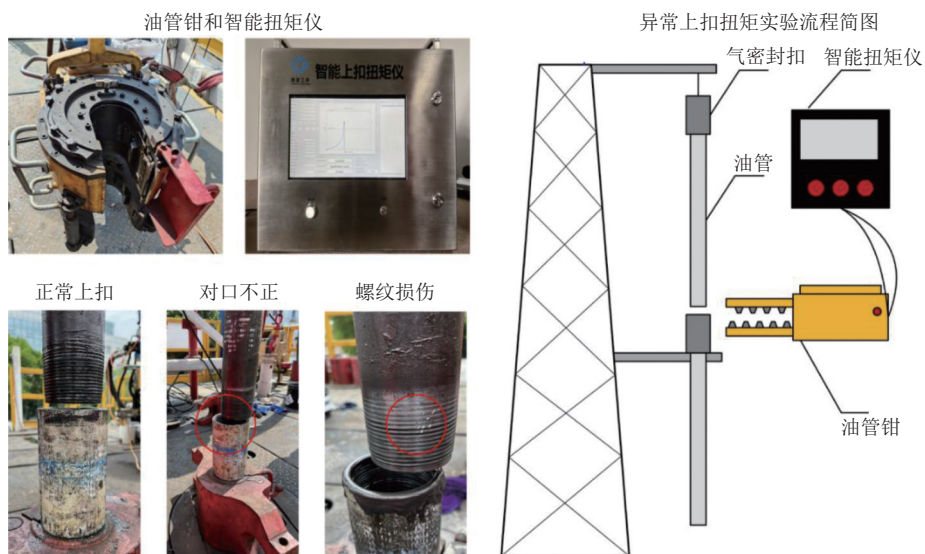


图9 实验设备和流程图

表1 数据集信息

上扣工况	曲线描述
标准	合格 (AC)
螺纹损伤	异常螺纹干涉 (ATI)
螺纹错位	无定义的扭矩 (NDT)

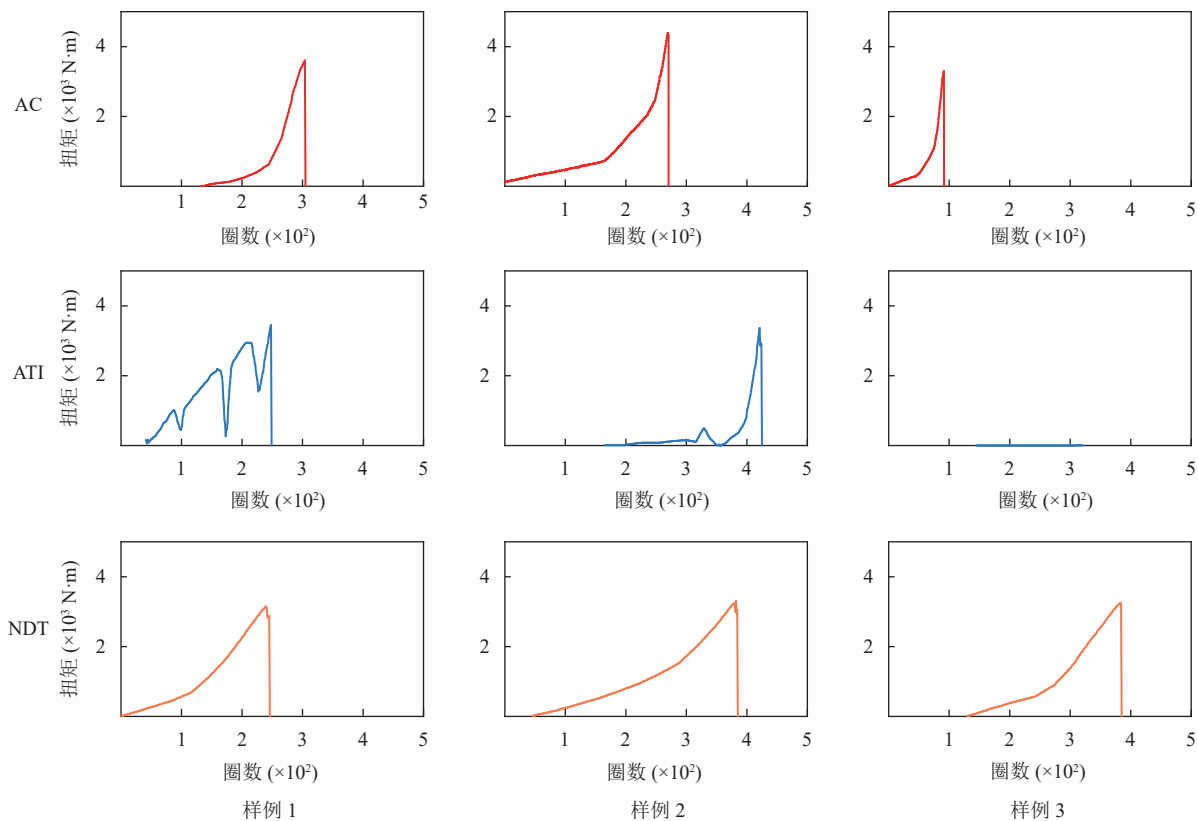


图10 实验中的 PTC 曲线示例



### 3.2 数据集构建

根据前述实验,共生成了600条原始PTC曲线,每个类别由200条曲线组成.该数据集被称为原始数据集,用于通过AoT-DCGAN模型生成合成的PTC曲线,并用于分类模型后续的对比较实验.为了确保模型生成高质量的PTC曲线,本文采用了一种权重优化策略,以促进判别器和生成器权重的异步更新.该策略旨在防止判别器的损失函数在早期训练阶段变得过小,从而阻碍权重更新.AoT-DCGAN模型使用原始数据集共生成了600条合成的PTC曲线,每个类别包含200条曲线.新生成的数据被添加到原始数据集中,形成了

数据增强比率为1.5、1.75和2的不同数据集.换句话说,增强数据集的大小分别是原始数据集的1.5倍、1.75倍和2倍.

图11显示了AoT-DCGAN在不同运行条件下生成的人工PTC曲线.其中第1列是原始的数据子集,代表3种真实工况下的图片,第2列、第3列则代表由第1列图片采用DCGAN生成的图片.可以看出,模型生成的曲线表现出与真实数据相似的特征.例如ATI曲线所示,真实样本的波动特征在生成的样本中得到了准确体现.因此,通过这种操作,可以扩展具有相似特征的数据集.

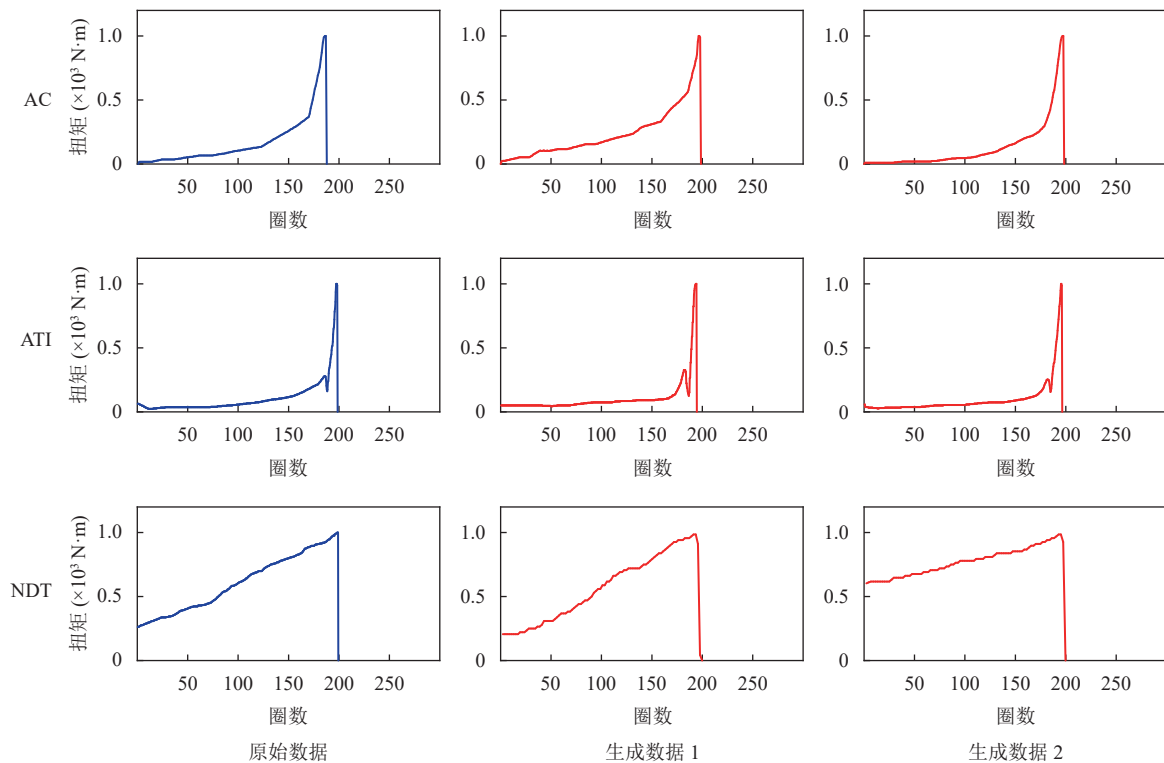


图11 AoT-DCGAN生成的真实和合成数据样本示例

### 3.3 性能分析

实验从3个方面验证了所提出的混合模型在PTC曲线分类中的优越性能.首先,利用4组不同规模的数据集进行对比实验,验证所提模型在不同数据增强比率下的分类性能.其次,与1组分类模型进行对比实验,以证明本文提出的P-CNN模型在相同数据集条件下对PTC曲线分类的优越性能.最后,使用3组损失函数进行了对比实验,以检验本文提出的异步优化策略对提高AoT-DCGAN训练过程的影响.表2列出了这些实验中使用的超参数.

在4组数据集大小的对比实验中,提出的混合模型在数据集大小为600、900、1050和1200时的性能得到了证明.其中,原始数据集大小为600,表明不使用AoT-DCGAN模型.数据集大小在900、1050和1200时对应的增强比率分别为1.5、1.75和2.在每一组中,训练集占数据集的80%,其余20%作为验证集.模型的性能使用召回率(式(4))、特异性(式(5))、F1分数(式(6))和精确率(式(7))进行评估.为减少随机性的影响,实验结果取5次试验的平均值.模型在不同数据集上的评估结果见表3-表5.

$$recall = \frac{T_p}{T_p + F_n} \quad (4)$$

$$specificity = \frac{T_n}{T_n + F_p} \quad (5)$$

$$F1\ score = 2 \times \frac{precision_n \times recall}{precision_n + recall} \quad (6)$$

$$precision_n = \frac{T_p}{T_p + F_p} \quad (7)$$

表 2 分类模型使用的超参数

超参数	额定数值
迭代周期 (Epoch)	250
批次数量 (Batch size)	16
学习率 (Learning rate)	0.002
优化器 (Optimizer type)	Adam
随机分组 (Shuffle)	每次迭代 (Every-epoch)

表 3 不同增强比率下合格 (AC) 曲线的分类评价指标 (%)

数据集规模	召回率	特异性	F1分数	精确率
600 (初始)	92.4	85.9	85.5	79.5
900	93.6	94.3	92.1	90.7
1050	95.9	98.4	95.9	95.9
1200	95.9	99.8	97.9	99.9

表 4 不同增强比率下异常螺旋干涉 (ATI) 曲线的分类评价指标 (%)

数据集规模	召回率	特异性	F1分数	精确率
600 (初始)	76.3	95.7	81.7	87.9
900	85.5	95.3	86.8	88.1
1050	92.5	93.8	91.1	89.8
1200	95.5	96.4	94.8	94.1

如表 3-表 5 所示,对于 AC 曲线,数据集大小为 1200 时的分类性能在所有指标中表现最佳,分别为 95.9%、99.8%、97.9% 和 99.9%。同样,对于 ATI 曲线,当数据集大小为 1200 时,其性能指标优于其他组别,分别为 95.5%、96.4%、94.8% 和 94.1%。NDT 曲线评估结果与前面的结果一致,当数据集大小为 1200 时,都达到了最佳性能,分别为 96.8%、97.4%、96.1% 和 95.4%。

表 5 不同增强比率下无定义的扭矩 (NDT) 曲线的分类评价指标 (%)

数据集规模	召回率	特异性	F1分数	精确率
600 (初始)	73.0	89.4	75.5	78.1
900	84.1	92.3	84.5	85.0
1050	90.6	96.5	92.0	93.5
1200	96.8	97.4	96.1	95.4

为了进一步证明 AoT-DCGAN 模型在提高 PTC 曲线分类性能方面的能力,本文利用 t-SNE 可视化方法描绘了 P-CNN 模型在 Softmax 层不同数据增强比率下获取的 PTC 曲线的内在结构和特征。如图 12 所示,不同颜色的数据点代表数据集中的样本,在图中,相似样本之间的距离较近,而不相似样本之间的距离相对较远。在图 12(a) 中,对于原始数据集,人工特征无法有效地聚类不同类型的曲线,导致不同曲线之间重叠,数据边界不清晰。然而,如图 12(b)-图 12(d) 所示,随着数据增强比率的增加,人工特征逐渐将不同类型的曲线聚类在一起,减少了不同曲线之间重叠的情况,数据边界也更加清晰。

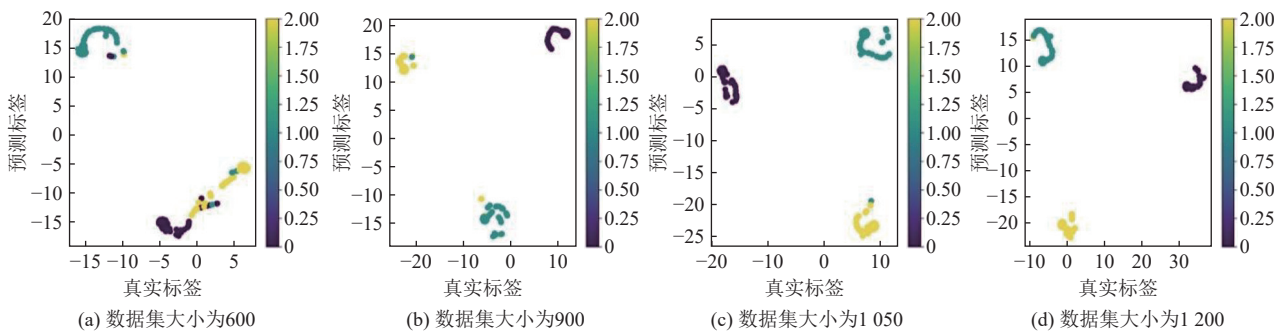


图 12 不同数据增强率的特征可视化

图 13 显示了所提模型在不同数据增强比率下的混淆矩阵结果。图 13 列对应预测标签,行对应真实标签。每个单元格代表真实类别和预测类别的组合,颜色表示预测的准确度,颜色越深表示预测越准确。结果显示,当数据集大小为 600 时,模型的预测准确率最低,对 AC、ATI 和 NDT 类别的预测准确率分别为

92%、76% 和 73%。特别是该模型对 ATI 和 NDT 的误判率最高,其中有 22% 的 ATI 曲线被错误地归类为 NDT。这可能是由于训练数据不足,模型无法区分 ATI 曲线的振荡特征和 NDT 曲线的平滑特征。此外,有 25% 的 NDT 曲线被错误地归类为 AC 曲线,这可能是由于某些 NDT 曲线的平滑特征与 AC 曲线的平

滑特征相似,难以分辨.在数据有限的情况下,模型很难准确提取出它们之间的区别特征.随着数据集规模的增加,模型在识别ATI和NDT方面的性能也有所

提升.当数据集规模达到1200时,模型对AC、ATI和NDT类别的预测准确率达到最佳,分别为96%、96%和97%.

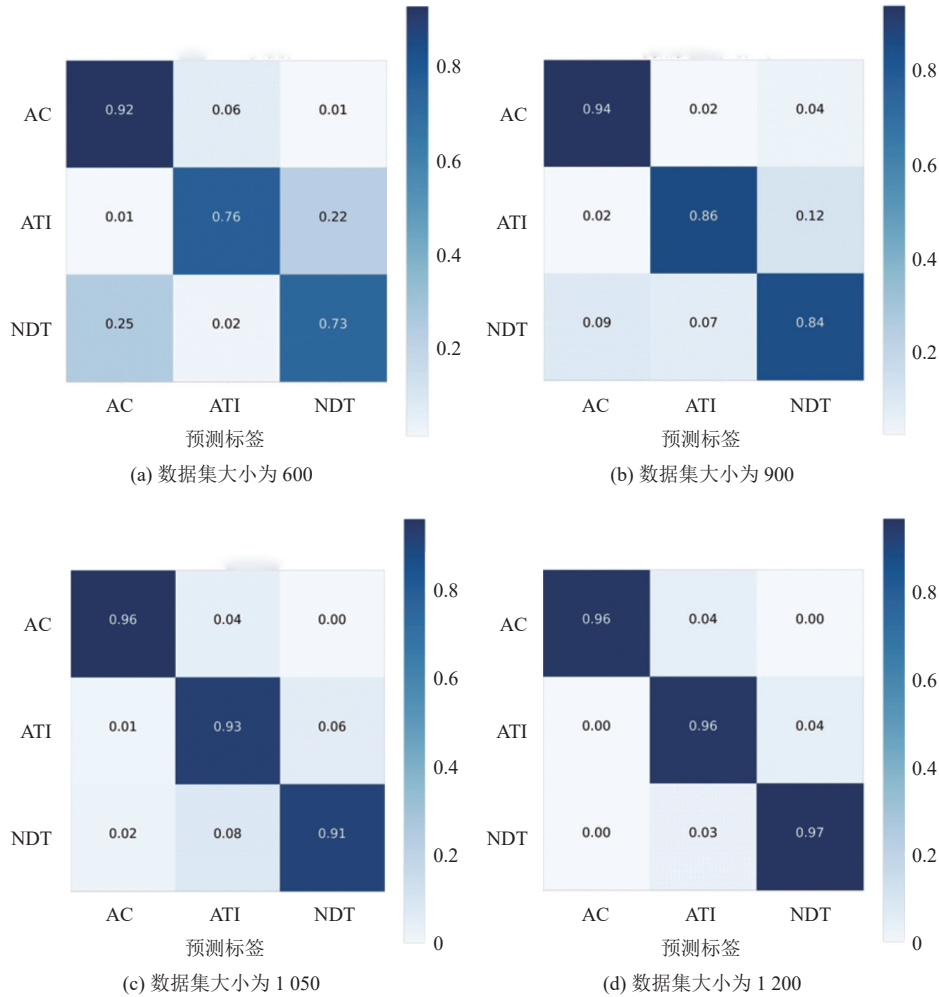


图 13 不同数据增强比率的混淆矩阵

在分类模型对比实验中,比较了数据集规模为1200时不同分类模型的性能.这些模型包括传统机器学习模型中的逻辑回归模型(LG)、传统深度学习模型中的神经网络模型(DNN)和本文设计的P-CNN模型.如图14所示,结果表明所提出的P-CNN在所有类别和总体准确率方面都优于其他模型,预测准确率分别为95.9%、95.5%和96.7%,总体准确率为96%.相比之下,虽然DNN在AC曲线上的表现与其他模型相当,预测准确率为95.2%,但它在ATI和NDT曲线上的准确率明显较低,分别为83.7%和84.2%,导致其总体准确率在所有模型中最低,仅为87.7%.LG模型的性能介于P-CNN和DNN之间,在AC、ATI和NDT

曲线上的准确率分别为94.3%、86.7%和87.1%,总体准确率为89.3%.

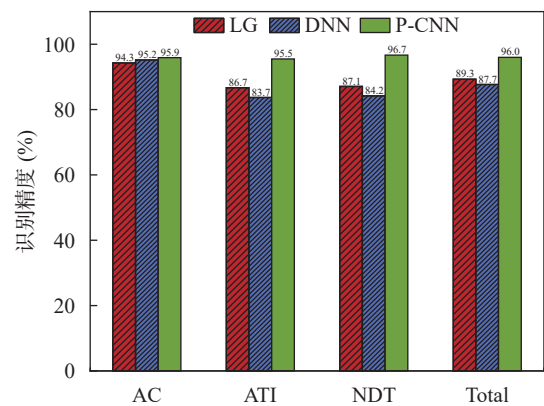


图 14 各种网络模型中每条曲线的识别准确率比较

在3组损失函数对比实验中,验证了所提出的权重优化策略对生成不同类型PTC曲线的模型损失函数的影响,如图15-图17所示。可以看出,对于AC、ATI和NDT曲线,不使用权重优化策略时,生成器的

损失函数无法稳定下降。相反,当采用权重优化策略时,生成器的损失函数会随着迭代次数的增加而持续下降,并最终达到稳定状态。此外,权重优化策略对判别器的损失函数也有影响,显示出更平滑的下降过程。




图15 用于生成AC曲线的AoT-DCGAN模型的损失函数




图16 用于生成ATI曲线的AoT-DCGAN模型的损失函数

#### 4 结论与讨论

在本文中,我们提出了一种改进的AoT-DCGAN和P-CNN混合深度学习模型,用于PTC曲线的自动识别和分类,从而实现对PTC连接质量的智能评估。该模型解决了以下难题:1)实现了PTC曲线的自动分类;2)克服了深度学习模型在处理小样本空间时分类性能有限的问题;3)引入一种权重优化策略,以缓解

DCGAN模型训练过程中的梯度消失问题。为了实现PTC的自动分类,本文设计了一种P-CNN模型,该模型能准确将PTC曲线分为不同类别。为解决小样本问题,本文设计了一个AoT-DCGAN模型来生成合成PTC曲线,从而扩增原始数据集。此外,本文采用异步优化策略来稳定生成器的梯度下降过程,从而生成逼真的合成PTC曲线。



通过一系列使用不同数据增强比率和传统分类模型的对比实验,我们发现随着数据集规模的增大,所提方法的性能显著提高,P-CNN在曲线分类任务中表现出更好的性能.t-SNE和混淆矩阵可视化进一步支持了这一结论,它表明模型的聚类能力与数据集规模之间

存在正相关.此外,我们还比较了DCGAN模型在不同优化策略下损失函数的变化,结果表明所提出的异步优化策略大大提高了生成器的性能.总之,本文提出的混合深度学习模型在PTC上扣质量评估中表现出优越的性能和巨大的潜力.




图17 用于生成NDT曲线的AoT-DCGAN模型的损失函数

此外,在数据生成过程中,还观察到AoT-DCGAN中生成器和判别器的权值更新频率和学习率对结果有显著影响.其中,学习率的选择对结果的影响更为明显.当使用较大的学习率时,损失函数迅速减小,但会导致模型拟合不足,无法进一步优化.因此,下一步将考虑在GAN模型中应用动态学习率来解决这一问题.

#### 参考文献

- 冯耀荣,付安庆,王建东,等.复杂工况油套管柱失效控制与完整性技术研究进展及展望.天然气工业,2020,40(2): 106–114. [doi: 10.3787/j.issn.1000-0976.2020.02.012]
- 郭建华,马发明.四川盆地高含硫气井油管螺纹气密封性能评价与应用——以龙岗气田为例.天然气工业,2013,33(1): 128–131. [doi: 10.3787/j.issn.1000-0976.2013.01.022]
- 张智,黄熠,李炎军,等.考虑腐蚀的环空带压井生产套管安全评价.西南石油大学学报(自然科学版),2014,36(2): 171–177. [doi: 10.11885/j.issn.1674-5086.2013.09.23.02]
- Chen W, Di QF, Zhang H, *et al.* The sealing mechanism of tubing and casing premium threaded connections under complex loads. Journal of Petroleum Science and Engineering, 2018, 171: 724–730. [doi: 10.1016/j.petrol.2018.07.079]
- Cui F, Li WJ, Wang GZ, *et al.* Design and study of gas-tight premium threads for tubing and casing. Journal of Petroleum Science and Engineering, 2015, 133: 208–217. [doi: 10.1016/j.petrol.2015.06.007]
- Hao L. The structural design of the threaded part of the premium connection tubing. IOP Conference Series: Earth and Environmental Science, 2021, 632: 052076. [doi: 10.1088/1755-1315/632/5/052076]
- Yang B, Xu HL, Xiang SL, *et al.* Effects of make-up torque on the sealability of sphere-type premium connection for tubing and casing strings. Processes, 2023, 11(1): 256. [doi: 10.3390/pr11010256]
- Ma ZH, Fan Y, Zhang HL, *et al.* Research on evaluation method of make-up torque of premium thread based on logistic regression. Proceedings of the 2021 International Field Exploration and Development Conference 2021. Singapore: Springer, 2021. 3840–3853. [doi: 10.1007/978-981-19-2149-0\_359]
- Rawat W, Wang ZH. Deep convolutional neural networks for image classification: A comprehensive review. Neural Computation, 2017, 29(9): 2352–2449. [doi: 10.1162/NECO\_a\_00990]
- 周飞燕,金林鹏,董军.卷积神经网络研究综述.计算机学报,2017,40(6): 1229–1251. [doi: 10.11897/SP.J.1016.2017.01229]

- 11 苏炯铭, 刘鸿福, 项凤涛, 等. 深度神经网络解释方法综述. 计算机工程, 2020, 46(9): 1–15. [doi: [10.19678/j.issn.1000-3428.0057951](https://doi.org/10.19678/j.issn.1000-3428.0057951)]
- 12 陈珂锐, 孟小峰. 机器学习的可解释性. 计算机研究与发展, 2020, 57(9): 1971–1986. [doi: [10.7544/issn1000-1239.2020.20190456](https://doi.org/10.7544/issn1000-1239.2020.20190456)]
- 13 司念文, 张文林, 屈丹, 等. 卷积神经网络表征可视化研究综述. 自动化学报, 2022, 48(8): 1890–1920. [doi: [10.16383/j.aas.c200554](https://doi.org/10.16383/j.aas.c200554)]
- 14 Qin JH, Pan WY, Xiang XY, *et al.* A biological image classification method based on improved CNN. Ecological Informatics, 2020, 58: 101093. [doi: [10.1016/j.ecoinf.2020.101093](https://doi.org/10.1016/j.ecoinf.2020.101093)]
- 15 Peng Y. Artificial intelligence applied in sucker rod pumping wells: Intelligent dynamometer card generation, diagnosis, and failure detection using deep neural networks. Proceedings of the 2019 SPE Annual Technical Conference and Exhibition. Calgary: SPE, 2019. [doi: [10.2118/196159-MS](https://doi.org/10.2118/196159-MS)]
- 16 Zhang RC, Wang LQ, Chen DC. An intelligent diagnosis method of the working conditions in sucker-rod pump wells based on convolutional neural networks and transfer learning. Energy Engineering, 2021, 118(4): 1069–1082. [doi: [10.32604/EE.2021.014961](https://doi.org/10.32604/EE.2021.014961)]
- 17 Tang SN, Yuan SQ, Zhu Y. Convolutional neural network in intelligent fault diagnosis toward rotatory machinery. IEEE Access, 2020, 8: 86510–86519. [doi: [10.1109/ACCESS.2020.2992692](https://doi.org/10.1109/ACCESS.2020.2992692)]
- 18 Shorten C, Khoshgoftaar TM. A survey on image data augmentation for deep learning. Journal of Big Data, 2019, 6(1): 60. [doi: [10.1186/s40537-019-0197-0](https://doi.org/10.1186/s40537-019-0197-0)]
- 19 Goodfellow I, Pouget-Abadie J, Mirza M, *et al.* Generative adversarial nets. Proceedings of the 28th International Conference on Neural Information Processing Systems. Montreal: MIT Press, 2014. 2672–2680.
- 20 杨鹏坤, 李金龙, 郝润来. 基于生成对抗网络的小样本图像数据增强技术. 网络安全与数据治理, 2023, 42(6): 79–84. [doi: [10.19358/j.issn.2097-1788.2023.06.013](https://doi.org/10.19358/j.issn.2097-1788.2023.06.013)]
- 21 Wang RG, Zhang SH, Chen ZY, *et al.* Enhanced generative adversarial network for extremely imbalanced fault diagnosis of rotating machine. Measurement, 2021, 180: 109467. [doi: [10.1016/j.measurement.2021.109467](https://doi.org/10.1016/j.measurement.2021.109467)]
- 22 Yu H, Wang H, Lian ZH. An assessment of seal ability of tubing threaded connections: A hybrid empirical-numerical method. Journal of Energy Resources Technology, 2023, 145(5): 052902. [doi: [10.1115/1.4056332](https://doi.org/10.1115/1.4056332)]
- 23 Szegedy C, Vanhoucke V, Ioffe S, *et al.* Rethinking the inception architecture for computer vision. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016. 2818–2826.

(校对责编: 王欣欣)