文章编号：1003－1251(2026)05－0017－08

杆泵机理协同 GAN 的抽油井故障样本扩充方法研究

李翔宇，于 博，袁春华

（沈阳理工大学 自动化与电气工程学院，沈阳 110159）

摘 要：针对有杆泵抽油井故障示功图数据不充足，不同故障下示功图样本数量分布不均衡，导致状态诊断可靠性低的问题，提出一种将机理模型与生成对抗网络(GAN)协同配合的样本扩充方法，该方法首先对抽油机重要结构进行动态分析，建立支持生成可靠示功图的机理模型，同时改进对抗生成网络；其次利用机理模型对故障数据进行扩充，使扩充样本具有真实性、多样性。采用油田实际数据开展实验，结果表明该方法使平均故障准确率提升至98.37%，对比 GAN、WGAN-UP、ACGAN 的平均故障诊断准确率分别提升了16.54、11.63、9.58 个百分点。

关 键 词：有杆泵；示功图；机理模型；生成对抗网络；样本扩充

中图分类号：TE355 **文献标志码**：A **DOI**：10.3969/j.issn.1003－1251.2026.05.003

Research on the Fault Sample Expansion Method of Oil Pumping Wells Based on the Synergistic GAN of Rod Pump Mechanism

LI XiangYu，YU Bo，YUAN ChunHua

（Shenyang Ligong University，Shen yang 110159，China）

Abstract：To address the issues of insufficient data on fault dynamometer cards for sucker rod pumping wells and the imbalanced distribution of samples under different fault conditions，which lead to unreliable state diagnosis，a sample augmentation method that synergistically combines a mechanistic model with a generative adversarial network (GAN) is proposed in this paper. Firstly，dynamic analysis of the key structures of the pumping unit is conducted to establish a mechanism model being capable of generating reliable dynamometer cards and improving GAN. Furthermore，the mechanistic model is utilized to augment fault data，ensuring the authenticity and diversity of the generated samples. Experiments conducted with actual oilfield data demonstrate that the proposed method improved the average fault diagnosis accuracy to 98.37%. Compared with GAN，WGAN-UP，and ACGAN，the average fault diagnosis accuracy was increased by 16.54，11.63，and 9.58 percentage points，respectively.

Key words：rod pump；dynamometer card；mechanism model；generative adversarial network；sample expansion

有杆泵抽油系统是一种广泛应用于人工举升采油的方式。在现代采油工业中有着举足轻重的作用[1－2]。采油场中，油井数量有限，地质、油层环境等因素大致相同，抽油井长时间工作导致运

收稿日期：2025－08－04

基金项目：国家自然科学基金项目(62173073)；辽宁省教育厅高等学校基本科研项目(JYTMS20230215)；辽宁省教育科学规划课题(JG22DB602)

作者简介：李翔宇(1982—)，男，副教授，博士；袁春华(1987—)，通信作者，女，副教授，博士。

行数据冗余但故障样本稀缺,难以获取故障类型覆盖度与样本数量均达标的故障样本集合,影响油井状态诊断效果[3]。

针对抽油井工作状态样本不足问题,Zuo 等[4]利用粒子群算法将电功率数据反演为示功图,但该方法无法对故障样本进行扩充。Wang 等[5]引入基于并行学习的新型数据增强机制 ParaDC 对小样本示功图数据进行数据增强。Zheng 等[6]针对有杆泵油井进行动态机理分析,建立出能够生成各种工作状态示功图的机理模型,为示功图的扩充提供了新思路,但忽略了生成示功图缺乏多样性的问题。生成对抗网络(GAN)目前已普遍应用于小样本故障数据扩充的研究中[7]。Yin 等[8]采用小批量方法改进的条件生成对抗网络(CGAN)对故障样本进行扩充。Hao 等[9]将辅助条件信息以及高斯混合噪音引入 Wasserstein 梯度惩罚 GAN(WGAN-GP)中,完成对故障样本的扩充。

本研究提出将可生成示功图的机理模型协同改进的 GAN 样本扩充的方法。首先对抽油机重要结构进行动态分析,构建可生成示功图的机理模型,将模型扩充样本与真实样本组成数据集;其次,应用改进后的 GAN 对数据集样本进行多样化、真实化处理,生成研究可行性样本。

1 有杆泵机理模型分析

1.1 四连杆机构机理分析

图 1 为有杆泵抽油井采油工艺原理图,四连杆机构是抽油井地上装置的重要组成部分,具有将曲柄的 360°(2π rad)旋转运动转化为抽油杆的垂直运动的功能[10]。对于游梁悬点的实时位移 $X(t)$ 与曲杆旋转角度的关系可由图 1 中四连杆机理图部分进行推导[11]。关键角度变量与长度变量的关系表达式为

$$\begin{cases}\theta=\arcsin\left(\dfrac{L}{N}\right)\\ \varphi(t)=2\pi-\beta(t)\\ \varphi_1(t)=\varphi(t)+\theta\\ E(t)=\sqrt{D^2+N^2-2DN\cos\varphi_1(t)}\\ \alpha_1(t)=\arccos\left(\dfrac{B^2+E^2(t)-C^2}{2BE(t)}\right)\\ \alpha_2(t)=\arcsin\left(\dfrac{D}{E(t)}\sin\varphi_1(t)\right)\\ \alpha(t)=\alpha_1(t)+\alpha_2(t)\end{cases}\tag{1}$$

式中:A、B、C、D 分别为游梁前杆长度、游梁后杆长度、连杆长度以及曲柄半径;H、L、N 分别表示游梁支点与曲柄旋转点的垂直高度、水平距离及直线距离(基杆长度);θ 为曲柄旋转点、游梁支点连线与曲柄旋转点处垂线的夹角(上述参数均为常量,具体数值因油井个体差异而有所不同[12]。);$\varphi(t)$、$\varphi_1(t)$、$\alpha_1(t)$、$\alpha_2(t)$、$\alpha(t)$ 为四连杆机构中 t 时刻重要角度变量(单位为 rad);$E(t)$ 为游梁支点与曲柄顶点的直线距离;β 为 φ 的周角。(上述参数均为变量,伴随四连杆机构的运行发生周期性变化。)

当悬点位于上下死点时,曲柄与连杆在一条直线上,此时驴头与基杆(游梁支点与曲柄旋转点连线)的夹角为

$$\begin{cases}\alpha_{\text{down}}=\arccos\left(\dfrac{B^2+N^2-(D+C)^2}{2BN}\right)\\ \alpha_{\text{up}}=\arccos\left(\dfrac{B^2+N^2-(C-D)^2}{2BN}\right)\end{cases}\tag{2}$$

式中:α_{down} 为下死点夹角;α_{up} 为上死点夹角。

在悬点位移的推导过程中,弧长近似等效于直线位移,并将上死点处的位移定义为 0。悬总位移 $X(t)$ 计算表达式为

$$X_{\max}=A(\alpha_{\text{down}}-\alpha_{\text{up}})\tag{3}$$

$$X(t)=A(\alpha(t)-\alpha_{\text{up}})\tag{4}$$

式中 $X_{\max}$ 为悬点系统冲程(最大冲程)。

1.2 悬点载荷机理分析

抽油杆在一个周期内向上运动阶段定义为上冲程,反之定义为下冲程。钢制抽油杆作为一种长度可达千米级的弹性体,在上下冲程交替过程中因负载的动态变化,会产生相应的形变,表现为持续交替的拉伸与压缩状态。本研究中,将抽油杆的形变过程近似为多弹簧阻尼系统[13]。

抽油杆近似的弹簧阻尼系统的输出 $\boldsymbol{U}(t)$ 根据牛顿第二定律可得

$$\boldsymbol{U}(t)=\boldsymbol{G}\ddot{\boldsymbol{Y}}(t)+\boldsymbol{Z}\dot{\boldsymbol{Y}}(t)+\boldsymbol{K}\boldsymbol{Y}(t)\tag{5}$$

式中:$\boldsymbol{G}$ 为质量矩阵;$\boldsymbol{Z}$ 为阻尼矩阵;$\boldsymbol{K}$ 为刚量矩阵;$\boldsymbol{Y}(t)$ 为距离向量。

悬点载荷 F 由多变量组合构成,根据机理分析,其表达式为

$$F=F_{\text{r}}+F_{\text{u}}+F_{\text{f}}+\eta\cdot F_{\text{i}}+\varepsilon\cdot(F_{\text{V}}+F_{\text{b}})\tag{6}$$

式中:F_{r} 为抽油杆载荷;F_{u} 为柱塞载荷;F_{f} 为摩擦载荷;F_{i} 为惯性载荷;F_{V} 为凡尔阻载荷;F_{b} 为抽油杆浮力;η 与 ε 定义为非 0 即 1 的常数值,当泵腔内的液体没有淹没柱塞时 η 为 1 且 ε 为 0,当泵腔内的液体淹没柱塞时 η 为 0 且 ε 为 1。

在公式(6)中,F_u 由液柱压力、泵腔压力、柱塞摩擦力组合而成,可表达为

$$F_u(t) = S_p(P_d + P(t)) + z_n\dot{\boldsymbol{Y}}(t) \tag{7}$$

式中:S_p 为柱塞横截面积;P_d 为液体的排出压力;$P(t)$ 为 t 时刻泵腔压力;z_n 为阻尼矩阵 $\boldsymbol{Z}$ 中的第 n 个元素。

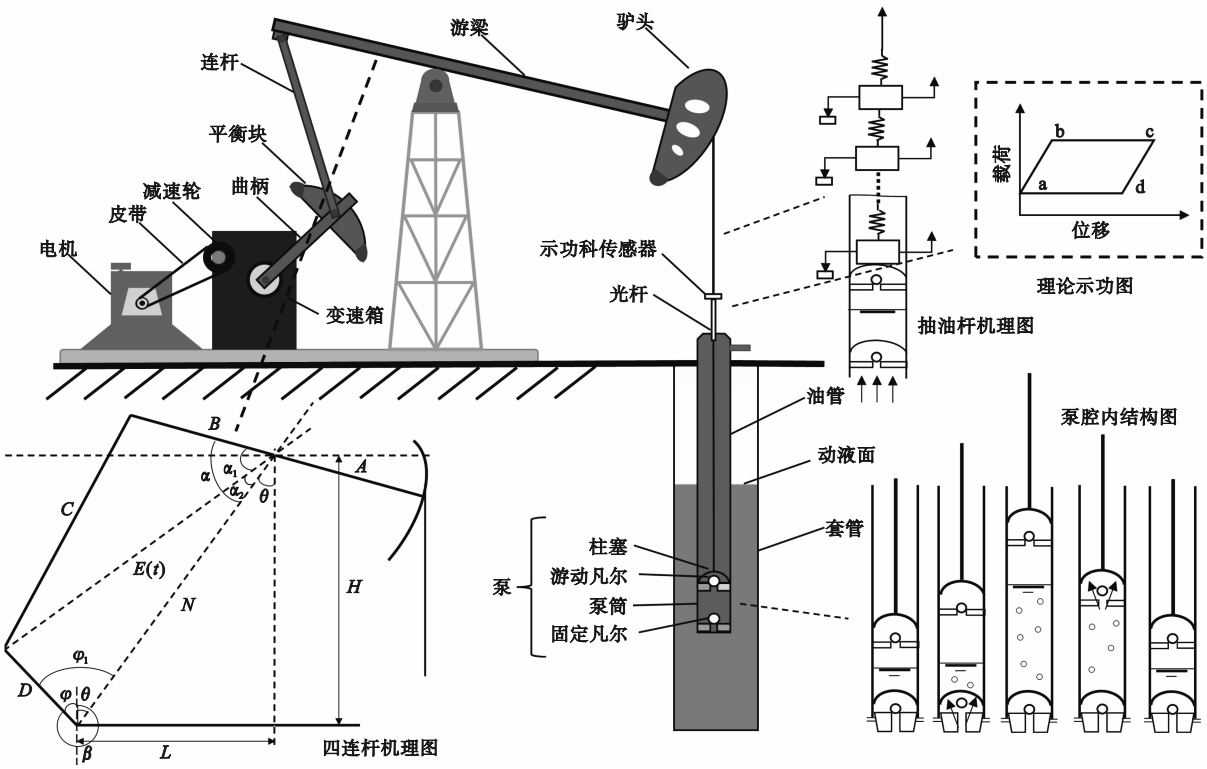


图 1　有杆泵采油工艺原理

Fig. 1　The principle of pumping well oil production technology

泵腔内容积的变化可表达为

$$V(t) = S_p x_s(t) + V_a \tag{8}$$

式中:$x_s(t)$ 为柱塞位移;V_a 为泵中空余容积。

计算泵腔压力变化时,设定单次冲程中泵腔内油水气质量比恒定且气体单一[14],游动阀开启后油液注入油管中,此时 $P(t)$ 等于 P_d。因此,本研究侧重凡尔开启前的压力分析,其分析表达式为

$$\begin{cases} \dfrac{M_g(t)}{M_l(t)} = \dfrac{V_{go}\rho_g}{V_l(t)\rho_l} = \xi \\ P(t)(V(t) - V_l(t))^j = M_g(t)R \\ P_o V_{go}^j = M_g(t)R \end{cases} \tag{9}$$

式中:$M_g(t)$、$M_l(t)$ 分别为游动凡尔开启前任意 t 时刻泵腔内气体质量以及液体质量;ρ_g、ρ_l 为泵腔内气体密度以及液体密度;$V_l(t)$ 为 t 时刻泵腔液体体积;ξ 为常数,代表泵腔内气体液体质量比;V_{go} 为在沉没压力为 P_o 时,质量为 $M_g(t)$ 的气体体积;j 为气体多方指数;R 为气体相关常数。

根据公式 9 可推出泵腔内压力,其表达式为

$$P(t) = P_o\left(\frac{V_l(t)\rho_l}{\rho_g(V(t) - V_l(t))}\right)^j \tag{10}$$

由上式可知,$V_l(t)$ 是求解 $P(t)$ 的一项重要参数。因此对 $V_l(t)$ 进行重点分析,将泵腔内液体分为泵腔余隙内液体体积 V_{la} 以及进泵腔的液体体积 $\Delta V_l(t)$ 两部分,表达式为

$$V_l(t) = V_{la} + \Delta V_l(t) \tag{11}$$

$\Delta V_l(t)$ 可根据牛顿 – 莱布尼茨公式推导为

$$\Delta V_l(t) = \int_{t_0}^{t_1} f(t)\,dt \tag{12}$$

式中:t_0,t_1 分别为固定凡尔开启时刻以及关闭时刻;$f(t)$ 为进泵液体流量。流动凡尔开启后,属于排液阶段,则 $V_l(t)$ 等于 $V(t)$。

依据能量守恒定律,在不考虑进泵液体位能损失的条件下,固定阀开启期间进入泵体的液体流量表达式为

$$f(t) = UA_d\sqrt{\frac{P(t) - P_0}{\lambda\rho_l}} \tag{13}$$

式中:U 为常数;A_d 为固定凡尔接触液体面积;λ 为固定凡尔阻力系数。

示功图是一种能够直观表征油井工作状态的闭合曲线,其通过描述悬点载荷与位移之间的对应关系构成。如图 1 中理论示功图所示,该闭合

曲线所围成的面积在物理意义上表示抽油机在一个冲程内所做功的大小。图中 ab 段对应增载过程,cd 段为卸载过程,bc 段表示活塞上行程阶段,ad 段则为活塞下行程阶段。其中 a 点称为下死点,c 点称为上死点。

通过对悬点位移及悬点载荷的动态分析,深入探究故障起因,从而调整与配置相关参数,便可生成与之对应的示功图样本。在生成示功图过程中,机理模型的约束系统由几何约束、动态约束、过程约束构成,用来约束其生成分布,确保其生成示功图与真实示功图分布对齐。

2 改进的生成对抗网络

本研究将自注意力机制与谱归一化处理联合应用于 GAN 的生成器与判别器中,同时保留 GAN 的基础框架。本研究设定生成器与判别器的优化器为 Adam,更新比例为1:1,学习率为 0.000 2。将上述网络在后续研究中称为 SASN-GAN,图 2 展示了 GAN 框架及其训练流程。

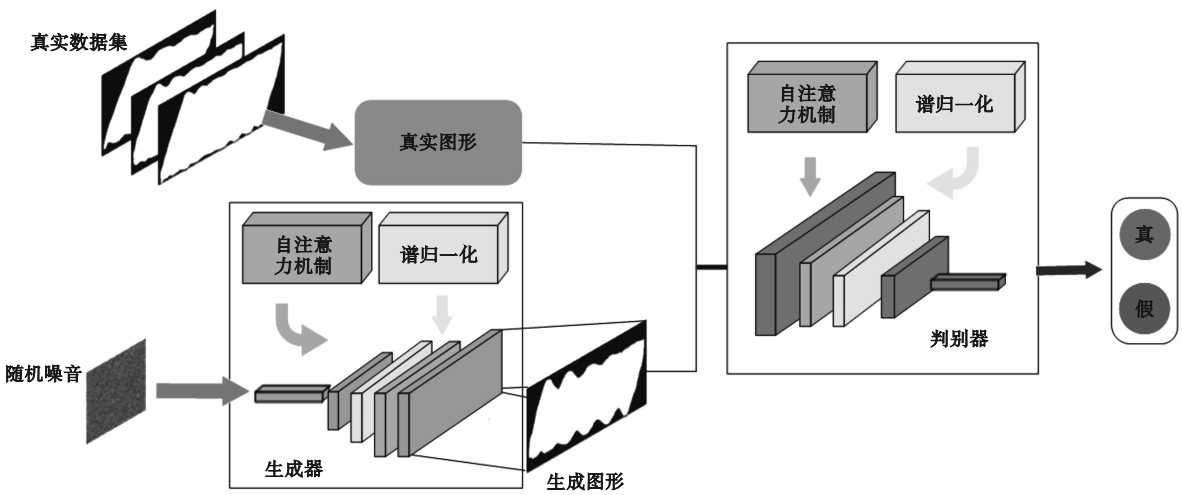


图 2 GAN 框架及其训练流程

Fig. 2 GAN framework and its training process

2.1 生成器模块的构成

本文所采用的生成器以多层全连接网络为基础架构,整合了谱归一化与自注意力机制。图 3 为改进的生成器结构。后续三个模块依次将特征维度扩展至 256、512 及 1 024,各模块均包含谱归一化线性变换、批归一化(动量设为 0.9)与 LeakyReLU 激活函数。256 维特征表示阶段引入自注意力模块,其头数为 4,借助提问、匹配、提取机制捕获长距离特征依赖关系,增强全局一致性[15]。最终生成器通过全连接层将 1 024 维特征映射至目标维度 3 × 123 × 199,并通过维度调整操作将其转换为 3 通道、123 × 199 像素的图像张量。输出层经 Sigmoid 激活函数归一化。该架构通过谱归一化稳定训练过程[16],其谱范数目标为 1,功率迭代步数为 1。自注意力机制增强特征关联性,有效提升示功图数据的生成质量。

2.2 判别器模块的构成

图 4 为改进的判别器结构,该判别器接收 3 × 123 × 199 维图像输入,经谱归一化线性层压缩至 512 维特征空间,并应用 LeakyReLU 激活函数。在特征表示阶段引入自注意力模块增强全局依赖性建模。经增强的特征通过谱归一化线性层进一步压缩至 256 维;最终经谱归一化线性层映射至标量输出,再通过 Sigmoid 函数归一化为 0 ~ 1 区间内的真实性得分。该架构通过谱归一化可有效稳定训练过程,自注意力机制则能增强特征的全

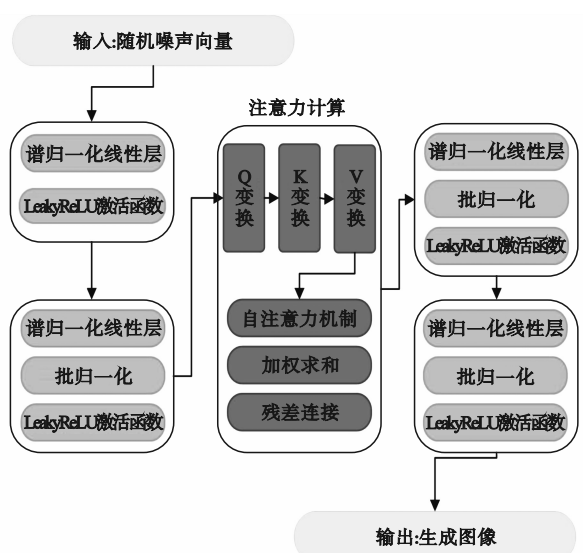


图 3 改进的生成器结构

Fig. 3 Improved generator structure

局关联性,进而提高判别器对真假图像的区分性能。

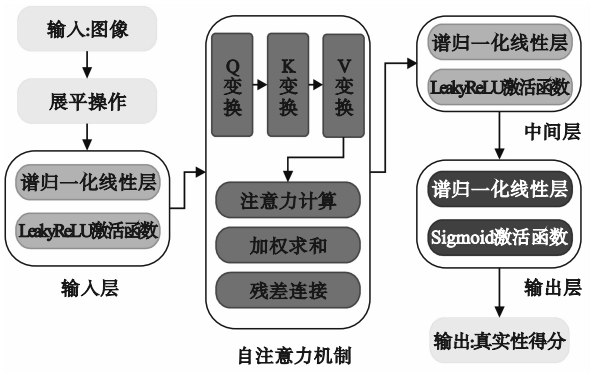


图 4　改进的判别器结构

Fig. 4　Improved discriminator structure

3　实验过程及结果分析

3.1　数据集的收集

本实验采集国内 10 口油井 1 450 组历史示功图作为数据集。包括正常状态、气体影响、固定凡尔漏失、移动凡尔漏失、出砂影响、供液不足、气锁七种工况。表 1 与表 2 分别为样本油井地上部分及地下部分的结构参数表。

表 1　抽油井地上部分结构参数表

Table 1　Surface structural parameters of rod pump wells

地上结构参数	参数值
游梁前臂长/m	3. 01
游梁后臂长/m	2. 40
连杆长/m	3. 35
曲柄半径/m	1. 15
曲柄轴至支架轴水平距离/m	2. 30

表 2　抽油井地下部分结构参数表

Table 2　Structural parameter table of the underground part of the oil well

地下结构参数	参数值
三联杆直径/mm	25/22/19
三联杆长度/m	302. 47/498. 60/994. 24
三连杆质量/kg	1 237. 1/1 565. 6/2 336. 5
泵径/mm	44
冲程长度/m	3
冲程周期/s	12

通过机理模型对油井进行样本扩充,图 5 为供液不足示功图,展示机理模型生成供液不足故障下不同程度的示功图样本。运用机理模型对 10 口油井的 7 种工况进行样本扩充,每种工况模拟 10 组,共 700 组(各工况 100 组),并将扩充样本与真实样本组合成 GAN 数据集。

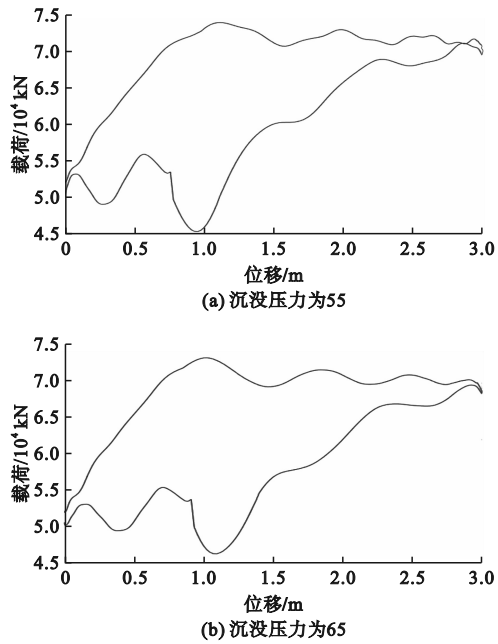


图 5　供液不足示功图样本

Fig. 5　Samples of indicator diagrams for insufficient liquid supply

3.2　GAN 训练及输出

为保障生成器与判别器高效稳定运行,对 GAN 数据集依次进行灰度、二值化、去坐标处理,并将像素统一缩放至 199 × 123,随后对轮廓进行提取,并对轮廓外区域进行黑色填充。图 6 为示功图预处理效果图,该预处理方法有效提取并且保留了示功图的重要形态学特征,并不会对诊断结果造成影响。图 7 为样本扩充方法框架。

设置迭代次数为 400 轮,每批次实验样本量为 2,图 8 为训练过程,其中 8(a)、8(b)分别展示气锁、固定凡尔漏失两种故障迭代次数为 1、100、200、300 时故障类型的模型输出效果。图 9 为生成的不同工况示功图,展示了 GAN 生成的 7 种工况示功图与原始示功图的对比结果。

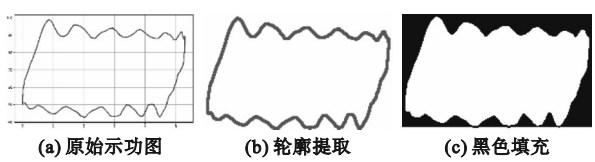


图 6　示功图预处理效果图

Fig. 6　Preprocessing effect diagrams of the indicator diagrams

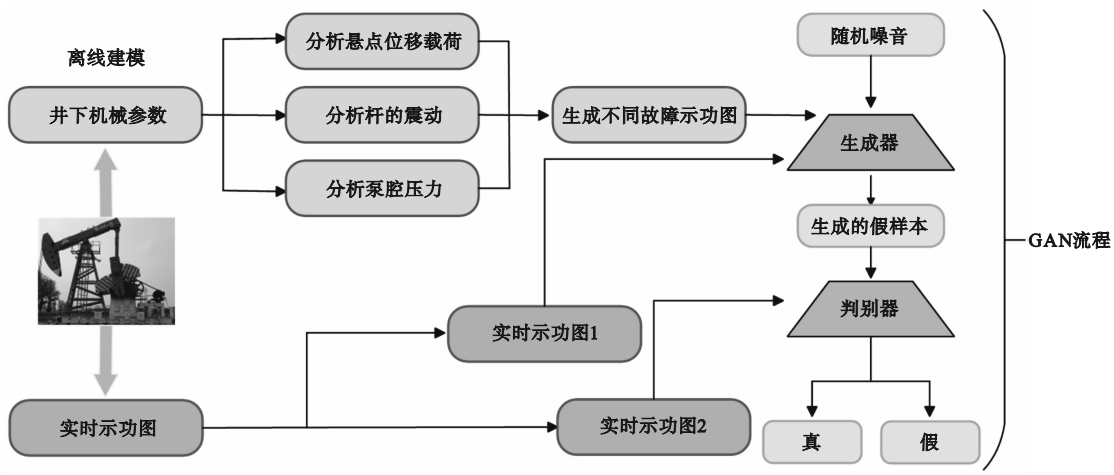


图 7 样本扩充方法框架

Fig. 7 Sample expansion method framework

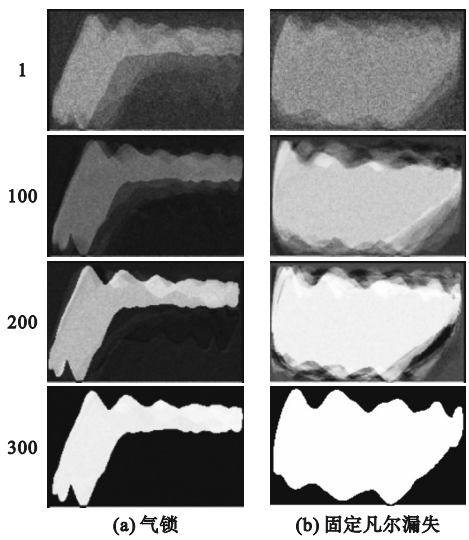


图 8 训练过程

Fig. 8 Training process

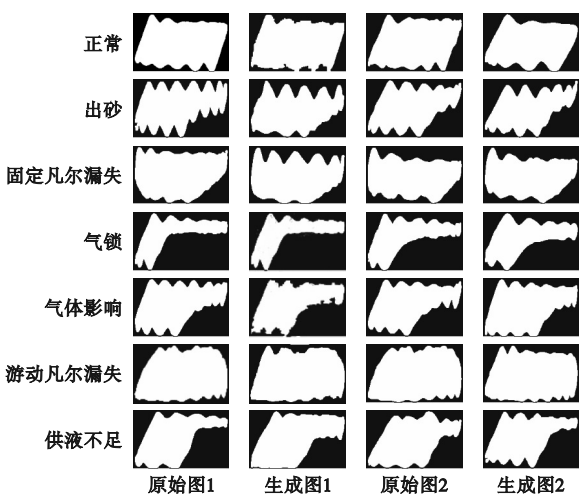


图 9 生成的不同工况示功图

Fig. 9 Indicator diagrams generated under various working conditions

3.3 对比验证

为验证 SASN-GAN 网络在示功图生成上的表现,与文献[17]的 GAN、文献[18]的 WGAN 网络比较,图 10 为对比不同方法生成的示功图,展示三种方法在三种工况下扩充的示功图。将三种方法扩充的 7 种故障示功图数据作为测试集,分别在文献[19]的 ResNet、文献[20]的 VGGNet、文献[21]的 AlexNet 识别网络上测试,表 3 为三种网络识别准确率对比表。图 11 为准确率统计图展现的对比结果。

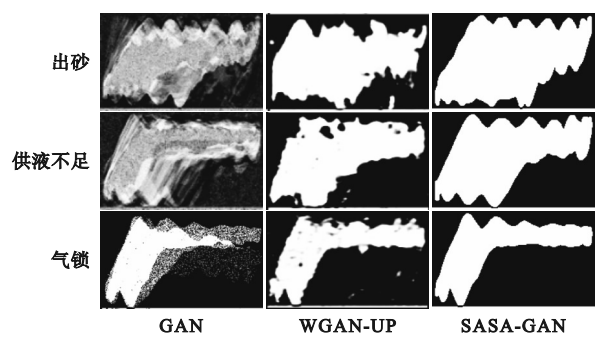


图 10 对比不同方法生成的示功图

Fig. 10 Comparison of indicator diagrams generated by different methods

表 3 三种网络识别准确率对比表

Table 3 Comparison of the accuracy rates of the three networks

模型	ResNet/%	VGGNet/%	AlexNet/%
GAN	81.23	83.16	81.11
WGAN	83.03	84.31	85.41
本文模型	85.05	87.86	89.32

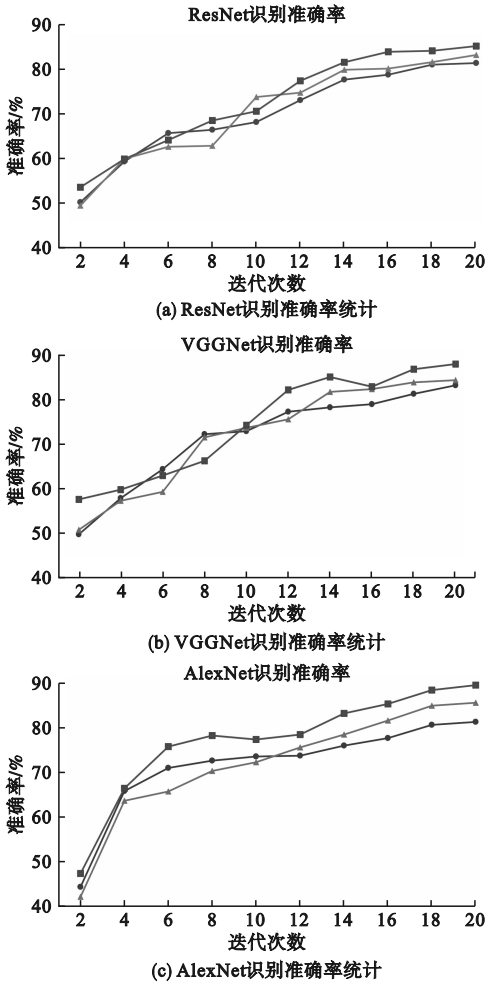


图 11　网络识别准确率统计

Fig. 11　Statistical results of AlexNet identification accuracy

选取不同模型生成的每种工况示功图各 300 张,计算生成示功图与原始示功图的召回率、准确率及 FID 分数,表 4 为三种模型评价指标对比表。由表 4 可见,SASN-GAN 网络在三种识别网络中准确度率均高于 GAN、WGAN,且准确率变化趋势最稳定,同时各项评价指标均优于其他两种模型,验证了 SASN-GAN 网络用于扩充故障示功图样本的优越性。

表 4　三种模型的评价指标对比表

Table 4　Comparison of evaluation indicators of the three models

模型	召回率/%	精确率/%	FID 分数
GAN	81. 36	79. 47	132. 51
WGAN	87. 68	92. 17	97. 87
本文模型	95. 84	96. 49	37. 06

尽管 SASN-GAN 的 FID 指标较为优秀,但结果与原始样本仍存在一定域偏差,在复杂工况下生成图像区分度偶有不足,原因可能为判别器对高频特征捕捉尚不充分,预处理中过滤了部分背景噪声,导致生成分布与原始分布存在细微差异。未来拟引入多尺度判别器与频率损失函数,增强高频细节约束,减少域偏差,并将真实噪音模式融入生成过程,进一步提升样本真实性。

3. 4　SASN-GAN 方法优势量化分析

为评价本文研究提出的样本扩充方法相较于常规方法的提升效果,将其与多种方法在完全相同的测试条件下进行对比,表 6 为准确率量化对比表。该量化结果表明本实验提出的方法在提高故障诊断准确率上具有一定优势。

表 5　准确率量化对比表

Table 5　Accuracy rate quantitative comparison table

样本	ResNet/%	VGGNet/%	AlexNet/%	准确率平均值/%
原始样本	68. 24	72. 91	73. 43	71. 53
GAN 样本	81. 23	83. 16	81. 11	81. 83
WGAN 样本	83. 03	87. 86	89. 32	86. 74
ACGAN[22] 样本	86. 32	89. 56	90. 48	88. 79
本文方法样本	97. 23	98. 46	99. 41	98. 37

4　总结

为了提高有杆泵抽油井状态诊断训练数据集的可靠性,本研究提出了机理模型协同 GAN 的样本扩充方法。首先,对抽油井开展动态分析,构建可生成示功图的机理模型,将该模型生成的不同样本数据融入原始数据,作为 GAN 的训练集;其次,在 GAN 框架中引入自注意力机制模块,以增强模型对不同故障细微波动的敏感性;在 GAN 的生成器与判别器中加入谱归一化,进而增强生成结果的多样性与真实性。通过对比实验,证明了本方法的有效性。在方法优势量化分析中,证明了扩充样本在故障诊断平均准确率上比原始数据提升了 26. 84 个百分点,对比 GAN、WGAN、ACGAN,其平均准确率分别提升了 16. 54、11. 63、9. 58 个百分点。研究结果表明,本文方法为油田故障样本稀缺与故障样本数量分布不平衡的问题提供了有效解决途径。

参考文献(References):

[1]　李翔宇. 有杆泵采油过程动液面软测量方法研究[D]. 沈阳:东北大学,2016.

[2]　Zheng B Y,Gao X W,Li X Y. Fault detection for sucker rod

pump based on motor power[J]. Control Engineering Practice,2019,86:37 – 47.
[3] Liu J Z,Feng J,Gao X W. Fault diagnosis of rod pumping wells based on support vector machine optimized by improved chicken swarm optimization[J]. IEEE Access, 2019, 7: 171598 – 171608.
[4] Zuo J Y,Wu Y,Wang Z Y,et al. A novel hybrid method for indirect measurement dynamometer card using measured motor power in sucker rod pumping system[J]. IEEE Sensors Journal,2022,22(14):13971 – 13980.
[5] Wang X X,Liu Y H,Cheng X,et al. ParaDC:Parallel-learning-based dynamometer cards augmentation with diffusion models in sucker rod pump systems[J]. Neurocomputing, 2025,617:128973.
[6] Zheng B Y,Gao X W,Li X Y. Diagnosis of Sucker Rod Pump based on generating dynamometer cards[J]. Journal of Process Control,2019,77:76 – 88.
[7] 魏书荣,殷世杰,闫梦飞,等. 基于改进生成对抗网络的海上风电机组故障数据增强及诊断[J]. 电力系统保护与控制,2025,53(1):114 – 124.
Wei S R,Yin S J,Yan M F,et al. Offshore wind turbine fault data enhancement and diagnosis based on an improved generative adversarial network[J]. Power System Protection and Control,2025,53(1):114 – 124. (in Chinese)
[8] Yin C Z,Zhang K,Zhang L M,et al. Imbalanced working states recognition of sucker rod well dynamometer cards based on data generation and diversity augmentation[J]. SPE Journal,2023,28(4):1925 – 1944.
[9] Hao D Z,Gao X W,Qi W H. Data augmentation method based on improved generative adversarial network for the sucker rod pump system[J]. International Journal of Control, Automation and Systems,2022,20(11):3718 – 3730.
[10] Utemissova L,Merembayev T,Bekbau B,et al. Predictive analytics for sucker rod pump failures in kazakhstani oil wells using machine learning[J]. Applied Sciences,2024,14(23): 10914.
[11] Wang J,Guo Q Y,Fu C L,et al. A novel optimization scheme for structure and balance of compound balanced beam pumping units using the PSO,GA,and GWO algorithms[J]. Petroleum Science,2025,22(3):1340 – 1359.
[12] Zhao H J,Wang J P,Liu T Y,et al. Research on the soft-sensing method of indicator diagram of beam pumping unit[J]. Sensors,2024,24(6):1794.
[13] 李翔宇,高宪文,侯延彬,等. 游梁式抽油机悬点负载耦合动力学建模[J]. 东北大学学报(自然科学版),2016,37(9):1225 – 1229.
Li X Y,Gao X W,Hou Y B,et al. Coupled dynamic modeling for polished rod load of beam pumping unit[J]. Journal of Northeastern University (Natural Science),2016,37(9): 1225 – 1229. (in Chinese)
[14] 李翔宇,袁春华,高宪文. 有杆泵抽油井采油过程建模[J]. 沈阳理工大学学报,2021,40(1):12 – 18.
Li X Y,Yuan C H,Gao X W. Modelling of sucker-rod pumping process[J]. Journal of Shenyang Ligong University, 2021,40(1):12 – 18. (in Chinese)
[15] 崔吉强,高军伟,吴文凯,等. 基于并行注意力机制的滚动轴承故障诊断方法[J/OL]. 控制工程,2025:1 – 8. (2025-01-22). https://doi.org/10.14107/j.cnki.kzgc.20240841.
Cui J Q,Gao J W,Wu W K,et al. Fault diagnosis method for rolling bearings based on parallel attention mechanism[J/OL]. Control Enginnering of China,2025:1 – 8. (2025-01-22). https://doi.org/10.14107/j.cnki.kzgc.20240841.
[16] 李洁松,刘韬,伍星. 谱归一化 CycleGAN 的轴承故障迁移诊断研究[J]. 振动与冲击,2023,42(24):282 – 289.
Li J S,Liu T,Wu X. Spectral normalization CycleGAN for bearing fault transfer diagnosis[J]. Journal of Vibration and Shock,2023,42(24):282 – 289. (in Chinese)
[17] Chen G,Sheng B Y,Fu G C,et al. A GAN-based method for diagnosing bodywork spot welding defects in response to small sample condition[J]. Applied Soft Computing,2024, 157:111544.
[18] Chen J Y,Yan Z T,Lin C Y,et al. Aero-engine high speed bearing fault diagnosis for data imbalance:a sample enhanced diagnostic method based on pre-training WGAN-GP[J]. Measurement,2023,213:112709.
[19] Razavi M,Mavaddati S,Koohi H. ResNet deep models and transfer learning technique for classification and quality detection of rice cultivars[J]. Expert Systems with Applications, 2024,247:123276.
[20] Zhong Y S,Lin H Y,Gan J C,et al. Quality grading of dried abalone using an optimized VGGNet[J]. Applied Sciences, 2024,14(13):5894.
[21] Zhang C,Zhang H,Tian F,et al. Research on sheep face recognition algorithm based on improved AlexNet model[J]. Neural Computing and Applications,2023,35(36):24971 – 24979.
[22] Wang C,Ma J J,Jin H,et al. ACGAN and BN based method for downhole incident diagnosis during the drilling process with small sample data size[J]. Ocean Engineering,2022, 256:111516.

(责任编辑:和晓军)

(上接第 16 页)

[20] Wang F,Feng J W,Zhao Y L,et al. Joint activity recognition and indoor localization with WiFi fingerprints[J]. IEEE Access,2019,7:80058 – 80068.
[21] Zhang X,Tang C P,Yin K,et al. WiFi-based cross-domain gesture recognition via modified prototypical networks[J]. IEEE Internet of Things Journal,2022,9(11):8584 – 8596.
[22] Ma Y S,Zhou G,Wang S Q,et al. SignFi:sign language recognition using WiFi[J]. Proceedings of the ACM on Interactive,Mobile,Wearable and Ubiquitous Technologies,2018,2(1):1 – 21.

(责任编辑:和晓军)