

基于 CGAN 的抽油机电参数反演示功图研究

李翔宇, 邓昱航, 袁春华

(沈阳理工大学 自动化与电气工程学院, 沈阳 110159)

摘要: 示功图的精准测量在有杆抽油系统故障诊断中非常重要, 针对载荷传感器直接测量法维护成本高、稳定性差, 电参数间接测量法精度低、应用性不强的问题, 提出一种基于条件生成对抗网络(CGAN)的电参数反演示功图混合模型。首先建立将电参数和机构参数转化光杆位移和负载的机理模型, 生成粗糙的示功图样本数据; 然后利用 CGAN 在图像转换领域的应用, 建立粗糙示功图数据细化器, 实现粗糙示功图与实测示功图之间的图像转化, 使粗糙示功图与实测示功图更加相似; 此外, 为了使 CGAN 能更好地提取示功图轮廓, 在生成器中加入自注意力机制进行改进。通过现场实测的电参数和示功图历史数据进行验证, 结果表明该方法对比纯机理模型反演示功图的精度有显著提高。

关键词: 示功图测量; 电参反演; 条件生成对抗网络; 图像转化

中图分类号: TE355 文献标志码: A DOI:10.3969/j.issn.1003-1251.2024.03.001

Study on the Inversion of Dynamometer Cards for Beam Pumping Units Based on Conditional Generative Adversarial Networks

LI Xiangyu, DENG Yuhang, YUAN Chunhua

(Shenyang Ligong University, Shenyang 110159, China)

Abstract: Accurate measurement of dynamometer cards is crucial in diagnosing faults in rod pumping systems. For the high maintenance cost and poor stability of direct load sensor measurement methods, and the low precision and weak applicability of indirect electrical parameter measurement methods, a hybrid model of electric parameter inversion dynamometer card based on conditional generative adversarial networks (CGAN) is proposed. Firstly, a mechanism model is established to transform electrical parameters and mechanical parameters into polished rod displacement and load, generating rough dynamometer card sample data. Then, leveraging the application of CGAN in the field of image transformation, a refiner is created for rough dynamometer card data to achieve image transformation between rough and actual dynamometer cards, making them more alike. In addition, in order to allow CGAN to better extract dynamometer card contours, a self-attention mechanism is incorporated into the generator for enhancement. Finally, this method is validated with field-measured historical electrical parameters and dynamometer card data. The results show that this method significantly improves the accuracy compared to the pure mechanism model inversion dynamometer card.

Key words: dynamometer card measurement; electrical parameter inversion; conditional generative adversarial networks; image transformation

收稿日期: 2023-06-14

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(LJKMZ20220618); 辽宁省本科教改优质教学资源建设与共享项目(SBKJGYZ-2021-06)

作者简介: 李翔宇(1982—), 男, 副教授, 博士, 研究方向为复杂工业过程建模、诊断与控制; 袁春华(1987—), 通信作者, 女, 副教授, 博士, 研究方向为复杂工业过程建模、诊断与控制。

示功图反映了抽油杆的一次往复性抽油运动,其图形特征是分析抽油机泵工况的重要参数,表征着抽油系统的实际运行状态以及各类异常故障现象。因此,示功图的实时、准确和高效测量一直是当前油井工况分析的关键技术,也是调控及优化系统运行效率的基础。现阶段生产中常用的示功图采集方式通过直接安装载荷传感器实现^[1],该方法存在诸多缺陷:示功仪的安装需要卸载悬挂点,操作繁琐,存在安全隐患;测量仪更换电池和安装负载传感器时需要强制停产,影响生产效益^[2]。

针对上述不足,广大学者致力于利用油井上易收集的电参数实现与示功图同步采集和实时转换的研究。其中绝大多数学者都是基于扭矩因数法^[3]实现电参数反演悬点载荷,从而得到示功图。然而扭矩因数在悬点上下死点附近等于0,导致反演的示功图会在上下死点区域发散,虽然可以在扭矩因数等于0附近进行补偿^[4],但是会大大降低反演示功图的精度。且此类方法的测量精度同时易受地面和井下复杂工况、抽油机不平衡度情况的影响,工程应用性不强。

近年来,通过“零和博弈”进行训练的生成对抗网络(GAN)被广泛应用于生成更真实的数据^[5]。Guo等^[6]通过GAN在合成孔径雷达领域开发了一种端到端的模型,可以直接合成所需图像;Li等^[7]提出了一种从空中图像和深度配对生

成逼真水下图像的GAN;程平^[8]利用改进的GAN实现了行人姿态到行人图像的转换。

受上述启发,为解决扭矩因数法反演示功图和实测数据之间存在较大误差的难题,结合条件生成对抗网络(CGAN)^[9]在图像转化领域的研究成果,本文提出一种基于CGAN的示功图反演模型。首先根据有杆抽油系统的运动规律和电机的工作原理建立系统输入电参数计算悬点载荷以及光杆位移的机理模型;然后使用CGAN建立粗糙数据细化器,对机理模型生成的粗糙示功图进行细化,针对图像轮廓的特征,在CGAN的生成器中加入自注意力机制^[10]使细化后的示功图与实测示功图更加相似;最后将历史采集的电机输入电参数代入计算,通过机理模型和粗糙数据细化器后得到最终反演的示功图。

1 基于电参数的机理模型

游梁式抽油系统的结构如图1所示。在工作过程中,抽油杆做上下往复运动,每个循环称为一次冲程。在一个冲程中,悬点上的载荷与位移变化的关系曲线称为示功图。曲线是闭合的,面积为抽油机在一个冲程内做功的大小,其中A点对应的是“下死点”,B点为抽油机固定凡尔打开点,C点对应的是“上死点”,D点则为游动凡尔开启点。




图1 游梁式抽油系统结构示意图

Fig. 1 Schematic diagram of the structure of the beam pumping system

1.1 电机机理模型

油田中广泛应用的异步交流电机模型如图2所示,将其定子和转子分别等效为三个电感元素,六个等效电感在此过程中会发生自感、互感以及漏感之间的交互作用。其中:A、B、C和a、b、c分别表示三个定子和转子; U_A 、 U_B 、 U_C 分别为三个定子的电压; I_A 、 I_B 、 I_C 、 I_a 、 I_b 、 I_c 则分别是三个定子和三个转子的电流;电感元素随着转子以角速度 ω_r 转动; θ_r 是各元素与转子位置角。由此机理推导出的电机电压方程为

$$\begin{bmatrix} U_s \\ U_r \end{bmatrix} = \begin{bmatrix} I_s \\ I_r \end{bmatrix} \begin{bmatrix} R_s & 0 \\ 0 & R_r \end{bmatrix} + p \times \begin{bmatrix} L_s & M_{sr} \\ M_{rs} & L_r \end{bmatrix} \begin{bmatrix} I_s \\ I_r \end{bmatrix} \quad (1)$$

式中: U_s 、 U_r 分别为定子、转子电压矩阵; R_s 、 R_r 分别为定子、转子电阻矩阵; I_s 、 I_r 为定子、转子电流矩阵; p 是微分因子; L_s 为定子总自感矩阵; L_r 为转子总自感矩阵; M_{sr} 为转子对定子绕组的互感矩阵; M_{rs} 为定子对转子绕组互感矩阵, $M_{sr} = M_{rs}^T$ 。




图2 异步交流电机模型

Fig. 2 Asynchronous AC motor model

将式(1)中电感矩阵整体记作 L ,电磁转矩 T_e 和转子运动方程为

$$\begin{cases} T_e = \frac{p_0}{2} [I_s \quad I_r] \frac{\partial L}{\partial \theta} \begin{bmatrix} I_s \\ I_r \end{bmatrix} \\ J_1 \frac{d\Omega_1}{dt} = T_e - T_L - R_w \Omega_1 \end{cases} \quad (2)$$

式中: p_0 为电机极对数; R_w 为摩擦系数; Ω_1 为角速度; J_1 为转子转动惯量; T_L 为负载扭矩。

皮带-齿轮箱作为表面传动装置会存在能量损失,曲柄输入机械功率 $P_c = \eta \times P_2$,其中 P_2 为电机输出机械功率, η 为传动效率,发电工况时作 η^{-1} 考虑。根据机械功率与扭矩、机械角速度间的数学关系可以得到

$$\begin{cases} T_c = \eta \times k \times T_L \\ \Omega_c = \frac{\Omega_1}{k} \end{cases} \quad (3)$$

式中: T_c 为曲柄驱动扭矩; Ω_c 为曲柄机械角速度; k 为皮带轮-齿轮箱传动比。

1.2 四连杆机构

有杆抽油系统的工作机制是一个包含诸多耦合变量的复杂过程,地面传动系统最主要的机械结构是四连杆机构,如图3所示。图中: R 为曲柄半径; L 为连杆长度; A 为前梁长度; B 为后梁长度; O 为游梁支撑重心; H 为支撑点到曲柄旋转中心的垂直高度; J 为支撑重心连接曲柄的辅助线; K 是基杆,为游梁支撑重心到曲柄旋转中心的长度; α 为曲柄与连杆之间的角度; β 为游梁后臂与连杆之间的角度; φ 为游梁后臂与基杆 K 之间的角度; γ 为基杆 K 与 H 之间的角度; θ_0 为曲柄按顺时针方向旋转的角度; θ 为基杆 K 与曲柄半径之间的角度。在曲柄轴和四连杆机构的作用下,将电机的旋转运动转变为抽油杆的上下往复运动,进而带动抽油泵进行抽油。




图3 四杆机构结构示意图

Fig. 3 The diagram of four-bar linkage architecture

根据其工作过程原理的分析与计算,建立基于曲柄转角的悬点位移机理模型,相关角度和参数定义如下。

$$\begin{cases} \theta = \theta_0 + \gamma \\ \gamma = \tan^{-1} \frac{I}{H} \\ K^2 = \sqrt{H^2 + I^2} \\ J = \sqrt{K^2 + R^2 - 2KR \cos \theta} \\ \cos^{-1} \beta = \frac{B^2 + L^2 - J^2}{2BL} \end{cases} \quad (4)$$

$$\begin{cases} \varphi_{\text{BOTTOM}} = \cos^{-1} \frac{B^2 + K^2 - (L+R)^2}{2BK} \\ \varphi_{\text{TOP}} = \cos^{-1} \frac{B^2 + K^2 - (L-R)^2}{2BK} \\ \alpha = 360^\circ - (\beta + \varphi + \theta) \\ S_C = A \cdot (\varphi_{\text{TOP}} - \varphi_{\text{BOTTOM}}) \\ S = \frac{\varphi_{\text{TOP}} - \varphi}{\varphi_{\text{TOP}} - \varphi_{\text{BOTTOM}}} \cdot S_C \end{cases} \quad (5)$$

式中: φ_{BOTTOM} 、 φ_{TOP} 是驴头位于上、下死点处游梁与基杆 K 之间的夹角; S_C 为有杆抽油系统冲程; S 为悬点位移。顺时针方向为正, 驴头位于下死点处开始采集电参数, 通过对四连杆机构建模, 将曲柄轴的旋转角度转化为悬点位移。

1.3 悬点载荷

悬点载荷在曲柄上形成的扭矩 M 计算公式如下。

$$M = T_C + M_i \quad (6)$$

式中: T_C 为曲柄轴净扭矩; M_i 为游梁式抽油机的平衡扭矩。扭矩因数为 \overline{TF} , 公式为

$$\overline{TF} = \frac{A}{B} \cdot R \cdot \frac{\sin \alpha}{\sin \beta} \quad (7)$$

不同平衡方式的游梁式抽油机对应不同的计算方法, 曲柄平衡的游梁式抽油机平衡扭矩 M_i 计算公式为

$$M_i = \overline{TF} \left(Q + \frac{C}{A} W_b \right) + (G_{cb} R_{cb} + G_b R_b) \sin \theta_0 \quad (8)$$

式中: G_{cb} 为抽油机平衡块总重量; R_{cb} 为抽油机平衡块重心到曲柄轴距离; C 是游梁平衡重心到游梁支点的距离; G_b 为曲柄轴总重量; R_b 为曲柄轴重心半径; W_b 为游梁平衡重; Q 是抽油机结构不平衡重。将式(8)代入式(6), 得到悬点载荷形成的扭矩 M 为

$$M = \overline{TF} \left(Q + \frac{C}{A} W_b \right) + (G_{cb} R_{cb} + G_b R_b) \sin \theta_0 + T_C \quad (9)$$

扭矩 M 、悬点载荷 W 与扭矩因数 \overline{TF} 之间的关系为

$$M = W \cdot \overline{TF} \quad (10)$$

整理上述公式得到 W 的表达式为

$$W = \frac{T_C}{\overline{TF}} + \frac{(G_{cb} R_{cb} + G_b R_b) \sin \theta_0}{\overline{TF}} + Q + \frac{C}{A} W_b \quad (11)$$

从式(5)得到悬点位移与曲柄转角的关系, 悬

点载荷通过式(11)计算。根据曲柄转角与位移和负载的机理关系, 通过变量替换可以得到粗糙的示功图数据样本。

2 基于 CGAN 的粗糙数据细化器

通过对电机到悬点载荷的机理分析所获得的粗糙示功图数据与现场实测数据误差较大, 不能直接用于工业现场。本文结合 CGAN 在图像转化领域的强大能力进行改进, 应用于细化机理生成的示功图数据。

GAN 由生成网络 G 和判别网络 D 组成^[11], 原始生成对抗网络所生成的图像为随机分布, 无法生成具有特定属性的图片, 但是 CGAN 可以解决该难题。其核心是在生成器和判别器中融入可以是任何标签的条件信息 y , CGAN 网络的目标函数为

$$\min_G \max_D V(D, G) = E_{x \sim p_{\text{data}}(x)} [\log D(x|y)] + E_{z \sim p_z(z)} [\log(1 - D(G(z|y)))] \quad (12)$$

式中: $V(D, G)$ 是整个目标函数的值, 其中 D 和 G 分别表示判别器和生成器; E 表示期望; x 是真实数据分布的数据样本; $p_{\text{data}}(x)$ 是真实数据分布; y 是条件信息; $p_z(z)$ 是生成器输入噪声 z 的先验分布; $D(x|y)$ 表示加入条件信息 y 后鉴别器对样本 x 的判断; $G(z|y)$ 表示生成器通过噪声 z 生成的假样本。

2.1 Pix2Pix 原理和结构

Pix2Pix 是用于图像转换任务的特定条件生成对抗网络^[12], 与 CGAN 算法的不同之处在于 Pix2Pix 对生成器和判别器分别进行了修改。判别器引入局部判别器 (PatchGAN) 进行图像判定, 输出一个矩阵实现对图像不同区域的判定, 更精准地提供有效信息判定生成结果。生成器采用 U 型网络 (U-Net) 结构, 在编码到解码的过程中进行跳跃连接, 帮助解码器直接从编码器学习特征参数从而获得更多信息。以随机失活 (dropout) 形式提供噪声, 在解码阶段以一定的概率随机将一些神经元输出设置为 0, 从而引入随机性, 增加输出结果的多样性, 同时也能够防止模型过拟合。图 4 是 Pix2Pix 网络根据标签图像生成真实图像的训练流程与生成器结构图。

Pix2Pix 算法的损失函数在 CGAN 损失函数 L_{CGAN} 的基础上加入 L_1 的损失函数 L_{L_1} , 其中 L_{CGAN} 的表达式如下。

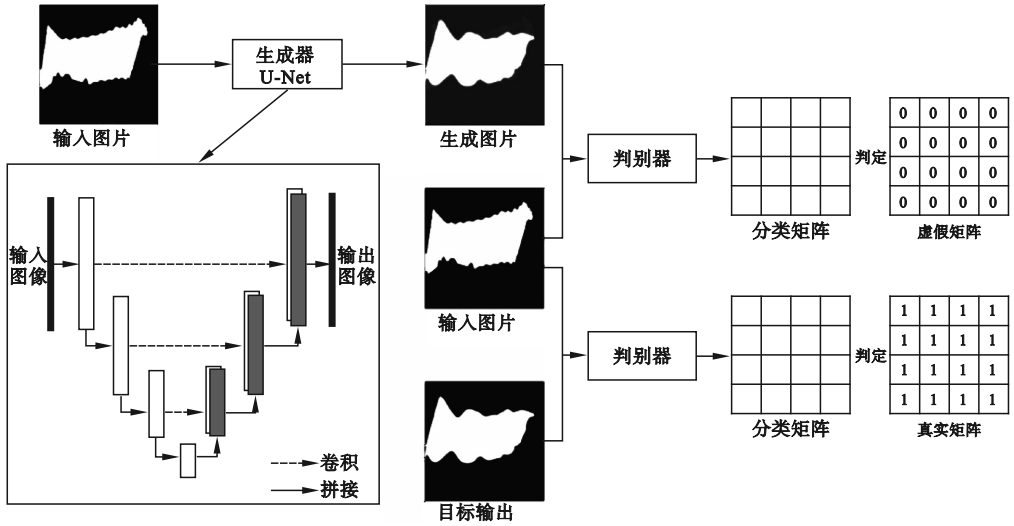


图4 Pix2Pix 训练流程与其生成器结构示意图

Fig.4 Pix2Pix training process and generator structure

$$L_{CGAN}(G, D) = E_{x, y \sim p_{data}(x, y)} [\log D(x|y)] + E_{x \sim p_{data}(x), z \sim p_z(z)} [\log(1 - D(x|G(x|z)))] \quad (13)$$

式中 y 是输入图像对应的目标图像; L_1 损失函数 l_{L_1} 的表达式为

$$l_{L_1}(G) = E_{x, y \sim p_{data}(x, y)} [\|y - G(x)\|_1] \quad (14)$$

式中 $\|\cdot\|_1$ 是 L_1 范数, $\|y - G(x)\|_1$ 表示生成图像 $G(x)$ 与目标图像 y 之间在所有像素上的绝对差值的和。Pix2Pix 算法的损失函数定义为

$$G = \min_G \max_D L_{CGAN}(G, D) + \lambda \cdot l_{L_1}(G) \quad (15)$$

式中 λ 为损失函数 l_{L_1} 的权重, 是一个超参数, 用于调整对抗性损失和 L_1 损失之间的权衡。

2.2 自注意力机制

将自注意力机制加入 Pix2Pix 网络中可以帮助生成器更好地理解输入图像的轮廓信息, 从而更好地捕捉图像轮廓, 提高生成图像的准确性。

本文将自注意力机制加入到生成器中的过程为: 经过编码器即多个卷积层后可以捕获输入图像更多的轮廓特征, 在 U-Net 生成器的上采样层中加入自注意力层将捕获到的特征拆分为 key、query、value 三个向量, 计算 query 和 key 之间的相似度得到权重向量, 最后将权重向量应用于 value 向量, 从而实现上下文信息之间的有效获取和利用。

$$Q(x) = W_q x \quad (16)$$

$$K(x) = W_k x \quad (17)$$

式中: $W_q \in \mathbf{R}^{\bar{C} \times C}$ 、 $W_k \in \mathbf{R}^{\bar{C} \times C}$, 为权值矩阵; $Q(x)$ 、 $K(x)$ 为图像特征 $x(x \in \mathbf{R}^{C \times N})$ 经过卷积层变换得到的两个不同空间特征; C 为通道数; N 为前一个

隐藏层的特征数量; \bar{C} 表示减少的通道数。

对 $Q(x)$ 、 $K(x)$ 进行矩阵变换得到注意力权重。为了满足注意力权重概率分布的要求, 对其进行归一化处理, 通过函数保证注意力权重之和为 1, 公式如下。

$$s_{i,j} = Q(x_i)^T K(x_j) \quad (18)$$

$$\beta_{j,i} = \frac{\exp(s_{i,j})}{\sum_{i=1}^N \exp(s_{i,j})} \quad (19)$$

式中: $s_{i,j}$ 是注意力权重, 即输入特征图中各个位置之间的相似性度量, j 表示区域, i 表示位置; $\beta_{j,i}$ 是经过归一化处理的注意力权重, 表示生成图像第 j 个区域时模型对第 i 个位置的相似度。注意力层的输出为

$$o = (o_1, o_2, \dots, o_j, \dots, o_N) \quad (20)$$

$$o_j = V\left(\sum_{i=1}^N \beta_{j,i} H(x_i)\right) \quad (21)$$

$$H(x_i) = W_h x_i \quad (22)$$

$$V(x_i) = W_v x_i \quad (23)$$

式中: o 表示注意力层的输出; x_i 是前一隐藏层的图像特征; H 与 V 是两个特征变换函数; $W_h \in \mathbf{R}^{\bar{C} \times C}$, 为权值矩阵。最终的输出结果为 $y_i = \tau \times o_i + x_i$, τ 是一个可学习的标量, 初始化为 0 来调整注意力层输出的权重。

2.3 Pix2Pix 网络结构设置

2.3.1 生成器结构

本方案设计的 U-Net 结构生成器包含 18 个数据处理单元, 其中下采样编码器部分由 8 个数据处理单元组成, 每个单元包括卷积层、批处理归一化层和 Leaky ReLU 激活函数。卷积层参数设

置均为:卷积核尺寸为 4×4 ,步长为 2,特征图边缘填充为 1,Leaky ReLU 参数设置为 0.2。解码器部分由 7 个数据处理单元组成,同下采样数据单元相同的设置,前两层解码器单元还包括 dropout 层,概率设置为 0.5。

2.3.2 判别器结构

判别器包含 5 个数据处理单元,每个处理单元包括卷积层(卷积核为 4×4)和批处理归一化层(除了第一层之外),激活函数为 Leaky ReLU,参数为 0.2,加强网络对负信息的响应。判别器的卷积层配置为:卷积核大小为 4×4 ,前三层步长为 2,最后两层为 1,特征图边缘填充为 1。

3 仿真结果及分析

依据公式(6)~(11),将电参数反演为示功图的结果如图 5 所示,曲线在位移最大和最小的位置存在不收敛区域,与实测示功图有显著差异。因为 \overline{TF} 的定义是一个近似正弦的曲线,其中包含接近于 0 的点。计算光杆上扭矩的公式中包含了 \overline{TF} 的倒数,因此在两个区域内产生了不收敛点。本文采用箱线图方法^[13]确定如何处理可疑和异常突变值,首先计算一个冲程周期内载荷值数据的四分位数(Q_1 、 Q_2 、 Q_3)以及四分位距(IQR);然后计算箱线图的上边界,上边界为 $Q_3 + 1.5 \times IQR$,下边界等于 $Q_1 - 1.5 \times IQR$;最后将载荷值数据 W_i 与上下边界进行比较。如果 W_i 大于上边界或小于下边界,那么将其排除;否则,保留该数据点,通过箱线图法对奇异突变值修正后的效果如图 5 所示。




图 5 机理模型生成示功图

Fig. 5 DC diagram of the mechanism model generation

3.1 数据集处理及训练过程

为了验证本文提出电参数反演示功图方法的有效性,以中国辽河油田沈阳采油厂中 10 口井的历史数据作为实验数据集。其中电参数测量仪安装在与电机相连的电控柜中,如图 6 所示,通过测

量仪中的数据采集模块实现对电参数的采集。模块中包括电压连接线、电流互感器、变压器隔离,既可以实现电压和电流数据的采集,还能保护操作人员安全,避免偶然触电带来的危险。




图 6 现场安装图示

Fig. 6 Field installation diagram

利用上述智能油井测控仪进行数据采集总计 1 800 组示功图和对应的电参数,包含 6 种工况。第一种工况为正常,其余分别为 5 种典型异常工况。首先将机理模型反演示功图和实测示功图组为 1 800 对基于 CGAN 数据细化器的数据集,选择 1 260 对作为训练集,其余 540 对示功图数据集作为测试集。

仿真实验的油井 CYJ-10-3-53 HB 抽油机尺寸如表 1 所示。对于出现故障工况的其中 6 口井分别编号为 1#到 6#,井下的生产参数如表 2 所示。

表 1 CYJ-10-3-53HB 抽油机尺寸

Table 1 Geometry of CYJ-10-3-53HB pumpjack

尺寸名称	参数
游梁前臂/mm	3 000
游梁后臂/mm	2 400
连杆/mm	3 350
支架轴中心高度/mm	5 290
减速箱中心高度/mm	2 020
减速箱中心至支架中心距离/mm	2 300
曲柄旋转半径/mm	1 150
平衡块重量/kN	1.4

为了让 Pix2Pix 网络可以高效地完成数据细化,需要在训练网络时对输入的数据集进行图像预处理。首先剔除示功图坐标值,保留原有图像窗口,便于最后将生成示功图图像恢复到原图尺寸并与实测和机理生成的示功图进行载荷、面积误差分析,其次将所有示功图图像的像素大小缩放为 256×256 ,最后对所有图像进行二值化、轮廓提取以及开运算处理,其过程如图 7 所示。

表 2 井下生产参数

Table 2 The productive parameters of down-hole

油井情况	含水率 /%	气液 体积比	抽油杆组合 及各部分长度/mm	泵径 /mm
1#正常	0.60	31.41	$\phi 25 \times 30$ 247 $\phi 22 \times 49$ 860 $\phi 25 \times 99$ 425	44
2#气体 影响	0.77	35.16	$\phi 25 \times 61$ 776 $\phi 22 \times 83$ 788 $\phi 25 \times 89$ 151	44
3#供液 不足	0.81	38.99	$\phi 25 \times 26$ 790 $\phi 22 \times 74$ 699 $\phi 25 \times 77$ 932	44
4#游动 伐漏失	0.64	44.31	$\phi 25 \times 50$ 682 $\phi 22 \times 75$ 841 $\phi 25 \times 80$ 729	44
5#气锁	0.81	29.41	$\phi 25 \times 33$ 922 $\phi 22 \times 54$ 160 $\phi 25 \times 84$ 318	44
6#杆断	0.75	35.44	$\phi 25 \times 40$ 199 $\phi 22 \times 74$ 794 $\phi 25 \times 68$ 941	44




图 7 示功图图形预处理

Fig. 7 DC graphics preprocessing

实验采用学习率为 0.000 2 的 Adam 优化器训练网络模型 ($\alpha = 0.5, \beta = 0.999$) 对 Pix2Pix 网络进行优化,生成器的输入通道为 1,判别器中局部判别器 (PatchGAN) 的大小设置为 30×30 ,损失函数 L_L 的权重 λ 设置为 100,批次大小 (batch size) 设置为 1。根据 Pix2Pix 训练过程中的结果表明,初始训练时随机生成的示功图图像与实测图像差异较大,随着训练时期的增加, Pix2Pix 生成的图像越来越接近实测示功图。图 8 显示了正常、供液不足和气锁三种工况分别迭代 1 次、50 次、100 次、150 次和 200 次的结果。

3.2 结果分析

为了客观评价粗糙数据细化器输出结果的精度,结合示功图在现场应用的指标要求,实验分别从示功图曲线的物理数值和 Pix2Pix 网络生成图像质量两个维度进行衡量。物理数值采用示功图面积误差、最大载荷误差以及最小载荷误差;生成图像的视觉质量采用结构相似性 (SSIM) 进行评价。SSIM 是一种衡量两幅图像相似度的指标,通过亮度、对比度和结构 3 个方面共同衡量图像的质量^[14]。




图 8 粗糙数据细化器训练过程

Fig. 8 Coarse data refiner training process

图 9 为 Pix2Pix 网络基于验证集所生成图像的 SSIM 分布图,横坐标为测试集数量标签,纵坐标为图像的 SSIM 值。由图 9 可见,在加入自注意力机制优化后的 Pix2Pix 网络所生成图像的 SSIM 值有显著提高。网络优化后生成图像的平均 SSIM 值大于 0.90,表明与真实图像相比具有很高的结构相似度和优秀的视觉质量。




图 9 模型输出图像 SSIM 值对比图

Fig. 9 Comparison of SSIM values of the model output image

对模型最终输出的二值化图像进行轮廓提取和像素尺寸还原处理,以便于对比示功图曲线的物理意义。机理建模生成示功图和粗糙数据经过细化器混合模型输出的结果如图10所示,两种方法得到的最大载荷、最小载荷和示功图面积的试

验误差如表3、表4所示。可以看出机理建模生成示功图与实测示功图的误差较大,本文提出混合模型生成的示功图与实测示功图在精度上面有显著提高。

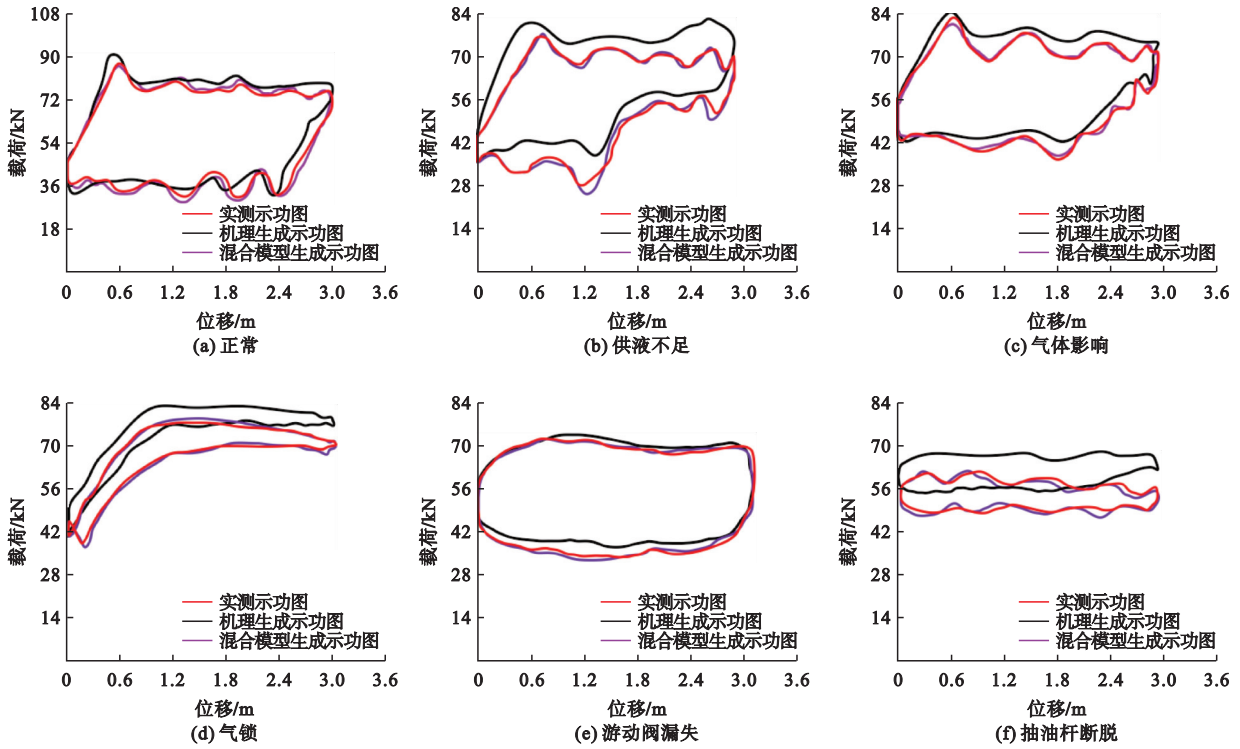


图10 示功图反演结果对比

Fig. 10 The difference between DCs

表3 机理生成与实测示功图误差分析表

Table 3 Mechanism generation and measured DC error analysis

工况	最大载荷 误差/%	最小载荷 误差/%	示功图面积 误差/%
正常	6.12	10.29	11.51
供液不足	9.16	29.81	17.57
气体影响	3.13	14.65	14.68
游动阀漏失	5.46	5.98	26.95
气锁	7.46	10.81	29.19
抽油杆断脱	10.49	10.04	27.16

3.3 理论意义

基于 SSIM 和悬点载荷误差、示功图面积误差对比分析,证明上述反演示功图的方法可以生成高质量的示功图,为基于示功图故障诊断领域提供了新的方法——通过连续的电参数对油井故

障进行预测和警示,将电参数同步生成对应的示功图,及时判断示功图的变化趋势,提高故障的风险预警。图11为油井出现供液不足和抽油杆断脱故障时由上述方法生成的示功图,可以明显地观察出示功图的动态变化过程。

表4 混合模型与实测示功图误差分析表

Table 4 Mixed model and measured DC error analysis

工况	最大载荷 误差/%	最小载荷 误差/%	示功图面积 误差/%
正常	1.27	4.42	1.42
供液不足	1.75	4.89	1.27
气体影响	2.40	3.84	2.13
游动阀漏失	1.47	4.09	5.16
气锁	1.56	4.36	5.79
抽油杆断脱	3.75	6.95	6.14

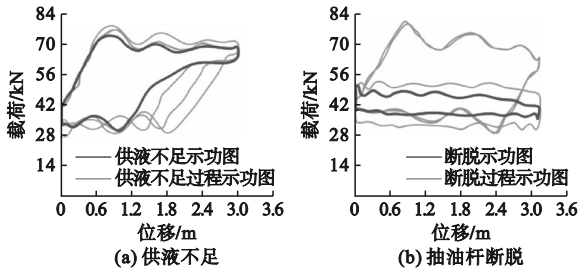


图 11 故障功图动态演变过程

Fig. 11 DCs failure process

4 结论

在实际的石油生产中,实时、精准地采集示功图对油井故障诊断有着重要的影响。鉴于油田现场示功图采集不便利、不及时,本文提出了一种基于CGAN混合模型的有杆抽油系统电参数反演示功图方法。首先以实测电参数为基础,建立间接测量光杆载荷和悬点位移的机理模型,生成粗糙的示功图数据,然后结合CGAN特定模型Pix2Pix强大的图像转换能力构建粗糙示功图细化器。在Pix2Pix模型中整合自注意力机制对示功图的轮廓信息进行动态加权融合,提高生成器生成图片的质量,实验仿真的对比结果表明本文所提混合模型方法相较于机理模型生成示功图的精度有显著提高,更加接近实测示功图。

参考文献 (References):

[1] 赵怀军,贺可可,胡定兴,等. 游梁式抽油机悬点载荷软测量方法的研究[J]. 仪器仪表学报,2021,42(9):160-171. ZHAO H J, HE K K, HU D X, et al. Research on the soft-sensing method of polished rod load of beam pumping unit [J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 160-171. (in Chinese)

[2] WEI J L, GAO X W. Electric-parameter-based inversion of dynamometer card using hybrid modeling for beam pumping system [J]. Mathematical Problems in Engineering, 2018, 2018:1-12.

[3] 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.

[4] 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.

[5] 柴梦婷,朱远平. 生成式对抗网络研究与应用进展[J]. 计算机工程, 2019, 45(9):222-234. CHAI M T, ZHU Y P. Research and application progress of generative adversarial networks [J]. Computer Engineering, 2019, 45(9):222-234. (in Chinese)

[6] GUO J Y, LEI B, DING C B, et al. Synthetic aperture radar image synthesis by using generative adversarial nets [J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(7):1111-1115.

[7] LI J, SKINNER K A, EUSTICE R M, et al. WaterGAN: unsupervised generative network to enable real-time color correction of monocular underwater images [J]. IEEE Robotics and Automation Letters, 2018, 3(1):387-394.

[8] 程平. 基于pix2pixHD的行人图像生成[J]. 数字通信世界, 2019(9):4, 16. CHENG P. Pedestrian image generation based on Pix2pixHD [J]. Digital Communication World, 2019(9):4, 16. (in Chinese)

[9] WANG J R, HAN B K, BAO H Q, et al. Data augment method for machine fault diagnosis using conditional generative adversarial networks [J]. Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering, 2020, 234(12):2719-2727.

[10] 于耀淋,张景异,睢付佳. 基于生成式对抗网络的人脸图像生成[J]. 沈阳理工大学学报, 2022, 41(5):29-33. YU Y L, ZHANG J Y, JU F J. Face image generation based on generative adversarial network [J]. Journal of Shenyang Ligong University, 2022, 41(5):29-33. (in Chinese)

[11] 汪美琴,袁伟伟,张继业. 生成对抗网络GAN的研究综述[J]. 计算机工程与设计, 2021, 42(12):3389-3395. WANG M Q, YUAN W W, ZHANG J Y. Overview of research on generative adversarial network GAN [J]. Computer Engineering and Design, 2021, 42(12):3389-3395. (in Chinese)

[12] XU X, ZHAO B B, TONG X H, et al. A data augmentation strategy combining a modified pix2pix model and the copy-paste operator for solid waste detection with remote sensing images [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 15:8484-8491.

[13] 武勇. 基于智能学习的抽油机井电参数反演示功图研究 [D]. 秦皇岛:燕山大学, 2022.

[14] YAO J C, SHEN J, YAO C Y. Image quality assessment based on the perceived structural similarity index of an image [J]. Mathematical Biosciences and Engineering, 2023, 20(5):9385-9409.

(责任编辑:和晓军)