

DOI: 10.19650/j.cnki.cjsi.J2614892

物理引导轻量化视觉网络及其在抽油机示功图识别中的应用

刘沛津¹, 孙 昱²

(1. 西安建筑科技大学机电工程学院 西安 710055; 2. 西安建筑科技大学理学院 西安 710055)

摘 要:游梁式抽油机示功图的人工解译效率低,难以定量刻画工况演化;传统数据驱动模型虽识别精度高,却存在物理可解释性弱与边缘部署困难的固有局限。针对上述挑战,故提出一种物理引导的轻量化时空视觉感知模型,实现低产油井供液能力的高效、可解释、可部署智能识别。首先,将悬点位移-载荷时序信号转换为规范化灰度图像,结合波动方程仿真与迭代智能标注,构建面向低产油井的专用示功图图像数据集 Low-YieldD。在此基础上,设计“时序预测-空间识别”级联架构:通过双流耦合 LSTM 网络建模示功图序列的动态演变趋势,实现对未来工况的精准预测;创新性地提出物理信息空间注意力(PISA)机制,将“液击延迟”机理编码为可微分高斯空间掩码,引导轻量化卷积神经网络聚焦于卸载区等关键图像区域,使视觉特征提取过程具备物理可解释性。实验结果表明,该模型参数量仅为标准 AlexNet 的 1.3%,在供液能力图像识别任务中准确率达 99.1%,物理合理性得分(0.93)显著优于 MobileNetV2 等主流轻量化网络。工业部署验证显示,系统响应延迟缩短 87.5%,月度无效抽油降低 59.7%,吨液耗电减少 22.0%,综合能效与运维效率均获显著提升。该研究为工业设备视觉检测提供了一种融合物理机理与轻量化深度学习的可行路径,兼具高精度、强可解释性与边缘部署适应性。

关键词: 抽油机;示功图图像识别;物理信息注意力;轻量化 CNN;边缘智能感知

中图分类号: TH17 **文献标识码:** A **国家标准学科分类代码:** 510.40

Physics-informed lightweight visual network and its application in dynamometer card recognition for beam pumping units

Liu Peijin¹, Sun Yu²

(1. School of Mechanical and Electrical Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China;
2. School of Science, Xi'an University of Architecture and Technology, Xi'an 710055, China)

Abstract: Manual interpretation of dynamometer cards for beam pumping units suffers from low efficiency and difficulty in quantitatively characterizing the evolution of operational conditions. Although traditional data-driven models have achieved high recognition accuracy, they inherently face challenges such as weak physical interpretability and difficulties in edge deployment. To address these issues, this paper proposes a physics-informed lightweight spatiotemporal visual perception model for efficient, interpretable, and deployable intelligent recognition of liquid supply capacity in low-yield oil wells. First, the time-series signals of suspension point displacement and load are converted into normalized grayscale images. Combined with wave equation simulation and iterative intelligent annotation, a dedicated dynamometer card image dataset, Low-YieldD, is constructed for low-yield oil wells. On this basis, a cascaded "temporal forecasting - spatial recognition" architecture is designed. A dual-stream coupled LSTM network models the dynamic evolution trends of dynamometer card sequences to achieve accurate prediction of future operating conditions. Innovatively, a physics-informed spatial attention (PISA) mechanism is proposed. This mechanism encodes the "fluid pound delay" mechanism into a differentiable Gaussian spatial mask, guiding the lightweight convolutional neural network to focus on critical regions such as the unloading zone, thereby endowing the visual feature extraction process with explicit physical interpretability. Experimental results show that the proposed model has only about 1.3% of the parameters of standard AlexNet, yet achieves 99.1% accuracy in liquid supply capacity image recognition, with a physical plausibility score of 0.93, significantly outperforming mainstream lightweight networks such as MobileNetV2. Industrial

deployment validation demonstrates that system response delay is reduced by 87.5%, monthly ineffective pumping is decreased by 59.7%, and electricity consumption per ton of liquid is lowered by 22.0%, achieving substantial improvements in both energy efficiency and operational maintenance efficiency. This study provides a feasible pathway for industrial equipment visual inspection that integrates physical mechanisms with lightweight deep learning, offering high accuracy, strong interpretability, and edge deployment adaptability.

Keywords: beam pumping unit; dynamometer card image recognition; physics-informed attention; lightweight CNN; edge intelligent perception

0 引言

石油是国民经济发展与国家能源安全的重要战略资源。低产油井的智能高效开发,对提升油田采收率、降低开采成本具有显著的工程与经济价值^[1-2]。作为典型的机电液耦合举升设备,抽油机运行状态的实时精准感知与智能调控能力,是影响系统泵效、能耗及生产稳定性的核心,也是油田智能化建设的关键环节^[3-5]。其中,对反映地层供液能力的准确识别,是实现抽汲参数动态优化与闭环自适应控制的前提^[6]。

传统方法主要依靠人工解译地面示功图(悬点载荷-位移曲线),通过其几何形态定性评估工况^[7-8]。该方法依赖专家经验,效率低、一致性差,且难以定量刻画工况缓慢演变的动态过程,无法满足实时调控与预测性维护的工业需求。随着机器学习的发展,支持向量机^[9]、随机森林^[10]等被用于示功图分类,基于波动方程的软测量技术也为动态分析提供了思路^[11]。然而,这些方法多侧重于静态或单点工况的判别,缺乏对状态时序演化的连续建模能力,本质上仍属于“离线分析”,难以支撑在线监测与动态调控。近年来,深度学习技术以其强大的端到端特征学习能力,为复杂工业系统的智能感知带来了变革。卷积神经网络(convolutional neural network, CNN)在轴承故障诊断^[12]、刀具磨损预测^[13]等典型健康监测任务中表现出优越性能,证明了其从传感器数据(如图像、信号)中自动挖掘故障敏感特征的潜力^[14]。为进一步捕捉系统状态随时间的动态演变规律,研究者融合CNN与长短期记忆网络(long short-term memory network, LSTM)等时序模型,构建混合架构进行时空特征联合建模,在旋转机械的故障预测与运行状态细粒度分类中取得了良好效果^[15-18]。

随着计算机视觉与深度学习的深度融合,将一维时间序列信号转换为二维图像,并利用卷积神经网络进行视觉特征提取与模式识别,已成为工业设备状态监测的前沿方向。此类方法不仅保留了时序动态信息,更将复杂系统行为映射为具有空间结构的视觉表征,为引入强表达能力的视觉模型奠定了基础。在轴承故障诊断、刀具磨损预测等典型工业监测任务中,基于信号图像化的CNN方法已展现出优越性能。进一步地,融合CNN与长

短期记忆网络的混合架构,能同时捕捉时空特征,在旋转机械故障预测与状态分类中表现突出^[19-20]。

然而,将上述方法应用于低产油井抽油机的实时工况感知时,仍面临3方面挑战:1)时序建模深度不足,难以有效捕捉供液能力恶化等缓慢退化趋势^[21];2)物理机理融合缺失,主流数据驱动模型未将抽油杆柱振动、泵阀启闭、“液击延迟”等动力学机理以可解释形式嵌入学习过程,导致特征物理意义不明确,工况剧烈变化时泛化能力下降^[22-23];3)工程部署可行性低,常规深度网络计算复杂度高,难以适应油田边缘侧在算力、内存与功耗上的严苛约束^[24]。深入剖析上述挑战,其根源在于感知表征系统动态机理分析、数据驱动智能建模与工业现场部署约束三者之间尚未形成深度协同。现有研究或偏重于数据驱动的端到端的性能优化,提升了精度却牺牲了模型的可解释性与物理一致性,在工况剧烈变化时泛化能力存疑;或固于复杂机理模型的离线仿真,难以满足实时在线感知与闭环调控的敏捷性需求。因此,如何将系统物理先验知识有机地注入强大的深度学习框架中,并在此融合基础上设计出满足边缘侧资源约束的轻量化模型,是推动系统迈向自主智能必须攻克的前沿课题。

通用轻量化技术(如网络剪枝、知识蒸馏、MobileNet等)在视觉任务中成效显著^[25-28],但其设计未充分考虑特定系统的物理约束与工况特性。直接移植时,模型难以聚焦与故障机理最相关的关键区域,为维持精度需回退至更大规模,导致压缩效率与任务适应性失衡^[29]。因此,深度融合领域物理先验,构建兼具高精度、强可解释性与低计算开销的轻量化智能感知框架,已成为复杂机电系统实现实时智能感知的技术瓶颈。

为应对上述挑战,本研究提出一种物理引导的轻量化时空视觉感知模型,核心思路是:将示功图时序信号图像化,构建“时序预测-视觉识别”级联架构,并设计物理信息空间注意力机制,引导视觉网络聚焦于图像中的物理敏感区域。本文主要贡献包括:

1)提出一种面向示功图序列的轻量化时空视觉架构,采用双流耦合LSTM模块建模示功图序列的动态演变趋势,结合轻量化CNN实现图像形态识别。

2)创新性地设计物理信息空间注意力(physics-informed spatial attention, PISA)。将描述抽油杆柱纵向振动的波动方程所蕴含的“液击延迟”物理机理,转化为

可微分的高斯空间掩码,引导网络聚焦于卸载区的物理敏感区域,在实现模型轻量化的同时,赋予决策过程明确的物理可解释性。

3)通过迭代智能标注策略构建专用图像数据集 Low-YieldD,并完成工业部署验证,系统在识别精度、响应速度与节能效果上均显著优于传统方法。

1 示功图感知机理与数据集构建

1.1 抽油机系统动力学与示功图映射机理

游梁式抽油机系统是一个典型的机电液耦合动力学系统,其结构示意图如图1所示。其功能是将地面电动机的旋转运动转化为井下柱塞的往复举升运动,从而实现地层流体的抽取。系统工作状态可通过地面采集的悬点载荷-位移曲线(即地面示功图)进行间接表征。然而,地面示功图并非井下泵功图的直接再现,而是泵端载荷信号经过千米级抽油杆柱这一分布式弹性系统传递、滤波与变形后的结果。因此,建立抽油杆柱纵向振动动力学模型,是理解示功图形态成因、特别是供液能力相关特征形成机理的理论基石。




图1 游梁式抽油机结构

Fig. 1 Diagram of the beam pumping unit structure

为构建可用于智能感知的机理模型,在保留系统核心物理本质的前提下,作如下合理简化假设:抽油杆柱视为均质等截面弹性杆;杆柱与油管间的摩擦及流体粘滞阻力等效为线性粘性阻尼;仅考虑沿杆柱纵向的一维振动;地面光杆位移由抽油机几何运动学规律确定;泵端载荷由泵阀启闭特性及泵腔流体压力决定。基于牛顿第二定律与胡克定律,可推导出抽油杆柱纵向振动的一维阻

尼波动控制方程,即:

$$\frac{\partial^2 u(x,t)}{\partial t^2} = a^2 \frac{\partial^2 u(x,t)}{\partial x^2} - c \frac{\partial u(x,t)}{\partial t} \quad (1)$$

式中: $\alpha = \sqrt{E/\rho}$ 为杆柱中应力波传播速度; c 为等效粘性阻尼系数; $u(x,t)$ 为深度 x (向下为正)处截面在时刻 t 的位移。地面边界($x=0$),深度由光杆位移函数 $S_p(t)$ 描述,即:

$$u(0,t) = S_p(t) \quad (2)$$

泵端边界($x=L$),杆柱载荷 $F_{\text{pump}}(t)$ 与泵内流体压力及柱塞运动状态相关,即:

$$EA \frac{\partial u(L,t)}{\partial x} = F_{\text{pump}}(t) = f\left(u(L,t), \frac{\partial u(L,t)}{\partial t}, p_{\text{fluid}}(t)\right) \quad (3)$$

式中:函数 $f(\cdot)$ 表征泵的工作状态; E 为杆柱弹性模量; A 为截面积。供液不足时,柱塞在下冲程初期无法立即接触液面,会产生“液击延迟”现象,此过程显著改变 $F_{\text{pump}}(t)$ 的载荷释放特性,是形成地面示功图中特征性“刀把”形态的根本物理来源。

假设系统从静止启动,则:

$$\begin{cases} u(x,0) = 0 \\ \frac{\partial u(x,0)}{\partial t} = 0 \end{cases} \quad (4)$$

地面光杆载荷 $F_{\text{surface}}(t)$ 可通过杆柱顶部应变关系与泵端载荷关联,即:

$$F_{\text{surface}}(t) = EA \frac{\partial u(0,t)}{\partial x} \quad (5)$$

结合已知光杆位移 $S_p(t)$,地面示功图 $[S_p(t), F_{\text{surface}}(t)]$ 实质上是泵端边界条件 $F_{\text{pump}}(t)$ 经杆柱系统(式(1))动态滤波后的响应输出。低供液能力通过改变泵端函数 $f(\cdot)$ 在下冲程初期的动力学行为,最终在地面示功图上表现为卸载线延长、右下角“刀把”形态凸显等稳定、可量化的形态学特征。该区域直接对应泵端“液击延迟”这一关键动力学过程的响应,是评估系统供液能力的最敏感区域。

1.2 示功图形态特征与供液能力的动力学关联分析

一个完整的示功图对应抽油机的一个工作周期,主要包括如图1示功图中的上冲程(光杆上行,对应曲线 ABC 段)和下冲程(光杆下行,对应曲线 CDA 段)。在供液充足的正常工况下(理想闭合图形 $ABCD A$),上、下冲程的载荷变化曲线基本对称,卸载迅速且充分,图形饱满。然而,在供液不足的低产工况下,示功图形态发生系统性畸变(如图1示功图中 $ABCD'A$ 所示),主要表现为以下两类关键特征:

1)下冲程载荷延迟释放:上冲程行为与理论预期基本吻合。但在下冲程初期,由于泵腔未能及时充满液体,

柱塞存在“空程”下落,导致光杆载荷不能立即下降,直至柱塞接触液面。这使得载荷-位移曲线在右下象限出现一段近似水平的“平台”,即卸载线。

2)“刀把”形态特征:“刀把”特指图 1 中示功图卸载线 CD' 段。其长度直接、反比于油井的即时供液能力。供液越差,液面越低,柱塞空程越长,“刀把”特征越显著(CD' 段越长);反之,供液改善则“刀把”缩短。

因此,通过持续监测示功图形状,特别是定量化追踪“刀把”长度、卸载线斜率及图形面积的演变趋势,即可实现对油井供液能力的实时、动态评估。这为后续基于深度学习的智能感知模型提供了明确的、具有物理意义的特征学习目标。

1.3 示功图图像化表征与数据集构建

1) 信号到图像的转换

为了应用以 CNN 为核心的视觉识别模型,本文将其一维信号序列转化为二维数字图像。具体转换流程如下:对于每一个工作周期采集到的 200 对位移-载荷数据点序列 将其视为一系列二维坐标,采用抗锯齿绘图技术,在一个预设的 200×100 pixels 的空白画布(灰度模式)上,将这些坐标点依次连接,绘制出闭合的示功图曲线。线宽设置为 1.5 pixels,以在保留曲线细节的同时确保视觉连续性。最终生成的是一张二进制灰度图像,生成的图像中曲线部分像素值为 1,背景部分像素值为 0。

2) 图像预处理

原始一维时序数据存在传感器噪声、井筒摩擦波动等干扰,且不同油井因设备与工况差异导致数据分布不一致。为此,设计的标准化预处理流程为:

(1) 值域归一化与灰度拉伸

首先,将像素值从原始的 0~255 或二值范围线性归一化至 0~1,消除不同采集设备间可能存在的亮度与对比度偏差,加速模型训练的收敛过程。

(2) 形态学清洗与去噪

应用形态学开运算滤除图像中孤立的噪声点和小尺度的非连通区域。提取示功图曲线的最大连通分量,确保分析目标为主体图形,消除可能的边缘毛刺或干扰标记。进行背景净化。

(3) 几何校正(倾斜校正)

由于安装或数据采集时的微小偏差,示功图图像可能发生整体倾斜。本文基于最小二乘法拟合卸载线(CD' 段,见图 1),计算其与图像水平轴的夹角 θ 。若 $|\theta|>1^\circ$,则对整幅图像进行反向旋转校正,确保所有样本在空间朝向上保持一致,减少 CNN 学习不必要的旋转不变性负担。

3) Low-YieldD 示功图数据集构建

基于上述图像化与预处理流程,本文构建了面向低

产油井供液能力评估的专用视觉检测数据集 Low-YieldD。数据来源于长庆油田某区块 20 口典型低产油井的长期监测数据,并结合前述的动力学模型进行了仿真扩充,以覆盖更广泛的工况参数。数据集的核心特点是其标签体系完全基于图像的视觉形态定义。基于领域专家经验,根据每个预处理后示功图图像中“刀把”的像素长度占整个图形轮廓长度的比例,将其供液能力精细划分为 10 个等级(0%~100%,间隔 10%),如图 2 所示。等级越高,代表图像形态越饱满,“刀把”特征越不明显,供液越充足。




图 2 供液能力样本分布等级

Fig. 2 Liquid supply capacity sample distribution levels

为确保仿真数据的有效性,本文在波动方程数值仿真中,依据长庆油田目标井的历史统计数据及 API Spec 11B 标准(<https://www.doc88.com/p-9085228107229.html>) 设定了关键参数的物理范围,详见表 1。仿真参数空间的构建覆盖了实测数据的分布区间,并通过拉丁超立方采样合理外推以覆盖边缘工况(供液能力 10%~30%)。

表 1 波动方程数值仿真关键参数设置
Table 1 Key parameter settings for numerical simulation of the wave equation

参数	名称	取值范围	依据来源
几何参数	泵挂深度	800~2 500 m	目标井资料(实测范围 950~2 100 m,均值 1 450 m,标准差 320 m)
	杆柱组合	一级、二级组合	API Spec 11B
物性参数	原油粘度	5~200 mPa·s	目标井原油物性分析(实测范围 8~150 mPa·s)
	混合液密度	850~1 000 kg/m ³	目标井产出液分析
阻尼参数	等效粘性	0.5~5.0 s ⁻¹	现场标定
	阻尼系数		
工况参数	供液能力	10%~100%	仿真目标
	冲次	2~8 min ⁻¹	目标井生产参数(实测范围 3~6 min ⁻¹)

为定量验证仿真数据与实测数据在形态学上的一致性,从测试集中随机抽取 500 张实测图和 500 张仿真图,

提取对供液能力最敏感的“归一化卸载线长度”作为核心特征,并增加“图形面积”作为辅助局部特征。统计分析表明卸载线长度指标的双样本 Kolmogorov-Smirnov 检验显示 $p=0.23$ (>0.05),且效应量 $Cohen's d=0.065$ (基于合并标准差计算),远小于 0.2 的小效应阈值,证明两组数据在该特征上分布高度趋同。辅助特征(图形面积)的两组数据均值分别为 432.5 和 441.8,相对误差 2.2%,证明仿真在整体能量特征上与实测一致。实测与仿真样本在“归一化卸载线长度”上的箱线图对比图如图 3 所示,两者中位数与四分位距高度重合,直观印证了统计结论。




图3 实测与仿真示功图归一化卸载线长度

Fig.3 Boxplot of normalized unloading line length for measured and simulated dynamometer cards

如图 4 所示,为卸载线长度的 $Q-Q$ 图,散点紧密围绕 $y=x$ 直线,进一步证实了分布一致性。




图4 实测与仿真数据归一化卸载线长度 $Q-Q$ 图

Fig.4 $Q-Q$ plot of normalized unloading line length comparing measured and simulated data

为高效完成大规模数据标注,本文采用迭代式智能标注策略构建专用数据集。首先由领域专家手动标注约 10% 的样本构成高质量初始子集 D_{seed} ,并基于此训练初步 CNN 模型 M_{init} 。在验证集上评估模型准确率 A_{val} 后,若未达到预设阈值,则采用不确定性或代表性采样策略选取新样本由专家补充标注并扩充 D_{seed} ,重复训练与验证过程直至模型性能达标。随后,利用通过验证的最终模型 M_{final} 对剩余未标注数据进行批量预测,生成带有初

步标签的伪标签数据集 D_{pseudo} 。最后,领域专家对伪标签数据进行抽样审查与必要校正,形成最终的高质量数据集 Low-YieldD。Low-YieldD 数据集包含总计 15 000 张已标注的示功图灰度图像,并按 8:1:1 的比例划分为训练集、验证集和测试集。

2 物理引导轻量化时空感知模型构建

2.1 模型总体架构

本模型旨在构建一个端到端的视觉感知系统,其输入为经预处理后的示功图灰度图像序列,输出为对当前及未来短期供液能力等级的精确识别。

如图 5 所示,模型采用“时序预测-视觉识别”的级联架构,紧密围绕抽油机周期性工作的物理本质与示功图的时空双重特性进行设计。该架构首先通过时序感知模块捕捉图像序列的动态演变趋势,进而由视觉识别模块对关键帧图像进行细粒度分类,实现了从动态趋势感知到静态状态判别的完整视觉分析流程。




图5 “时序预测-空间识别”网络总体架构

Fig.5 The architecture of the “temporal forecasting-spatial recognition” network

2.2 时序感知模块

1) 位移-载荷协同预处理

原始示功图的时间序列包含位移 $x(t)$ 与载荷 $F(t)$ 两个物理维度。为消除量纲差异并凸显各自特性,进行分流通路预处理。

位移时间序列数据使用三次样条插值处理,在最大位移点处将曲线分割为上冲程和下冲程段,对载荷数据应用最小-最大缩放以消除维度影响。插值函数满足边界连续性约束,即:

$$S_i(x) = a_i + b_i(x - x_i) + c_i(x - x_i)^2 + d_i(x - x_i)^3 \quad (6)$$

$$\begin{cases} \text{位移标准化: } x_{st} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \text{ (消除冲程波动)} \\ \text{载荷归一化: } F_{\text{norm}} = \frac{F - F_{\min}}{F_{\max} - F_{\min}} \text{ (固定量纲基准)} \end{cases} \quad (7)$$

其中, $F_{\min}$ 和 $F_{\max}$ 由第1张示功图获得, 以保持序列间相对关系的稳定性。

2) LSTM 用于时间建模的适应性

LSTM 是一种循环神经网络 (recurrent neural network, RNN) 架构, 够处理长期依赖关系并减少梯度消失问题的可能性^[30]。如图6所示, 在给定时间 t , x_t 和 h_{t-1} 分别表示当前输入和先前输出。




图6 LSTM 架构

Fig. 6 LSTM architecture

前后时间步的状态信息分别由 c_{t-1} 和 c_t 表示。Sigmoid 函数表示为 σ ^[31]。

控制方程为:

$$\begin{cases} f_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t = \tanh(W_c \times [h_{t-1}, x_t] + b_c) \\ C_t = f_t \otimes C_{t-1} + i_t \otimes \tilde{C}_t \\ o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\ h_t = o_t \otimes \tanh(C_t) \end{cases} \quad (8)$$

其中, W_i , W_f , W_c 和 W_o 是权重矩阵; b_f , b_i , b_c 和 b_o 是偏置向量; h_{t-1} 和 C_{t-1} 是先前隐藏状态和细胞状态; C_t 和 h_t 是更新后的状态。LSTM 建模长期依赖关系的能力使其能够有效捕捉提供液能力的逐渐变化。

3) 双流耦合 LSTM 结构与预测机制

双流耦合 LSTM 网络结构如图7所示, 两个独立的 LSTM 子网络分别处理预处理后的位移序列和载荷序列, 以捕获各自的时间动态模式。在最终时间步, 从两个 LSTM 流中提取的隐藏状态向量被拼接, 形成一个融合了几何与动力学信息的统一上下文表征。

全连接解码器的第1层使用128个单元和ReLU激活函数进行非线性变换, 第2个线性输出层配置为直接预测整个未来的载荷值序列。对于输出长度 $l=5$, 该层拥有5个单元, 其输出被重塑为目标序列。这种“多步直接回归”范式, 避免了迭代预测的误差累积, 区别于循环图像到图像模型, 为长期示功图预测提供了比更高效、更稳定的方法^[20, 32]。




图7 双流耦合 LSTM 预测框架

Fig. 7 Dual-stream coupled LSTM prediction framework

该模型被训练用于将 $k=10$ 个时间步的历史序列映射到 $l=5$ 步的未来序列, 通过最小化预测值与真实值之间的均方误差 (mean squared error, MSE)。训练采用 Adam 优化器 ($\beta_1=0.9$, $\beta_2=0.999$), 学习率为 0.001, 批大小为 32, 并进行 100 轮次训练以确保收敛。

4) 预测性能与参数优化

多步预测的质量使用归一化预测效能度量 Q 进行量化, 定义如式(9)所示。

$$Q = \frac{1}{l \times N_p} \sum_{j=1}^l \sum_{p=1}^{N_p} (\hat{y}_p^{(j)} - y_p^{(j)})^2 \quad (9)$$

其中, $\hat{y}_p^{(j)}$ 和 $y_p^{(j)}$ 分别是第 j 个预测步中第 p 个数据点的预测值和真实值, N_p 是数据点总数。较低的 Q 值表示更优的预测精度。

本文对双流耦合模型进行了严格的敏感性分析, 以评估模型性能对输入序列长度 k 和输出序列长度 l 的依赖性, 目标是找到一个在预测精度和计算效率之间取得

平衡的配置。

在 $k \in [1, 15], l \in [1, 10]$ 定义的参数空间上进行了网格搜索, Q 的可视化结果如图 8 所示, 揭示了低误差平台区 ($k \geq 6$ 且 $l \leq 6$) 时, 模型达到鲁棒且稳定的性能, Q 值持续保持在 0.06~0.07 范围内。




图 8 Q 随输入长度 k 和输出长度 l 变化的 3D 曲面图

Fig. 8 3D surface plot of Q versus input length k and output length l

图 9 所示的 2D 切片视图表明, 在输入长度足够 ($k=6$) 时, 预测误差 Q 随输出长度 l 单调增加, 这归因于多步预测中固有的不确定性累积。相反, 在固定输出长度 ($l=5$) 时, 误差随着 k 从 1 增加到 4 而急剧下降, 并在 $k \geq 6$ 时趋于稳定。




图 9 预测误差的二维切片视图

Fig. 9 2D slice view of prediction error

基于上述分析, 配置 $(k, l) = (6, 5)$ 为操作最优值。这一选择在预测精度和模型复杂度之间取得了最佳平衡, 使其非常适合实时工业部署。

2.3 基于轻量化 CNN 与 PISA 的图像识别模块

1) 面向示功图图像分类的轻量化 CNN 结构设计

AlexNet 作为一种开创性的深度卷积神经网络 (deep convolutional neural network, DCNN), 在自动特征学习和复杂模式识别方面具有强大能力^[33-35]。然而, 将其直接用于示功图分析面临三重挑战:

(1) 输入维度不匹配: 原生 AlexNet 要求 224×224 pixels (3 channels) 的输入^[36], 与示功图灰度图像

200×100 pixels (1 channel) 不兼容;

(2) 计算效率低: 模型参数量超过 6 000 万, 计算开销大, 在小规模工业数据集上易过拟合;

(3) 缺乏物理引导: 网络未嵌入领域知识 (如“刀把”形态的物理意义), 限制了其可解释性与工况泛化能力。

为此, 本文对 AlexNet 进行了面向任务的重设计。核心改进包括: 调整输入层以适配 $200 \text{ pixels} \times 100 \text{ pixels}$ 灰度图像; 缩减各层卷积核数量与尺寸; 将全连接层替换为更小的隐藏层 (512 神经元) 并移除冗余层; 最重要的是, 在第 2 个卷积层后嵌入 PISA 模块。与通用注意力机制或后验解释方法不同, PISA 通过编码物理先验, 显式引导网络聚焦于诊断关键区域。改进后模型参数量降至原 AlexNet 的约 1.3%, 结构如图 10 所示, 关键改动汇总于表 2。




图 10 网络架构

Fig. 10 Network architecture diagram

2) 物理信息空间注意力机制

(1) 物理先验的统计化表征与可微分嵌入

基于波动方程 (式 (1)) 边值问题, 对涵盖典型低产工况 (供液能力 10%~50%) 的参数空间进行批量数值仿真, 生成一系列仅由物理机理驱动的“纯净”示功图。对仿真生成的示功图, 采用形态学算法自动精确提取卸载线, 并定位其端点坐标集合 $\{(x_i, y_i)\}_{i=1}^{N_s}$, 其中 N_s 为仿真样本数。假设该坐标集服从二维高斯分布, 其均值向量 $\mu_{ROI} = (x_0, y_0)$ 表征了“液击延迟”这一物理现象在图像空间中最具代表性的视觉响应中心, 协方差矩阵 Σ_{ROI} 则反映了因工况参数微小扰动导致的位置波动。参数计算如式 (10) 所示。

表 2 AlexNet 架构轻量化改进

Table 2 Lightweight modification of AlexNet architecture

网络组件	标准 AlexNet 参数 ^[36]	改进 AlexNet 参数	改进目标
输入	224×224×3 (RGB)	200×100×1 (灰度)	适配示功图原生维度
Conv1	96 filters, 11×11, stride 4	64 filters, 7×7, stride 2	减少参数, 计算更高分辨率的初始特征图以获取更精细节。
Conv2	256 filters, 5×5, pad 2	128 filters, 3×3, pad 1	更小的卷积核和减少的通道数进一步压缩模型。
物理注意力	—	空间注意力模块	引导网络关注特征图中物理显著性区域。
Conv3	384 filters, 3×3, pad 1	192 filters, 3×3, pad 1	保持网络学习复杂特征组合的能力。
Conv4	384 filters, 3×3, pad 1	192 filters, 3×3, pad 1	平衡各层间的计算负载。
Conv5	256 filters, 3×3, pad 1	128 filters, 3×3, pad 1	为后续的全连接层准备特征。
FC6	4 096 neurons	512 neurons	大幅缩减。替换了原本过大的全连接层。
FC7	4 096 neurons	— (移除)	移除。进一步简化架构并减少计算。
FC8 (输出)	1 000 neurons	10 neurons	最终输出层根据诊断类别数量设定大小。
参数量	62.4 百万	0.79 百万	参数量减少约 98.7%, 极大提高了计算效率和部署能力。

$$\boldsymbol{\mu}_{\text{ROI}} = \frac{1}{N_s} \sum_{i=1}^{N_s} \begin{bmatrix} \mathbf{x}_i \\ \mathbf{y}_i \end{bmatrix} \quad (10)$$

$$\boldsymbol{\Sigma}_{\text{ROI}} = \frac{1}{N_s - 1} \sum_{i=1}^{N_s} \left(\begin{bmatrix} \mathbf{x}_i \\ \mathbf{y}_i \end{bmatrix} - \boldsymbol{\mu}_{\text{ROI}} \right) \left(\begin{bmatrix} \mathbf{x}_i \\ \mathbf{y}_i \end{bmatrix} - \boldsymbol{\mu}_{\text{ROI}} \right)^T \quad (11)$$

为简化并与后续网络兼容, 将协方差矩阵简化为各向同性, 取 $\sigma^2 = \frac{1}{2} \text{tr}(\boldsymbol{\Sigma}_{\text{ROI}})$, 其中 $\text{tr}(\cdot)$ 为矩阵的迹。由此, 定义物理引导的注意力掩码 M 为可微分的 $M \in \mathbb{R}^{H \times W}$ 二维高斯核函数, 即:

$$M(x, y) = \exp \left(- \frac{(x - x_0)^2 + (y - y_0)^2}{2\sigma^2 + \varepsilon} \right) \quad (12)$$

其中, ε 为小常数 (取 1×10^{-6}), 确保数值稳定性。 M 在以 (x_0, y_0) 为中心的物理关键区域内值接近 1, 向外则平滑衰减至 0。该掩码本质上是“卸载区最为重要”这一领域知识, 编码为一个可计算、可优化的概率化空间权重模板。

为验证将卸载区位置建模为二维高斯分布的合理性, 本文对 Low-YieldD 数据集所有实测样本的卸载区中心坐标进行统计分析。采用等频率分箱法将二维平面划分为 5×5 网格, 确保每箱样本数大致相等。依据 Cochran 准则合并低频网格后, 有效自由度为 5。皮尔逊卡方拟合优度检验结果显示, $\chi^2 = 6.54, p = 0.26 (> 0.05)$, 表明在 95% 置信水平下无法拒绝“数据服从所估计二维高斯分布”的原假设。如图 11 所示, 展示了实测卸载区中心点的散点分布及其拟合二维高斯分布的等高线叠加图, 可见数据点紧密围绕均值中心, 无明显多峰迹象。

图 12 所示, 为样本马氏距离与理论 χ^2 分布分位数的 $Q-Q$ 图, 散点沿 $y=x$ 直线分布, 直观证实了高斯拟合的有效性。




图 11 实测卸载区中心点分布及其二维高斯拟合等高线

Fig. 11 Scatter distribution of measured unloading zone centers and fitted 2D Gaussian contours




图 12 样本马氏距离与 χ^2 分布分位数的 $Q-Q$ 图

Fig. 12 $Q-Q$ plot of Mahalanobis distance versus χ^2 distribution quantiles

本文聚焦的 20 口低产油井具有高度相似的工程背景 (泵挂深度、杆柱组合、供液不足主导工况), 由“液击延迟”主导的卸载区位置在图像空间中呈现稳定的单峰聚集。井下复杂因素的扰动在不同井间表现为围绕共同中心的随机波动, 而非产生新的聚集中心。因此, 单峰高

斯分布是对本研究所面向的特定井群卸载区位置的有效且高效建模。

(2) 注意力调制与特征增强

如表 3 所示,PISA 模块嵌入于轻量化 CNN 的第 2 个卷积层之后,以前馈方式对特征图进行物理引导的重新校准。

表 3 不同预测模型的平均性能对比

Table 3 Average performance comparison of different prediction models				
指标	MSE	预测效能 Q	推理速度/ms	时间一致性
双流 LSTM	0.083 2	0.06	8.2	0.94
标准 LSTM	0.158 6	0.08	11.5	0.87
RNN	0.195 4	0.37	6.8	0.72
BPNN	0.201 2	1.25	4.3	0.65

给定输入特征图 $F \in \mathbb{R}^{H \times W \times C}$, 注意力生成过程:
首先,通过 1×1 卷积将通道维压缩并映射至注意力空间:

$$\mathbf{Z} = \text{ReLU}(\mathbf{W}_a * \mathbf{F}) \tag{13}$$

其中, $\mathbf{W}_a$ 为可学习的卷积核权重。

继而,将统计得到的物理先验掩码 $\mathbf{M}$ 与学习得到的注意力特征 $\mathbf{Z}$ 融合($\odot$ 表示逐元素相乘),生成最终注意力权重图,即:

$$\mathbf{A} = \sigma(\mathbf{Z} \odot \mathbf{M}) \tag{14}$$

其中, σ 为 Sigmoid 函数。该过程相当于用物理先验对网络自学习的注意力进行软约束,引导其在合理的物理区域内增强响应。

最后,利用注意力图对原始特征进行调制,即:

$$\tilde{\mathbf{F}} = \mathbf{F} \otimes \mathbf{A} \tag{15}$$

其中, $\otimes$ 表示沿通道维进行广播的逐元素相乘。调制后的特征 $\tilde{\mathbf{F}}$ 在物理关键区域得到增强,在无关区域受到抑制。此过程使网络能够以极低的参数代价,学习到与领域物理高度一致的特征表示。

3 实验与工业验证

3.1 实验设置与训练策略

实验在配备 NVIDIA GeForce RTX 3060 GPU 的硬件平台上进行,软件环境为 Python 3.8 与 PyTorch 深度学习框架。使用构建的 Low-YieldD 数据集,该数据集包含 10 个供液能力等级,共 15 000 张标注示功图,并已通过归一化与清洗预处理。

采用 Adam 优化器 ($\alpha = 0.001, \beta_1 = 0.9, \beta_2 = 0.999$) 替代传统的 SGD,其自适应学习率特性加速了在示功图

非均匀特征分布上的收敛。模型使用加权分类交叉熵损失函数进行训练以平衡类别样本,数学表达式如式 (16) 所示。

$$L = - \frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C \omega_c \cdot y_{i,c} \log(\hat{y}_{i,c}) \tag{16}$$

其中, N 是样本数, C 是供液能力等级数 (10 类)。 $y_{i,c}$ 是样本 i 在类别 C 的真实标签。 $\hat{y}_{i,c}$ 是预测的概率分布,而 ω_c 是类别 C 的权重因子,用于进一步平衡数据集。模型训练 200 个 epoch,批大小为 32。在网络中使用了批归一化 (batch normalization, BN) 与 Dropout (比率 = 0.5) 来加速训练并抑制过拟合。

3.2 时空网络性能分析

1) 时序预测模块性能

给定连续历史序列,如图 13(a) 所示,模型成功预测了未来 5 个时间步 (1T~5T) 的示功图形态,如图 13(b) 所示。预测结果不仅保持了高度的视觉保真度,更重要的是清晰捕捉到了“刀把”长度逐渐增加的渐变趋势,直观反映了供液能力的恶化过程,证明了模块对时序演变规律的捕捉能力。




图 13 实测示功图与 LSTM 预测示功图 (归一化)

Fig. 13 Measured and LSTM-predicted dynamometer cards (normalized)

为了进行定量比较,使用标准 LSTM、RNN 和反向传播神经网络 (back propagation neural network, BPNN) 处理相同的输入序列,如图 14(a) ~ (e) 所示。

双流 LSTM 预测在所有时间步上都与测量数据保持了优越的对齐度,特别是在保持“刀把”形态演变趋势方面表现最佳,突显了其在捕捉时序模式和长期依赖关系方面的优势。

如表 3 所示,总结了各模型的平均性能指标。双流 LSTM 实现了最低的均方误差 ($MSE = 0.083\ 2$) 和最佳的预测效能得分 ($Q = 0.06$),同时保持了每样本 8.2 ms 的推理速度,证实了其适用于实时应用。表 4 则提供了所提双流 LSTM 在各未来时间步的详细误差分析,作为图 9 定性对比的量化补充。两者结合,从视觉对齐与数值精度两个维度完整评估了预测性能。




图 14 各模型在连续时间步的预测性能比较

Fig. 14 Prediction performance comparison of different models at consecutive time steps

表 4 双流 LSTM 模型在各时间步的预测误差

Table 4 Prediction error of the dual-stream LSTM model at each time step

时间步	Q
1T	0.06
2T	0.07
3T	0.05
4T	0.06
5T	0.06
平均	0.06

为了提供超越时间预测精度的模型能力整体评估, 本文使用雷达图可视化进行了全面的多维度性能分析, 如图 15 所示。

该评估涵盖了 5 个关键性能指标: 预测精度 (MSE)、预测效能 (Q-Score)、计算效率 (推理速度)、时间一致性和操作稳定性。所提出的双流 LSTM 展现了一个平衡且优越的性能轮廓, 特别是在预测精度和时间一致性方面表现出色。

2) 空间识别模块与 PISA 机制有效性

为验证物理引导的空间识别能力, 本文重点分析了 PISA 机制的作用。如图 16 所示, 展示了一个典型案例: 图 16(a) 为 PISA 生成的注意力图; 图 16(b) 为基于梯度的通用注意力图结果。




图 15 5 个评估维度上综合模型性能的雷达图比较

Fig. 15 Radar chart comparison of overall model performance across five evaluation dimensions

可见, PISA 准确地聚焦于卸载线关键区域, 而通用注意力图则较为弥散, 区分度低。定量分析表明, 在卸载区域内, PISA 的平均注意力强度达到 0.89, 比基线方法 (0.62) 提升 43.5%。其注意力图与专家根据动力学先验标注的关键区域之间的皮尔逊相关系数高达 0.91, 显著优于基线的 0.67。这强有力地证明了 PISA 成功地将泵杆系统“液击延迟”的物理先验嵌入网络, 使其注意力机制与领域知识高度一致, 实现了物理可解释的特征聚焦。




图 16 代表性低产油井示功图的对比分析
Fig. 16 Comparative analysis of representative dynamometer cards from low-yield oil wells

3) 与主流轻量化网络对比

为进一步验证所提轻量化 CNN-PISA 架构的先进性, 本文将其与近年来仪器仪表领域广泛采用的几种轻量化网络进行对比, 包括 MobileNetV2、ShuffleNetV2、EfficientNet-Lite 以及 SqueezeNet。所有模型均在相同数据集 (Low-YieldD) 与训练策略下进行公平比较, 结果如表 5 所示。

表 5 与主流轻量化网络的性能对比
Table 5 Performance comparison with mainstream lightweight networks

模型	参数量/ M	准确率/%	推理速 度/ms	物理合理 性得分
MobileNetV2	3.50	96.8	5.2	0.71
ShuffleNetV2	2.85	97.1	4.8	0.68
EfficientNet-Lite	4.52	97.5	6.5	0.73
SqueezeNet	1.25	95.3	3.9	0.65
本文方法	0.79	99.1	8.3	0.93

为量化模型学习特征与物理机理的一致性, 引入物理合理性得分, 即采用空间 Dice 系数进行计算。首先将模型最终卷积层的特征图进行归一化与阈值二值化, 得到模型关注区域掩模; 随后与专家根据泵杆动力学先验标注的卸载线关键区域掩模进行对比。Dice 系数计算公式为:

$$D = \frac{2|A \cap B|}{|A| + |B|} \tag{17}$$

得分越高, 表明模型越倾向于依据正确的物理原理进行决策, 其“黑箱”特性越低, 可解释性越强。

为确保专家标注具备客观性和可重复性, 从测试集中随机抽取 200 张示功图, 邀请 3 位具有 10 年以上经验的油田采油工程专家, 在互不干扰的情况下独立对卸载区进行像素级标注。采用双向随机效应模型, 计算基于单测度、绝对一致定义的类内相关系数 ICC(2, 1)。结果显示, $ICC(2, 1) = 0.93$ (95% CI: 0.90~0.95), 表明专

家标注具有极佳的一致性。同时, 针对二值数据补充计算 Fleiss' Kappa 系数, $\kappa = 0.89$ (95% CI: 0.86~0.92), 进一步验证了标注的可靠性。

最终基准掩模的生成采用“多数投票制”, 即将至少两位专家 (共识强度 ≥ 2) 一致认为是关键区域的像素定义为 GT。为评估阈值选择的影响, 分别采用阈值 ≥ 1 、 ≥ 2 、 ≥ 3 生成 3 种 GT 掩模, 并计算模型 Dice 系数。结果显示, Dice 系数分别为 0.91、0.93、0.92, 波动 $< 2.2\%$, 证明评估结果对阈值不敏感, 模型关注区域与专家共识核心高度重叠。

从表 5 中可见, 本文方法在极低参数量 (0.79 百万) 下仍保持最高识别准确率 (99.1%), 且物理合理性得分显著优于其他轻量化网络。虽然推理速度略低于部分极轻量网络 (如 SqueezeNet), 但其在实现模型轻量化的同时, 从根本上提升了特征的物理可解释性。这对于要求高可靠性、需人机协同决策的工业智能感知与仪器仪表系统而言, 具有比单纯追求精度或速度更重要的价值。

3.3 消融实验与敏感性分析

1) 消融实验

消融实验结果如表 6 所示。在基础模型上引入通用注意力模块后, 准确率提升至 95.3%, 物理合理性得分增至 0.79。进一步引入 PISA 机制后, 模型准确率显著提升至 99.1%, 且参数量增加极微 (仅 0.01 百万)。与基础模型相比, PISA 机制带来 +6.4% 的准确率提升; 与仅添加通用注意力的模型相比, 也带来 +3.8% 的提升。这表明, 基于物理先验的架构引导远比单纯增加模型复杂度或添加通用数据驱动组件更为有效。PISA 机制使得物理合理性得分从基础模型的 0.71 大幅提升至 0.93, 同时, 模型对关键物理特征 (如卸载线长度) 预测的梯度误差减少了 70.7%。

表 6 消融实验结果
Table 6 Ablation Study Results

模型	准确率/ %	参数量/ M	预测 误差	推理速 度/ms	物理合理 性得分
基础模型	92.7	0.76	0.41	8.1	0.71
+通用注意力	95.3	0.78	0.38	8.3	0.82
+PISA 机制	99.1	0.79	0.35	8.3	0.93

如图 17 所示的箱线图进一步显示, 引入 PISA 的模型在准确率与物理合理性得分上不仅中位数更高, 且分布更紧凑, 表现出优异的稳定性。消融实验证明, PISA 机制是达成高精度与高物理可解释性的关键, 其效能超越单纯增加模型复杂度或使用通用注意力模块。




图 17 消融实验

Fig. 17 Box plot of the ablation study results

2) 参数敏感性分析

为评估模型在变工况下的鲁棒性,敏感性分析研究了抽汲速度 (strokes per minute, SPM) 和液体粘度 μ 对模型准确率的交互影响,如图 18 所示。模型在标准工况下 (4 SPM, $\mu=5\sim15\text{ mPa}\cdot\text{s}$) 保持高准确率 (>98.5%)。在高粘度条件下 (>35 mPa·s) 极端条件下性能有所下降,这明确了模型当前的能力边界,也为未来针对复杂流体工况的改进指明了方向。

3.4 综合效益评估

为验证所提轻量化框架的工程实用价值,将其部署于长庆油田某区块的边缘计算网关(华为 Atlas 500),进行了为期一个月的连续运行测试。针对油田现场网络不稳、算力有限等挑战,采取了模型量化、缓存重传、云边协




图 18 参数敏感性热力图

Fig. 18 Heatmap of parameter sensitivity

同更新等工程化措施,保障了系统长期稳定运行。系统实现了近实时的工况感知与闭环调控。如表 7 所示的量化效益对比,相较于传统人工诊断方法,本系统取得了显著提升:系统响应延迟减少了 87.5%,实现了近实时的自适应控制,同时识别准确率提高到 99.1%。与此同时,月度无效抽油操作减少了 59.7%,能耗降低了 22.0%,维护效率提高了 35.3%。

表 7 工业应用效益对比分析

Table 7 Comparative Analysis of Industrial Application Benefits

方法	识别准确率/ %	系统响应 延迟/min	月度无效 操作次数	用电量/ (kWh·t ⁻¹)	人工干预频率/ (次·天 ⁻¹)	预测性维护 效率/%
传统方法	86.2	240	62	42.7	3.2	68
所提方法	99.1	30	25	33.3	0.8	92
改善幅度	+15.0%	-87.5%	-59.7%	-22.0%	-75.0%	+35.3%

4 结 论

针对低产油井示功图人工解译效率低、传统数据驱动方法物理可解释性弱、边缘实时处理困难等问题,本研究提出了一种物理引导的轻量化时空视觉感知模型。该方法通过将悬点位移-载荷时序信号转换为规范化的示功图灰度图像,构建了专用数据集 Low-YieldD,并设计了“时序预测-空间识别”级联架构。创新性地引入物理信息空间注意力机制,将抽油杆柱“液击延迟”动力学机理编码为可微分高斯空间掩码,引导轻量化 CNN 聚焦于卸载区等关键图像区域,实现了视觉特征的物理可解释性

聚焦。实验表明,该模型在极低参数量(约标准 AlexNet 的 1.3%)下,供液能力识别准确率达到 99.1%,显著优于主流轻量化视觉网络。工业部署验证显示,系统响应延迟缩短 87.5%,月度无效抽油降低 59.7%,吨液耗电减少 22%,展现出良好的工程应用价值。

尽管所提模型在低产油井示功图识别中表现优异,仍存在对图像质量敏感、依赖像素级标注、单峰高斯先验在极端工况下适应性有限等局限。未来研究将聚焦模型鲁棒性与泛化能力提升:通过物理先导图像增强、对抗训练及 PISA 正则项,增强低质量数据下的特征稳定性;利用 PISA 伪标签驱动弱监督学习,有效降低像素级标注依赖;将物理先验编码为可搜索超参数,通过多目标神经架

构搜索实现边缘超低功耗部署。此外,针对极端工况下卸载区的多模态分布,突破单峰高斯假设,探索高斯混合模型与可变形卷积融合的自适应注意力机制,进一步提升模型在复杂环境下的泛化能力。

参考文献

- [1] WANG CH, HOU J R, ZHANG L, et al. Quantitative characterization of the extent of crude oil mobilization and the range of pore-throat utilization during the gas flooding stage in low-permeability reservoirs [J]. *Physics of Fluids*, 2025, 37: 0281966.
- [2] LI J T, WEI J G, CHEN Y H, et al. Analysis of asynchronous/inter-fracture injection-production mechanism under the condition of five-spot vertical and horizontal well combination in low permeability oil reservoirs [J]. *Energy*, 2024, 308: 132923.
- [3] 赵怀军,姬永晟,胡定兴,等. 基于抽油机悬点载荷的油井动液面软测量方法[J]. *仪器仪表学报*, 2025, 46(7): 251-259.
- ZHAO H J, JI Y SH, HU D X, et al. Soft measurement method for dynamic liquid level of oil wells based on pumping unit suspension point load[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(7): 251-259.
- [4] 辜小花,王坎,李燕,等. 基于演化模型偏好多目标优化的智能采油辅助决策支持[J]. *机械工程学报*, 2017, 53(13): 159-169.
- GU X H, WANG K, LI Y, et al. Intelligent oil production decision support based on evolutionary model preference multi-objective optimization [J]. *Journal of Mechanical Engineering*, 2017, 53(13): 159-169.
- [5] 董世民,李伟成,侯田博文,等. 变频游梁式抽油系统运行参数的优化设计与性能仿真[J]. *机械工程学报*, 2016, 52(21): 63-70.
- DONG SH M, LI W CH, HOU T B W, et al. Optimal design and performance simulation of operating parameters for variable frequency beam pumping systems[J]. *Journal of Mechanical Engineering*, 2016, 52(21): 63-70.
- [6] 王通,李远超,高宪文,等. 基于多分支融合嵌入式注意力特征提取的油井工况诊断[J]. *控制与决策*, 2025, 40(5): 1742-1750.
- WANG T, LI Y CH, GAO X W, et al. Oil well working condition diagnosis based on multi-branch fused embedded attention feature extraction [J]. *Control and Decision*, 2025, 40(5): 1742-1750.
- [7] ZHANG R CH, YIN Y Q, XIAO L F, et al. A real-time diagnosis method of reservoir-wellbore-surface conditions in sucker-rod pump wells based on multidata combination analysis[J]. *Journal of Petroleum Science and Engineering*, 2021, 198: 108254.
- [8] ANDRADE G M P, DE MENEZES D Q F, SOARES R M, et al. Virtual flow metering of production flow rates of individual wells in oil and gas platforms through data reconciliation [J]. *Journal of Petroleum Science and Engineering*, 2022, 208: 109772.
- [9] 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.
- [10] LIU X W, LI D P, JIA Y X, et al. Optimizing construction parameters for fractured horizontal wells in shale oil[J]. *Frontiers in Digital Humanities*, 2023, 10: 1015107.
- [11] LIU W H, LI J H, YANG G H, et al. Interval estimation of dynamic liquid level of sucker-rod pumping systems based on dynamometer card[J]. *Control Engineering Practice*, 2024, 152: 106064.
- [12] LEE S, KIM T. FRFconv-TDSNet: Lightweight, noise-robust convolutional neural network leveraging full-receptive-field convolution and time-domain statistics for intelligent machine fault diagnosis [J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73: 1-13.
- [13] BANG J, DI MARCO P, SHIN H, et al. Deep Transfer learning-based fault diagnosis using wavelet transform for limited data [J]. *Applied Sciences*, 2022, 12(15): 7450.
- [14] MENG W F, ZHAO P P, SHI Y J, et al. Intelligent fault diagnosis of mechanical engineering using NLF-LSTM optimized deep learning model [J]. *Optimization and Engineering*, 2025, 6: 891-912.
- [15] YIN CH ZH, ZHANG K, LIU J Y, et al. The real-time dynamic liquid level calculation method of the sucker rod well based on multi-view features fusion [J]. *Petroleum Science*, 2024, 21: 3575-3586.
- [16] CHEN G Y, TANG G, ZHU ZH X. VKCNN: An interpretable variational kernel convolutional neural network for rolling bearing fault diagnosis [J]. *Advanced Engineering Informatics*, 2024, 62: 102705.
- [17] 汪鑫,廖小平,刘树胜,等. 多传感器融合下多工况刀具磨损状态预测的深度森林方法研究[J]. *仪器仪表*

- 学报, 2023, 44(9): 265-274.
- WANG X, LIAO X P, LIU SH SH, et al. Research on deep forest method for tool wear state prediction under multi-sensor fusion and multi-condition [J]. Chinese Journal of Scientific Instrument, 2023, 44(9): 265-274.
- [18] ZHANG ZH, DONG D ZH, LYU L L, et al. Research on ultra-short-term load forecasting method of oil and gas field integrated energy system based on hybrid neural network[J]. Electrical Engineering, 2025, 107(10): 14021-14036.
- [19] LIU D J, FENG G Q, FENG G Y, et al. Hybrid long short-term memory and convolutional neural network architecture for electric submersible pump condition prediction and diagnosis [J]. SPE Journal, 2024, 29(5): 2130-2147.
- [20] SONG F Q, DING H Y, WANG Y ZH, et al. A well production prediction method of tight reservoirs based on a hybrid neural network [J]. Energies, 2023, 16(6): 2904.
- [21] WANG X, HE Y F, LI F J, et al. A working condition diagnosis model of sucker rod pumping wells based on deep learning [J]. SPE Production & Operations, 2021, 36(2): 317-326.
- [22] MA R, TIAN H F, CHENG X CH, et al. Oil-Net: A learning-based framework for working conditions diagnosis of oil well through dynamometer cards identification [J]. IEEE Sensors Journal, 2023, 23(13): 14406-14417.
- [23] HE Y P, CHENG H B, ZENG P, et al. Working condition recognition of sucker rod pumping system based on 4-segment time-frequency signature matrix and deep learning [J]. Petroleum Science, 2024, 21(1): 641-653.
- [24] 付承彪, 庄清源, 田安红. 基于多通道卷积方式的土壤重金属镍含量定量预测 [J]. 浙江大学学报(工学版), 2025, 59(10): 2221-2228.
- FU CH B, ZHUANG Q Y, TIAN AN H. Quantitative prediction of soil heavy metal nickel content based on multi-channel convolutional method [J]. Journal of Zhejiang University (Engineering Science), 2025, 59(10): 2221-2228.
- [25] 韩萍, 白继睿, 周杰龙, 等. 基于轻量化改进和模型剪枝的 SAR 图像飞机目标检测 [J]. 仪器仪表学报, 2025, 46(9): 110-124.
- HAN P, BAI J R, ZHOU J L, et al. Aircraft target detection in SAR images based on lightweight improvement and model pruning [J]. Chinese Journal of Scientific Instrument, 2025, 46(9): 110-124.
- [26] 陈方彬, 赵仲勇, 王建, 等. 基于 YOLO-MCSL 的轻量化智能电表热缺陷目标检测方法 [J]. 仪器仪表学报, 2025, 46(8): 108-119.
- CHEN F B, ZHAO ZH Y, WANG J, et al. Lightweight thermal defect target detection method for smart electric meters based on YOLO-MCSL [J]. Chinese Journal of Scientific Instrument, 2025, 46(8): 108-119.
- [27] 张彪, 苟荣科, 许家忠. 基于深度学习的工业轴承缺陷检测算法研究 [J]. 仪器仪表学报, 2025, 46(4): 136-149.
- ZHANG B, XUN R K, XU J ZH. Research on industrial bearing defect detection algorithm based on deep learning [J]. Chinese Journal of Scientific Instrument, 2025, 46(4): 136-149.
- [28] 吴启航, 丁晓喜, 何清波, 等. 齿轮箱故障边缘智能诊断方法及应用研究 [J]. 仪器仪表学报, 2024, 45(1): 70-80.
- WU Q H, DING X X, HE Q B, et al. Research and application of edge intelligent diagnosis method for gearbox faults [J]. Chinese Journal of Scientific Instrument, 2024, 45(1): 70-80.
- [29] MA B, DONG SH M. A hybrid prediction model for pumping well system efficiency based on stacking integration strategy [J]. International Journal of Energy Research, 2024: 8868949.
- [30] QIU B B, LIU S Q, LI W D, et al. Dynamic adaptive fault diagnosis using multi-channel image fusion and deep learning in channel failure occasions on rolling bearings [J]. Advanced Engineering Informatics, 2025, 68: 103631.
- [31] SHEN Y L, WANG J X, MO SH P, et al. Data augmentation aided excavator activity recognition using deep convolutional conditional generative adversarial networks [J]. Advanced Engineering Informatics, 2024, 62: 102789.
- [32] GU D SH, ZHENG R CH, CHENG P, et al. Single well production prediction model of gas reservoir based on CNN-BILSTM-AM [J]. Energies, 2024, 17(22): 5674.
- [33] DUTTA S, BOONGAOEN T, ZWIGGELAAR R. Human activity recognition with noise-injected time-distributed AlexNet [J]. Biomimetics, 2025, 10(9): 613.
- [34] SIVAKUMARI T, VAN R. Retracted: Performance analysis

of Alexnet for classification of knee osteoarthritis [J].
Current Medical Imaging, 2024, 20: 090823219574.

[35] LIAO H B, LI ZH, LIU H Q, et al. Research on the prediction method of mineral fraction content of lacustrine shale based on AlexNet [J]. Petroleum Science and Technology, 2025:2498208.

[36] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.

作者简介



刘沛津,1994 年于西安交通大学获得学士学位,2003 年于西安交通大学获得硕士学位,2012 年于西安建筑科技大学获得博士学位,现为西安建筑科技大学机电工程学院教授,主要研究方向为新能源系统智能检测与优化控制、电力设备状态监测与故障诊断、复杂机电系统非线性控制。

E-mail:liuxpj@xauat.edu.cn

Liu Peijin received her B. Sc. and M. Sc. degrees both from

Xi'an Jiaotong University in 1994 and 2003, respectively, and her Ph. D. degree from Xi'an University of Architecture and Technology in 2012. She is currently a professor in the School of Mechanical and Electrical Engineering, Xi'an University of Architecture and Technology. Her main research interests include intelligent detection and optimal control of new energy systems, condition monitoring and fault diagnosis of power equipment, and nonlinear control of complex electromechanical systems.



孙昱(通信作者),2008 年于西安建筑科技大学获学士学位,2012 年于西安建筑科技大学获硕士学位,2023 年于西安建筑科技大学获博士学位,现为西安建筑科技大学讲师,主要研究方向为机电一体化技术。

E-mail:cw124758@foxmail.com

Sun Yu (Corresponding author) received his B. Sc. , M. Sc. and Ph. D. degrees all from Xi'an University of Architecture and Technology in 2008, 2012, and 2023, respectively. He is currently a lecturer at Xi'an University of Architecture and Technology. His main research interest includes mechatronics technology.