

文章编号:1009-9603(2022)01-0181-09

DOI:10.13673/j.cnki.cn37-1359/te.2022.01.023

基于深度学习的油井工况智能诊断技术研究及应用

王相¹,杨耀忠²,何岩峰¹,王振³,窦祥骥¹

(1.常州大学石油工程学院,江苏常州213164;2.中国石化胜利油田分公司信息化管理中心,山东东营257000;3.胜利油田鲁明油气勘探开发有限公司,山东东营257000)

摘要:及时准确地掌握油井的工况,对于油田安全高效生产和提高采收率具有重要意义。随着油田信息化建设的不断深入,示功图等油井生产动态监测数据实现了实时采集,并积累了海量数据,亟待进一步挖掘利用。基于“大数据+深度学习”的新一代人工智能技术,有望突破现有技术的局限,引领油井工况诊断技术升级。为此,依托4000余万组涵盖不同油藏类型油井的历史动态监测数据,制备了涵盖5大类37种工况类型的油井工况诊断样本集,在此基础上,选择卷积神经网络算法,个性化设计了面向油井工况诊断问题的卷积神经网络(OWDNet),包含26层5900余万个可学习参数。使用油井工况诊断样本集对OWDNet进行训练,10轮次后,训练准确率达99.7%,验证准确率达98.9%。利用开发的油井工况智能诊断系统,在现场完成500余万次工况诊断,准确率达90%,报警推送及时,借助该系统开展油井生产管控更加合理高效,油井工况持续改善,连续稳定生产井比例由68%上升到88%,为油田大数据的高价值应用提供了有益示范。

关键词:油井;工况诊断;深度学习;大数据;卷积神经网络

中图分类号:TE319

文献标识码:A

Research and application of intelligent diagnosis technology of oil well working conditions based on deep learning

WANG Xiang¹, YANG Yaozhong², HE Yanfeng¹, WANG Zhen³, DOU Xiangji¹

(1.School of Petroleum Engineering, Changzhou University, Changzhou City, Jiangsu Province, 213164, China; 2.Information Management Center, Shengli Oilfield Company, SINOPEC, Dongying City, Shandong Province, 257000, China; 3.Luming Oil and Gas Exploration and Development Co., Ltd., Dongying City, Shandong Province, 257000, China)

Abstract: Timely and accurate monitoring of the working conditions of oil wells is of great significance to the safe and efficient production of oilfields and the enhanced oil recovery. With the continuous deepening of oilfield informatization construction, real-time collection of dynamic monitoring data regarding oil well production such as indicator diagrams has been realized, and massive amounts of data have been accumulated and urgently need to be further explored and utilized. A new generation of artificial intelligence technology based on “big data+deep learning” is expected to break through the limitations of existing technologies and lead the upgrade of working condition diagnosis technology for oil wells. To this end, first, relying on more than 40 million sets of historical dynamic monitoring data covering oil wells in the different reservoirs, we prepared a large-scale dataset for working condition diagnosis of oil wells, which covered 5 categories and 37 different types of working conditions. On this basis, we selected the convolutional neural network algorithm and designed a personalized convolutional neural network (OWDNet) for working condition diagnosis of oil wells which contained more than 59 million learnable parameters in 26 layers. The OW DNet was trained using the above-mentioned working condition diagnosis dataset. After 10 epochs, the training accuracy was up to 99.7%, and the verification accuracy reached 98.9%. Furthermore, an intelligent working condition diagnosis system for oil wells was developed, and more than 5 million working condition diagnoses have been completed on site. The application accuracy of working condition diagnosis is 90%, and timely

收稿日期:2021-07-26。

作者简介:王相(1989—),男,山东滕州人,讲师,博士,从事石油工程大数据与人工智能应用研究。E-mail:xiangwang@cczu.edu.cn。

基金项目:中国石化科技攻关项目“大数据技术在油田开发中的应用研究”(P20071)。

alarms are achieved. With this system, oil well production management and control were more reasonable and efficient, and working conditions of oil wells continued to improve. The proportion of continuous and stable production wells increased from 68% to 88%. The research provided a useful demonstration for the high-value application of oilfield big data.

Key words: oil well; working condition diagnosis; deep learning; big data; convolutional neural network

目前中国有10万余口油井,其中约90%采用有杆抽油系统生产,由地面抽油机经过抽油杆带动井下千米深处的抽油泵工作,将原油举升到地面^[1]。作为典型的高风险高能耗系统,油井工作条件复杂恶劣,在长期运行过程中一旦发生异常,不仅会造成原油产量损失,甚至可能导致恶劣的安全和环境事故^[2]。因此,及时准确地掌握油井的工作状况,对于油田安全高效生产和提高采收率具有重要意义。

油井工况诊断作为石油开采中的关键问题之一,一直面临很大困难。由于油井分布分散,抽油杆和抽油泵等大量重要装备位于数千米深的油井内,不可视、不可及,其工况难以直观判断。同时,受系统结构复杂性及井下的腐蚀、出砂、结蜡、产气和产水等因素的影响,油井可能出现的工况种类十分多样,监测指标和工况间的响应关系复杂且不清晰。经过数十年的研究和探索,油井工况诊断技术大致经历了人工识别、自动化诊断和人工智能诊断三个阶段^[3-6],形成了一系列方法,但大多只实现了部分常见的、单一型工况的诊断,现场应用效果不够理想,仍未摆脱依靠人工分析的局面。

随着当前油田信息化建设的不断深入,大量传感器装配在油井生产系统中,实时采集油井的温度、压力和电流等数据并源源不断的传入油田数据中心,形成油井生产监测大数据。同时,大数据和深度学习技术正在引起新一轮技术革命,在图像识别、语音处理、无人驾驶和医疗诊断等多个领域不断取得突破性进展,石油公司也纷纷出台大数据和人工智能相关战略和发展计划,大数据和深度学习技术在油田应用迎来战略机遇^[7-9]。在这种情况下,基于“大数据+深度学习”的新一代人工智能技术,有望突破现有技术的局限,引领油井工况诊断技术进入新的阶段。为此,基于油田信息化建设成果,依托油井生产实时监测大数据,综合利用大数据和人工智能技术,制备了涵盖5大类37种工况问题的油井工况诊断样本集,研究建立了面向油井工况诊断的卷积神经网络(OWDNet),构建了具备持续学习能力的油井工况智能诊断系统,实现了油井工况诊断和生产管理的精准化、智能化和实时化,为油井工况持续改善、产量提升和石油行业的智能化转型升级提供了技术支撑。

1 基于油井监测数据的工况诊断样本集制备

样本集是机器学习相关研究的基础,用于训练机器学习模型。机器学习模型的质量取决于样本集的质量和规模。目前该领域流行的样本集,如MNIST手写数字识别样本集,包含70 000张数字0到9的图片,ImageNet图像识别数据集的图像总数超过150万张。

对于油井工况诊断问题,其数据集的样本为示功图,同时每张图像对应一个标签,用于表征该示功图所属的工况类型。调研了2010年以来公开发表的基于机器学习的油井工况诊断相关研究,对于各研究中使用的样本集规模、样本覆盖工况类型数量、采用的机器学习算法等进行了统计^[10-27],结果如表1所示。

表1 2010年以来油井工况诊断研究统计结果

Table1 Statistical results of research on working condition diagnosis of oil wells since 2010

发表时间	采用的机器学习算法	覆盖工况类型数量/种	样本数/张
2012 ^[10]	粗糙集	5	500
2013 ^[11]	BP神经网络	3	180
2013 ^[12]	自组织竞争神经网络	4	600
2014 ^[13]	自组织竞争神经网络	5	750
2014 ^[14]	极限学习机	6	150
2016 ^[15]	深度信念网络与支持向量机	8	1 347
2017 ^[16]	深度信念网络	8	1 500
2018 ^[17]	卷积神经网络(LeNet-5)与支持向量机	8	7 200
2018 ^[18]	改进的AlexNet网络	4	746
2018 ^[19]	卷积神经网络	17	200
2018 ^[20]	多分类支持向量机	10	275
2018 ^[21]	稀疏自编码神经网络	8	8 000
2019 ^[22]	灰度矩阵极限学习机	11	154
2019 ^[23]	卷积神经网络与栈式稀疏自编码神经网络	8	7 200
2019 ^[24]	卷积神经网络(Inceptionv3)	5	500
2020 ^[25]	改进的AlexNet网络	13	3 900
2020 ^[26]	轻量注意力卷积神经网络	10	18 500
2021 ^[27]	卷积神经网络(GoogleNet)	11	11 550

由表1可以看出,随着研究的不断发展,油井工况诊断样本集的样本规模和覆盖的工况类型数量总体上呈现增长的趋势,样本规模最大已达到18 500张示功图,覆盖工况类型数量最大达17种。面对复杂的工作环境,油井可能出现的工况类型远不止十几种,为了实现更全面的油井工况问题诊断,油井工况诊断样本集的样本规模和覆盖的工况类型数量还有待进一步提升。

在油田信息化建设中,越来越多的油井井口安装了示功图采集仪,实时采集示功图的位移和载荷数据并传输到数据中心。以S油田为例,目前各油井的示功图采集频率为30 min/次,1万口油井每年产生的示功图相关数据可达1.7亿余组,为构建大规模油井工况诊断样本集奠定了坚实的数据基础。本研究抓取了S油田4 000余万组示功图相关数据,覆盖油井1 930口,涵盖了高含水整装、低渗透和稠油等多种油藏类型,以期尽可能全面地覆盖不同油藏生产情况。

1.1 标准化示功图绘制

绘制示功图是制备油井工况诊断样本集的前提。示功图原始数据在数据库中以位移向量(W)和载荷向量(Z)的形式存储,位移向量和载荷向量中分别记录了抽油井上下冲程过程中200个采样点的

悬点位移和悬点载荷。分别以位移和载荷作为横、纵坐标,在直角坐标系中绘制得到的位移与载荷的关系曲线即为示功图。示功图绘制需要遵守统一的规范,传统上习惯于将黑色示功图曲线绘制在宽高比为2:1的画面中,同时隐去坐标轴标记。默认情况下,示功图纵轴的取值范围为 $[\min Z, \max Z]$ 。在某些工况下,如杆断,最大载荷和最小载荷的差距会显著减小,如果采用默认的纵轴取值范围,示功图看起来仍较饱满(图1a),从而极易误判。为此,本研究在绘制示功图时纵轴的取值范围设定为 $[\max(\min Z, 0), \max Z]$,如图1b所示。在此基础上,考虑到单一时刻示功图难以充分展示油井工况的动态变化信息,在当前时刻示功图的基础上,增加上一时刻示功图,构成叠加示功图(图1c),为精准的工况诊断提供更丰富的信息。综合以上分析,本研究最终确定采用的示功图绘制标准为:①图像宽高比为2:1,大小为200×100像素。②图像无坐标轴标记。③图像为灰度图,底色为白色,当前示功图颜色为黑色,上一时刻示功图颜色为50%灰度。线型均为实线,线宽均为2像素。④图像横轴取值范围设定为 $[\min W, \max W]$,纵轴取值范围设定为 $[\max(\min Z, 0), \max Z]$ 。

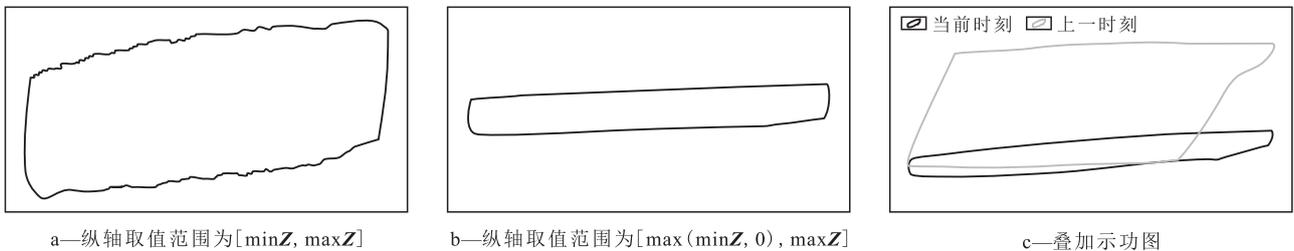


图1 不同绘制标准下示功图

Fig.1 Indicator diagrams under different drawing standards

1.2 工况类型划分及标注

有杆抽油系统由抽油机、抽油杆和抽油泵等部件组成,结构复杂,且长期与地层流体接触,油井可能出现的工况种类多种。结合现场专家经验及示功图特征,总结梳理常见工况类型37种,涵盖健康、地层问题、井筒问题、地面问题和数据问题5大类(表2)。

样本标注的准确性对于机器学习模型的性能至关重要,针对每一张标准化示功图,均需要经验丰富的油田专家结合示功图形状及油井井史进行逐一研判标注。高质量大规模的已标注数据样本是油田宝贵的数据资产,但标注过程费时费力,完全依靠人力完成数百万示功图的标注难以实现。

表2 工况分类结果

Table2 Classification of working conditions	
工况大类	工 况 类 型
健康	健康生产
地层问题	轻微供液不足,一般供液不足,严重供液不足,轻微气体影响,一般气体影响,严重气体影响,抽喷,出砂,油稠
井筒问题	管漏,管脱,浅部杆断脱,深部杆断脱,杆卡,缓下,游动凡尔漏失,固定凡尔漏失,双凡尔漏失,活塞单凡尔漏失,泵体漏失,泵卡
地面问题	上挂,下碰,脱出工作筒,振荡,驴头别光杆
数据问题	镜像翻转,死点超前,死点滞后,周期延长,周期缩短,载荷突变,载荷漂移,载荷锯齿,位移丢失,位移错乱

为此,采用了迭代式标注策略以减少标注过程的人力,具体操作流程如图2所示。迭代式标注策略首先从未标注样本集中抽取部分未标注样本进行人工标注,之后采用人工标注的样本集训练1个神经网络分类器,如果神经网络分类器的准确率能够满足要求,则利用该神经网络分类器对剩余未标注的样本进行自动标注,人工只需要对自动标注的结果进行审核,从而有效降低了样本标注时间。

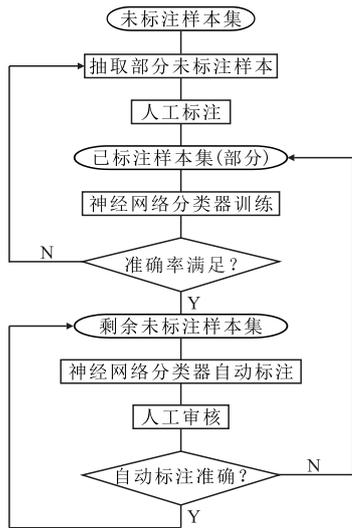


图2 样本迭代式标注策略流程

Fig.2 Flowchart of iterative labeling strategy

截至2021年10月,已完成示功图标注153 772组,尽管目前工况诊断样本集中已标注样本的总体规模已经有数量级的突破,但不同工况间样本数量存在显著差异,健康生产包含34 089个样本,而载荷漂移工况样本仅为3个(图3)。这主要是由于不同工况在油田发生的频次不同,载荷漂移等工况发生次数较少,因此产生的有效样本也较少。

为了保证不同工况类型的样本数分布足够均

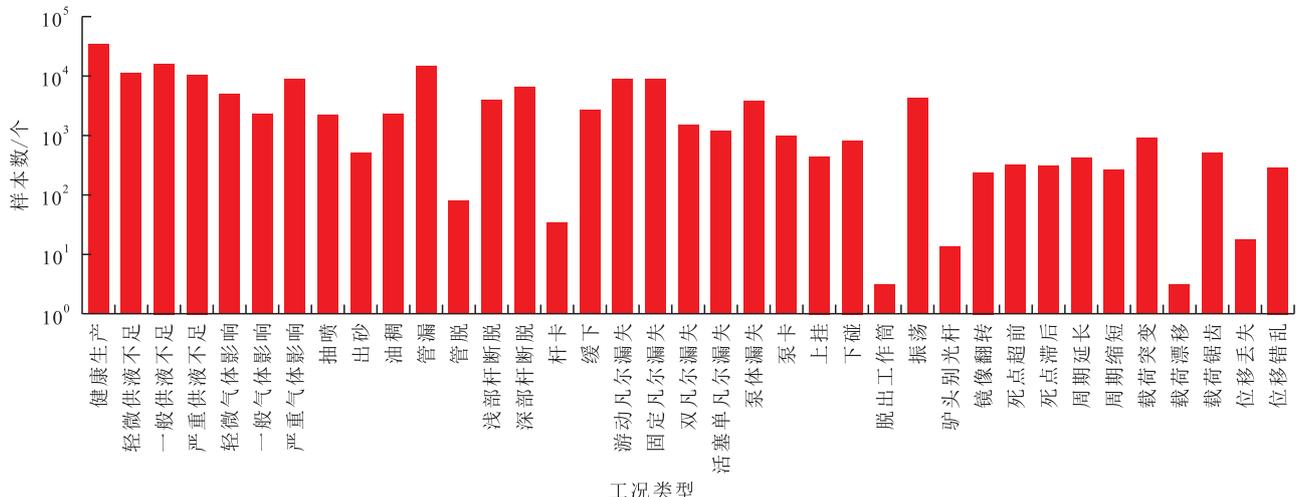


图3 各工况类型所包含的示功图样本数

Fig.3 Number of indicator diagram samples for each working condition

匀,机器学习领域中常用数据增强的办法解决有效样本少的问题,即在现有示功图样本的基础上,对其进行随机旋转、平移、翻转和缩放等操作产生一批新的同类样本。对于示功图来说,上述操作极易使得示功图所代表的工况类型发生变化,因此对于油井工况诊断样本集难以应用数据增强技术。在实际机器学习模型训练过程中,选择重复采样策略,确保小样本量所对应的工况类型得到足够多的学习。

2 基于深度学习的油井工况诊断神经网络架构设计

油井工况诊断的目的即根据油井示功图,利用计算机进行分类判定,从而给出该油井所处的工况,这属于典型的模式识别问题。机器学习是解决模式识别问题的核心算法,通过对比传统机器学习和深度学习在油井工况诊断时的优缺点,从常用深度学习算法中选择了卷积神经网络,并针对油井工况诊断问题开展神经网络架构的个性化设计。

2.1 传统机器学习与深度学习

油井工况诊断的原始输入对象为示功图。对于传统机器学习方法,需要首先对示功图进行特征提取,例如基于灰色理论的工况诊断方法,先将示功图转化为灰度矩阵,之后计算灰度均值和灰度方差等6个参数组成特征向量,再根据不同示功图特征向量的差异性进行诊断分类^[10-13]。特征选取的优劣对于分类准确率影响显著,面对复杂多样的油井工况,人工开展特征设计难度很大。另外,示功图在特征提取过程中,大量有效信息损失,使得某些工况类型难以有效区分。

深度学习作为机器学习中的一个新兴领域,不需要进行人工特征提取,可以直接将原始数据作为输入对象,通过大量样本学习自动找出用于诊断分类的重要特征,有效避免了人工特征提取的繁琐和有效信息损失^[28-29]。与此同时,深度学习算法的复杂度更高,算法性能依赖更大量的数据样本。考虑到目前油田信息化建设水平,油井示功图已经实现自动化采集,积累了海量示功图样本,为开展基于深度学习的油井工况智能诊断创造了良好条件。

2.2 深度学习算法优选与神经网络架构设计

典型的深度学习算法包括深度置信网络(DBN, Deep Belief Network)、卷积神经网络(CNN, Convolution Neural Network)、递归神经网络(RNN, Recurrent Neural Network)等^[28-31]。3类深度学习算法的特点及典型应用领域对比如表3所示。

表3 典型深度学习算法对比
Table3 Comparison of typical deep learning algorithms

算法名称	算法特点	典型应用领域
DBN	包含许多隐藏层,为受限玻耳兹曼机和自动编码器的组合	时间序列分析 聚类 数据挖掘 非线性降维
CNN	通过卷积和池化操作提取图像等模式数据的隐含信息,实现分析判定	图像识别 视频分析 自然语言处理 异常检测
RNN	隐藏层中的每个神经元接收具有特定时间延迟的输入,可以处理历史信息	机器翻译 时间序列预测 语音识别 语音合成

考虑到油井工况诊断的输入对象为示功图,因此选择了具有强大的图像特征学习和分类能力的CNN。CNN是目前在图像识别等计算机视觉领域研究中的主导算法,已经取得了一系列成功应用。作为一种深度学习算法,CNN的灵感来自于动物视觉皮层组织,通过一层层不同类型的视觉神经自适应地提取图像的空间层次信息。从数学模型上,CNN通常包含卷积层、池化层和全连接层3种不同类型的层。其中卷积层和池化层用于执行图像特征提取操作,前者通过不同卷积核对特征图进行滤波扫描实现不同视角下的特征提取,后者对特征进行降维,全连接层将提取的特征映射到最终输出。

针对不同问题,卷积层、池化层和全连接层的数量和逻辑关系有所不同,即卷积神经网络架构设计不同。由于神经网络类算法的不可解释性,目前神经网络架构设计仍缺少通用的标准和规范,更多

地依赖经验和试错法完成。针对油井工况诊断问题特点,结合图像识别领域LeNet-5, AlexNet, VGG-Net, GoogleNet(Inception)和ResNet等经典网络架构及矿场实践,设计面向油井工况诊断的卷积神经网络(OWDNet)的架构如表4所示。

OWDNet共包含26层,其中5个卷积层,均采用3×3的小卷积核;3个池化层,均采用2×2的最大池化。除了分类输出前采用Softmax激活函数以外,各中间层均采用ReLU激活函数。Softmax和ReLU激活函数的公式分别为:

$$\text{soft max}_i(x) = \frac{e^{x_i}}{\sum_{j=1}^J e^{x_j}} \quad i = 1, 2, 3, \dots, J \quad (1)$$

$$\text{relu}_i(x) = \max(0, e^{x_i}) \quad i = 1, 2, 3, \dots, J \quad (2)$$

OWDNet可学习参数总数达到5 900余万个,为了避免模型训练过程耗时过长及可能出现过拟合现象的问题,加入了5个Dropout层。Dropout层在训练过程中随机选定一定比例的神经元停止参与运算,在减少了计算量的同时,将一个单一大规模模型转化为多个相对小规模模型的集合,能够有效提升模型的泛化能力^[32]。

3 神经网络训练与矿场应用

3.1 神经网络训练

神经网络训练是寻找卷积层中各卷积核和全连接层中各神经元连接之间权重的过程,以期最大程度地降低输出层的计算结果与样本集给定的真实标签之间的差异。损失函数和优化器的选择及设定在神经网络训练中起到关键作用。首先将数据样本输入到神经网络,再通过向前传播过程和损失函数评估当前模型性能,然后通过反向传播过程和优化器根据损失的大小对神经网络中可学习参数的权重进行更新。

OWDNet训练的损失函数选用交叉熵损失函数,其刻画了2个概率分布之间的距离,其表达式为:

$$C = -\frac{1}{n} \sum_{k=1}^n [y_k \ln a_k + (1 - y_k) \ln(1 - a_k)] \quad (3)$$

优化器选用Adadelta,其是在Adagrad算法的基础上改进得到的扩展版。Adadelta相比Adagrad,不再累积所有过去的梯度,而是根据渐变更新的移动窗口调整学习率,使其具有更强的鲁棒性^[33]。Adadelta算法参数设定主要包括:学习率为1.0, Adadelta梯度平方移动均值的衰减率为0.95,模糊因子

表4 面向油井工况诊断的卷积神经网络(OVDNet)架构
Table4 Architecture of convolutional neural network(OVDNet)for working condition diagnosis of oil wells

编号	类型	参数	数据维度	可学习参数	可学习参数总数
1	图像输入		200×100×1		0
2	卷积	卷积核大小:3×3 卷积核数量:32 步幅:1×1	198×98×32	权重:3×3×1×32 偏置:1×1×32	320
3	激活	激活函数:ReLU	198×98×32		0
4	池化	池化类型:最大池化 池化核大小:2×2 步幅:2×2	99×49×32		0
5	Dropout	比例:5%	99×49×32		0
6	卷积	卷积核大小:3×3 卷积核数量:64 步幅:1×1	97×47×64	权重:3×3×32×64 偏置:1×1×64	18 496
7	激活	激活函数:ReLU	97×47×64		0
8	卷积	卷积核大小:3×3 卷积核数量:64 步幅:1×1	95×45×64	权重:3×3×64×64 偏置:1×1×64	36 928
9	激活	激活函数:ReLU	95×45×64		0
10	池化	池化类型:最大池化 池化核大小:2×2 步幅:2×2	48×23×64		0
11	Dropout	比例:5%	48×23×64		0
12	卷积	卷积核大小:3×3 卷积核数量:128 步幅:1×1	46×21×128	权重:3×3×64×128 偏置:1×1×128	73 856
13	激活	激活函数:ReLU	46×21×128		0
14	卷积	卷积核大小:3×3 卷积核数量:128 步幅:1×1	44×19×128	权重:3×3×128×128 偏置:1×1×128	147 584
15	激活	激活函数:ReLU	44×19×128		0
16	池化	池化类型:最大池化 池化核大小:2×2 步幅:2×2	22×10×128		0
17	Dropout	比例:5%	22×10×128		0
18	全连接	神经元数量:2 048	1×1×2 048	权重:2 048×28 160 偏置:2 048×1	57 673 728
19	激活	激活函数:ReLU	1×1×2 048		0
20	Dropout	比例:5%	1×1×2 048		0
21	全连接	神经元数量:512	1×1×512	权重:512×2 048 偏置:512×1	1 049 088
22	激活	激活函数:ReLU	1×1×512		0
23	Dropout	比例:25%	1×1×512		0
24	全连接	神经元数量:37	1×1×37	权重:37×512 偏置:37×1	18 981
25	激活	激活函数:Softmax	1×1×37		0
26	分类输出		1×1×37		0

为 1×10^{-6} ,每次参数更新后学习率衰减值为0。

训练过程中,随机抽取20%样本作为验证样

本,剩余80%样本作为训练样本,共计训练10轮次,每次送入神经网络训练的样本数量为100。训练环

境为 keras+tensorflow。工作站配置方面,处理器为 Intel Xeon E5-2673 v312C/24T 2.40 GHz,内存为 64 G 2 400 MHz DDR4 ECC。

分析 OWDNet 性能随着训练轮次的变化结果(图4)可以看出,第1轮次训练完成后,模型训练准确率和验证准确率分别为 78.6% 和 94.9%,二者存在较大差距,说明训练还不充分。第2轮次训练完成后,训练准确率和验证准确率均超过 97.0%,说明模型具有良好的快速收敛能力。第3轮次之后,模型准确率呈现缓慢上升的趋势,至第10轮次结束,训练准确率达 99.7%,验证准确率达 98.9%。两类准确率之间的差异没有出现大幅增加的现象,说明模型没有出现拟合,训练效果理想。模型训练损失值和验证损失值随训练轮次的变化趋势基本相同,进一步说明训练效果理想。

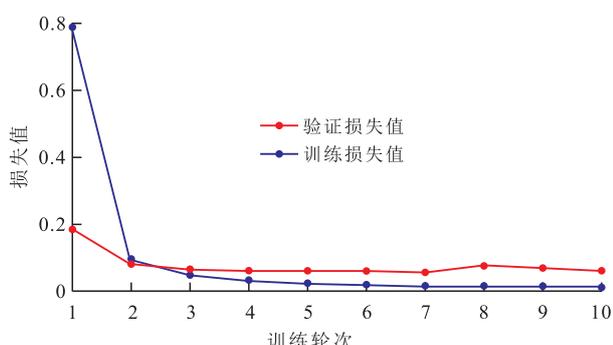
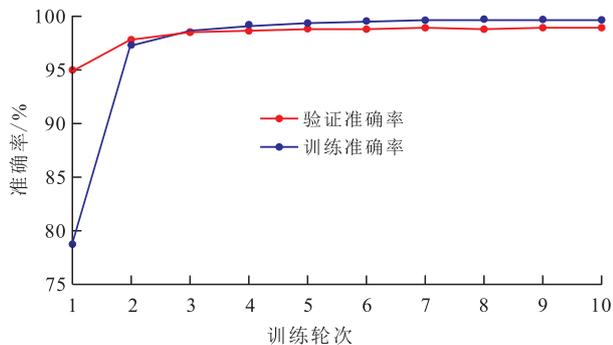


图4 OWDNet性能随着训练轮次的变化曲线

Fig.4 Variation of OWDNet performance with epochs

在当前训练环境下,OWDNet单轮次训练平均耗时为 7 077.6 s,训练完成后以 H5 文件格式存储的神经网络模型大小为 572 MB,从训练耗时和模型空间占用上均能够满足油田现场部署需要。

3.2 矿场应用

在训练完成的 OWDNet 基础上,开展油井工况智能诊断系统的设计和开发,系统架构如图5所示。该系统包含 2 个工作流程:①工况诊断流程。油井传感器数据不断传入油田数据库,部署在工况诊断

服务器上的后台程序会持续向油田数据库发送请求,抓取最新的油井监测数据。数据接收后进行预处理,绘制标准化示功图,再传入已训练的 OWDNet 中进行工况分类,分类结果写入工况诊断数据库。油田管控人员通过图形化的工况诊断客户端查看工况诊断结果,并进行相应的油井管控。②持续学习流程。当油田管控人员发现误诊后,通过工况诊断客户端进行修正,修正数据会更新到工况诊断数据库。当修正数据积累到一定数量时,利用新产生的数据样本对 OWDNet 进行追加训练,实现 OWDNet 的持续升级。

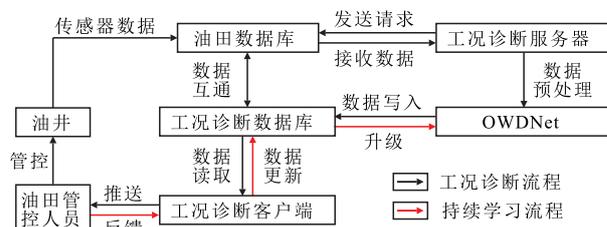


图5 油井工况智能诊断系统架构

Fig.5 Architecture of intelligent working condition diagnosis system for oil wells

截至 2021 年 10 月,油井工况智能诊断系统已完成 500 余万次工况诊断,现场工况诊断准确率达到 90%,从监测数据进入油田数据库到油井工况智能诊断系统完成诊断推送报警平均耗时约为 2 min,有效提升了异常井的发现和处置效率,油井生产管控更加合理,油井运行工况持续改善,连续稳定生产井比例由 68% 上升到 88%,为油田安全高效生产和提高采收率提供了有力支撑。借助精准的油井工况诊断,节省了大量巡检、监控时间,使油田管控人员从简单繁杂的监控工作中解脱出来,将更多的精力投入到运行管理和异常处置等更高级的智能工作中。

4 结论

基于 S 油田信息化建设成果,抓取了涵盖高含水整装、低渗透和稠油等多种油藏类型 1 930 口油井的示功图相关数据 4 000 余万组,设计了用于工况诊断的叠加示功图绘制规范并完成了绘制。结合现场专家经验及示功图的形状特点,总结梳理常见工况类型 5 大类 37 种。提出了迭代式标注策略,有效降低了样本标注所花费的人工时间,构建了包含 15 万余组示功图的工况诊断样本集。

结合油井工况诊断问题特点,对比了传统机器学习算法和深度学习算法的适用性,从常用深度学

习算法中选择了卷积神经网络,开展了网络架构的个性化设计,构建了包含26层5 900余万个可学习参数的OWDNet。设定合理的学习参数后,使用工况诊断样本集对OWDNet进行训练,10轮次训练后训练准确率达99.7%,验证准确率达98.9%。在此基础上,开发了油井工况智能诊断系统,并已在现场完成500余万次工况诊断,工况诊断准确率高达90%,报警推送及时,借助该系统开展油井生产管控更加合理高效,油井运行工况持续改善,产量提升,也为油田安全高效生产和提高采收率提供了有力支撑,为油田大数据的高价值应用提供了有益示范。

未来围绕如何进一步扩充油井工况诊断样本库,更好地解决样本分布不均匀的问题,以及引入更多的油井动态监测指标,如电流、压力、产量等,实现更精准更广泛的油井问题诊断,还有待于进一步探索。

符号解释

- a_k ——第 k 个样本的输出值;
 C ——交叉熵损失函数;
 i, j ——神经元编号;
 J ——神经网络层神经元总数;
 k ——样本编号;
 n ——样本总数;
 $relu_i(x)$ ——ReLU激活函数;
 $softmax_i(x)$ ——Softmax激活函数;
 W ——位移向量;
 x ——神经网络层中各神经元参数组成的向量;
 x_i, x_j ——第 i 个和第 j 个神经元参数;
 y ——标签值;
 y_k ——第 k 个样本的标签值;
 Z ——载荷向量。

参考文献

- [1] 雷群,翁定为,罗健辉,等.中国石油油气开采工程技术进展与发展方向[J].石油勘探与开发,2019,46(1):139-145.
 LEI Qun, WENG Dingwei, LUO Jianhui, et al. Achievements and future work of oil and gas production engineering of CNPC[J]. Petroleum Exploration and Development, 2019, 46(1): 139-145.
- [2] NGUYEN T. Artificial lift methods: design, practices, and applications[M]. Cham: Springer Nature, 2020.
- [3] TECLE S I, ZIUZEV A. A review on sucker rod pump monitoring and diagnostic system[C]. Russia: 2019 IEEE Russian Workshop on Power Engineering and Automation of Metallurgy Industry: Research & Practice(PEAMI), 2019.
- [4] WANG Z, WANG X, DUAN W, et al. Well production real-time intelligent monitoring based on convolutional neural network[J]. Improved Oil and Gas Recovery, 2019, 3: 1-9.
- [5] 刘合,郝忠献,王连刚,等.人工举升技术现状与发展趋势[J].石油学报,2015,36(11):1 441-1 448.
 LIU He, HAO Zhongxian, WANG Liangang, et al. Current technical status and development trend of artificial lift[J]. Acta Petrolei Sinica, 2015, 36(11): 1 441-1 448.
- [6] WANG Xiang, HE Yanfeng, LI Fajun, 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.
- [7] 梁文福.油田开发智能应用系统建设成果及展望[J].大庆石油地质与开发,2019,38(5):283-289.
 LIANG Wenfu. Constructed achievements and prospects of the intelligent application system for the oilfield development[J]. Petroleum Geology & Oilfield Development in Daqing, 2019, 38(5): 283-289.
- [8] 葛静涛,姚荣昌,马继胜.延川南煤层气井无损智能间抽技术研究[J].油气藏评价与开发,2020,10(4):97-100.
 GE Jingtao, YAO Rongchang, MA Jisheng. Research on non-destructive intelligent inter-pumping technology for CBM wells in South Yanchuan Block [J]. Reservoir Evaluation and Development, 2020, 10(4): 97-100.
- [9] 刘巍,刘威,谷建伟,等.利用卡尔曼滤波和人工神经网络相结合的油藏井间连通性研究[J].油气地质与采收率,2020,27(2):118-124.
 LIU Wei, LIU Wei, GU Jianwei, et al. Research on interwell connectivity of oil reservoirs based on Kalman filter and artificial neural network [J]. Petroleum Geology and Recovery Efficiency, 2020, 27(2): 118-124.
- [10] 钟峥.基于粗糙集的石油开采故障诊断方法[J].制造业自动化,2012,34(8):56-58.
 ZHONG Zheng. Fault diagnosis method based on rough set oil exploration[J]. Manufacturing Automation, 2012, 34(8): 56-58.
- [11] 曲文尧,王春华.人工神经网络法用于抽油机井故障诊断[J].油气田地面工程,2013,32(8):14-15.
 QU Wenyao, WANG Chunhua. Artificial neural network method for fault diagnosis of pumping wells[J]. Oil-Gasfield Surface Engineering, 2013, 32(8): 14-15.
- [12] 刘卓,罗明良,陆雪皎,等.有杆抽油系统工况诊断的数学模型研究[J].数学的实践与认识,2013,43(15):41-48.
 LIU Zhuo, LUO Mingliang, LU Xuejiao, et al. Study on the working condition diagnosis method for suck rod pumping system based on wavelet moment features [J]. Mathematics in Practice and Theory, 2013, 43(15): 41-48.
- [13] 郭健.基于特征值提取与神经网络的抽油井故障诊断[J].电子设计工程,2014,22(2):41-43.
 GUO Jian. Fault diagnosis of pumping well based on the eigenvalue extraction and neural network [J]. Electronic Design Engineering, 2014, 22(2): 41-43.
- [14] 苏志伟.极限学习机算法的改进及其在抽油机井中的应用研究[D].杭州:中国计量学院,2014.
 SU Zhiwei. Improvement of extreme learning machine algorithm and its application research in pumping well [D]. Hangzhou: China University of Metrology, 2014.

- na Jiliang University, 2014.
- [15] 仲志丹,李鹏辉,郭苗苗,等.石油生产中有杆抽油机故障诊断研究[J].计算机仿真,2016,33(2):443-447.
ZHONG Zhidan, LI Penghui, GUO Miaomiao, et al. Study on rod pumping unit fault diagnosis in oil production[J]. Computer Simulation, 2016, 33(2): 443-447.
- [16] 仲志丹,赵斐,李鹏辉.深度信念网在油井功图识别中的应用[J].西安石油大学学报:自然科学版,2017,32(3):89-93.
ZHONG Zhidan, ZHAO Fei, LI Penghui. Application of deep belief network in identification of indicator diagram types [J]. Journal of Xi'an Shiyou University: Natural Science, 2017, 32(3): 89-93.
- [17] 仲志丹,樊浩杰,李鹏辉.CNN-SVM模型在抽油机井故障诊断中的应用[J].河南理工大学学报:自然科学版,2018,37(4):112-117.
ZHONG Zhidan, FAN Haojie, LI Penghui. Application of CNN-SVM model in fault diagnosis of pumping well [J]. Journal of Henan Polytechnic University: Natural Science, 2018, 37(4): 112-117.
- [18] 段友祥,李钰,孙歧峰,等.改进的 Alexnet 模型及在油井示功图分类中的应用[J].计算机应用与软件,2018,35(7):226-230,272.
DUAN Youxiang, LI Yu, SUN Qifeng, et al. Improved Alexnet model and using in dynamometer card classification [J]. Computer Applications and Software, 2018, 35(7): 226-230, 272.
- [19] 刘宝军.基于 CNN 卷积神经网络的示功图诊断技术[J].西安石油大学学报:自然科学版,2018,33(5):70-75,82.
LIU Baojun. Research on diagnostic technique of indicator diagram based on CNN convolution neural network [J]. Journal of Xi'an Shiyou University: Natural Science, 2018, 33(5): 70-75, 82.
- [20] 孙婷婷,韩雪,梁华庆.基于 LIBSVM 的融合傅里叶幅值与相位的示功图识别方法[J].计算机测量与控制,2018,26(10):240-245.
SUN Tingting, HAN Xue, LIANG Huaqing. An identification method of indicator diagram based on LIBSVM fusion fourier amplitude and phase information [J]. Computer Measurement & Control, 2018, 26(10): 240-245.
- [21] 仲志丹,樊浩杰,李鹏辉.基于稀疏自编码神经网络的抽油机井故障诊断[J].西安科技大学学报,2018,38(4):669-675.
ZHONG Zhidan, FAN Haojie, LI Penghui. Fault diagnosis of pumping well based on sparse auto-encoder neural network [J]. Journal of Xi'an University of Science and Technology, 2018, 38(4): 669-675.
- [22] 侯延彬,陈炳均,高宪文.基于 GM-ELM 的有杆泵抽油井故障诊断[J].东北大学学报:自然科学版,2019,40(12):1673-1678.
HOU Yanbin, CHEN Bingjun, GAO Xianwen. Fault diagnosis of sucker rod pumping wells based on GM-ELM [J]. Journal of Northeastern University: Natural Science, 2019, 40(12): 1673-1678.
- [23] 樊浩杰.基于人工智能算法的示功图智能识别研究[D].洛阳:河南科技大学,2019.
- FAN Haojie. Research on intelligent recognition of indicator diagram based on artificial intelligence algorithm [D]. Luoyang: Henan University of Science and Technology, 2019.
- [24] 王万庆.卷积神经网络在 PCS 系统辅助诊断油井示功图的研究[J].内蒙古石油化工,2019,45(2):28-30.
WANG Wanqing. Study on Indicator Diagram of oil wells auxiliary diagnosis in PCS system with convolutional neural network [J]. Inner Mongolia Petrochemical Industry, 2019, 45(2): 28-30.
- [25] 何岩峰,刘成,王相.改良的 AlexNet 模型在有杆泵故障诊断中的应用[J].工业安全与环保,2020,46(7):22-26.
HE Yanfeng, LIU Cheng, WANG Xiang. Fault diagnosis of rod pump working conditions based on improved indicator AlexNet model [J]. Industrial Safety and Environmental Protection, 2020, 46(7): 22-26.
- [26] 杜娟,刘志刚,宋考平,等.基于卷积神经网络的抽油机故障诊断[J].电子科技大学学报,2020,49(5):751-757.
DU Juan, LIU Zhigang, SONG Kaoping, et al. Fault diagnosis of pumping unit based on convolutional neural network [J]. Journal of University of Electronic Science and Technology of China, 2020, 49(5): 751-757.
- [27] 宋纯贺,李泽熙,于洪霞,等.一种基于改进 GoogLeNet 的油井故障识别方法[J].江苏科技大学学报:自然科学版,2021,35(2):52-58.
SONG Chunhe, LI Zexi, YU Hongxia, et al. An oil well fault identification method based on improved GoogLeNet [J]. Journal of Jiangsu University of Science and Technology: Natural Science Edition, 2021, 35(2): 52-58.
- [28] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. Nature, 2015, 521: 436-444.
- [29] SCHMIDHUBER J. Deep learning in neural networks: An overview [J]. Neural Networks, 2015, 61: 85-117.
- [30] 吴君达,李治平,孙妍,等.基于神经网络的剩余油分布预测及注采参数优化[J].油气地质与采收率,2020,27(4):85-93.
WU Junda, LI Zhiping, SUN Yan, et al. Neural network-based prediction of remaining oil distribution and optimization of injection-production parameters [J]. Petroleum Geology and Recovery Efficiency, 2020, 27(4): 85-93.
- [31] 谷建伟,周梅,李志涛,等.基于数据挖掘的长短期记忆网络模型油井产量预测方法[J].特种油气藏,2019,26(2):77-81,131.
GU Jianwei, ZHOU Mei, LI Zhitao, et al. Oil well production forecast with long-short term memory network model based on data mining [J]. Special Oil & Gas Reservoirs, 2019, 26(2): 77-81, 131.
- [32] BALDI P, SADOWSKI P J. Understanding dropout [J]. Advances in Neural Information Processing Systems, 2013, 26: 2814-2822.
- [33] BOTTOU L, CURTIS F E, NOCEDAL J. Optimization methods for large-scale machine learning [J]. Siam Review, 2018, 60(2): 223-311.