

◀油气开发▶

doi:10.11911/syztjs.2019093

# 基于人工智能的抽油机井结蜡预警方法

邴绍强

(中国石化胜利油田分公司信息化管理中心, 山东东营 257000)

**摘 要:** 针对依靠现场经验确定的清蜡周期不准确而导致蜡卡躺井的问题, 开展了基于人工智能的抽油机井结蜡预警方法研究。利用皮尔逊相关系数分析方法, 分析了 17 项油井自动采集参数与结蜡程度的关联性, 确定了 7 项主控参数, 创建了结蜡预警规则模型; 将 7 项主控参数的合并指标进行归一化处理得到结蜡综合特征指标 (WPSC), 并利用结蜡预警规则模型产生的样本数据建立了结蜡井 WPSC 样本集, 选用长短时记忆神经网络 (LSTM) 对样本集进行训练, 得到了 WPSC 机器学习模型, 用其可以定量预测抽油机井的结蜡程度。该方法在胜利油田桩 23 区块的现场应用结果表明, 油井清蜡周期得到延长, 且有效避免了蜡卡躺井。研究结果表明, 基于人工智能的抽油机井结蜡预警方法实现了油井结蜡程度的定量化预测与预警, 对精准确定清蜡时机具有较好的指导作用。

**关键词:** 油井结蜡; 清蜡周期; 规则模型; 机器学习; 人工智能; 预测预警; 胜利油田

**中图分类号:** TE358<sup>+</sup>.2      **文献标志码:** A      **文章编号:** 1001-0890(2019)04-0097-07

## An Early Warning Method Based on Artificial Intelligence for Wax Deposition in Rod Pumping Wells

BING Shaoqiang

(Information Management Center of Sinopec Shengli Oilfield Company, Dongying, Shandong, 257000, China)

**Abstract:** The timing of wax clearance is usually determined in the field by observations, which is inaccurate and may cause wells to fail due to wax locking. To solve this problem, a wax deposition early warning method based on artificial intelligence for rod pumping wells has been developed. The Pearson correlation coefficient analysis method is used to conduct correlation analysis between 17 points of data automatically acquired by oil well condition and degree of wax deposition, and seven main control parameters are determined. A wax deposition early warning rule protocol was established on this basis. The wax deposition synthetic characteristics (WPSC) index was obtained by normalizing the merged indexes of seven main control parameters, and the WPSC sample set of wells with paraffin problems was established by using the sample data generated by the wax deposition early warning rule model. Long-term and short-term memory (LSTM) neural networks were selected to train the sample set, and the machine learning model of WPSC is obtained, which could quantitatively predict the degree of wax deposition in the rod pumping wells. The field trial of this method in Block Zhuang 23 of the Shengli Oilfield showed that by using this method, the wax clearance timing as prolonged and the wax locking in failed wells was effectively avoided. Research results showed that the wax deposition early warning method based on artificial intelligence for rod pumping wells achieves quantitative prediction and provides effective early warning on the wax deposition degree in oil wells, and could be used as an effective guide in precise the selection of wax clearance timing.

**Key words:** wax deposition of oil well; wax clearance timing; rule model; machine learning; artificial intelligence; prediction and early warning; Shengli Oilfield

传统模式下, 针对易结蜡的有杆泵抽油井, 人们往往根据现场经验确定其清蜡周期, 受人工采集数据频率低、时间对应性不强等条件限制, 清蜡周期往往不准确, 易因井筒清蜡不及时而发生蜡卡躺井, 不仅降低了油井生产时率, 而且增加了油井作业维护费用和生产成本<sup>[1-3]</sup>。例如, 胜利油田桩 23 区块平均每年有 2 口井因清蜡周期不准确、井筒清蜡不及

时而发生蜡卡躺井。近年来, 随着油气生产物联网

收稿日期: 2019-01-21; 改回日期: 2019-07-05。

**作者简介:** 邴绍强 (1974—), 男, 山东莒县人, 1996 年毕业于石油大学 (华东) 采油工程专业, 2007 年获中国石油大学 (华东) 油气田开发专业硕士学位, 高级工程师, 主要从事信息自动化研究工作。E-mail: bingshaoqiang.slyt@sinopec.com。

**基金项目:** 中国石化科技攻关项目“勘探开发智能化关键技术研究” (编号: P14130) 部分研究内容。

建设的不断推进,抽油机井悬点载荷与位移、井口温度、回压、电参数等逐步实现了自动实时采集<sup>[4]</sup>,为人工智能技术的应用提供了大量的数据支持,因而国内外开展了利用人工智能预测油井结蜡工况的研究:段友祥等人<sup>[5-8]</sup>利用人工智能的分类算法,建立了异常工况诊断模型,对油井的结蜡工况进行识别;A. K. Manshad 等人<sup>[9-10]</sup>利用人工智能预测算法,建立了储层流体结蜡量预测模型。上述方法均难以实现抽油机井结蜡及清蜡周期的定量化预测及预警,为此,笔者利用人工智能预测算法,结合大数据挖掘技术<sup>[11-13]</sup>,通过研究抽油机井生产数据变化规律与结蜡程度的定量关系,建立了结蜡程度预测预警模型,可实时预测油井结蜡程度并超前预警,从而帮助人们合理选择清蜡时机,尽可能避免蜡卡躺井,实现了抽油机井清蜡时机由传统的业务驱动向数据驱动的转变。

## 1 应用人工智能预测抽油机井结蜡的技术思路

近年来,随着智能传感器、物联网等技术的快速发展和大规模应用,工业生产逐步进入大数据时代,工业大数据的产生促进了新一代人工智能技术在工业领域的应用,拓展了利用人工智能解决问题的深度和广度<sup>[14]</sup>。新一代人工智能技术在油田的应用越来越广泛<sup>[15-18]</sup>,已在储层识别、油藏动态分析、油水井工况诊断等方面取得了较好的应用成果。深度学习和知识工程是新一代人工智能技术在工业领域应用的2大技术,在工业领域应用中有相互融合的趋势,从而提高了结果的可靠性和可解释性。新一代人工智能技术用于抽油机井结蜡预测和预警的技术思路为:将数据挖掘技术与专业知识结合,识别抽油机井结蜡预警的主控参数,建立结蜡预警规则模型,实现结蜡井的有效识别,并建立结蜡井样本库;在此基础上,将归一化处理后的结蜡预警主控参数作为输入变量,应用长短时记忆深度学习算法,建立结蜡程度人工智能预测模型,利用大量样本数据对所建模型进行训练,利用训练后的模型可以定量预测抽油机井的结蜡程度,从而确定清蜡时机,辅助技术人员及时采取清蜡措施,避免蜡卡躺井。

## 2 抽油机井结蜡预警规则模型的建立

抽油机井结蜡是一个渐变的过程,在分析结蜡

井生产参数变化规律的基础上,可以确定其主控参数,结合采油专业知识和专家经验,建立油井结蜡预警规则模型,自动识别有结蜡趋势的抽油机井,为结蜡程度人工智能预测模型提供学习样本,同时为预测模型提供输入的自变量数据。

### 2.1 结蜡预测主控参数的优选

收集了胜利油田2015—2017年300口典型结蜡井的生产参数,包括采取清蜡措施或蜡卡躺井前后地面示功图的相关参数(上行电流、下行电流、最大载荷、最小载荷、载荷差和功图面积)、井口生产参数(井口回压、井口套压和井口温度)和电参数(A项电流、A项平均电流、耗电量、AB项电压、功率因数、无功功率、周期内有功功率平均值和周期内无功功率平均值)等17项自动采集处理参数,作为属性数据。其中,地面示功图相关数据的采集频率为1次/30min,其他数据的采集频率为1次/min。利用皮尔逊相关系数分析方法,对收集的结蜡井属性数据,逐口井进行两两之间的相关性分析,从而确定结蜡预警的主控参数。

皮尔逊相关系数也称为皮尔逊积矩相关系数(Pearson product-moment correlation coefficient),是一种线性相关系数,记为 $r$ ,用来反映两个变量 $X$ 和 $Y$ 的线性相关程度, $r$ 值介于 $-1\sim 1$ 之间,其绝对值越大表明相关性越强。 $r$ 的计算公式为:

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (1)$$

$r$ 还可以由 $(X_i, Y_i)$ 样本点的标准分数均值估计得到与式(1)等价的表达式:

$$r = \frac{1}{n-1} \sum_{i=1}^n \left( \frac{X_i - \bar{X}}{\sigma_X} \right) \left( \frac{Y_i - \bar{Y}}{\sigma_Y} \right) \quad (2)$$

式中: $\frac{X_i - \bar{X}}{\sigma_X}$ 和 $\frac{Y_i - \bar{Y}}{\sigma_Y}$ 分别为 $X_i$ 和 $Y_i$ 样本的标准分数; $\bar{X}$ 和 $\bar{Y}$ 分别为 $X_i$ 和 $Y_i$ 样本的平均值; $\sigma_X$ 和 $\sigma_Y$ 分别为 $X_i$ 和 $Y_i$ 样本的标准差; $n$ 为样本数量; $i$ 为样本点的序号。

将每口结蜡井17项属性数据两两之间的皮尔逊相关系数进行平均,分析300口典型结蜡井属性数据的相关性,结果见表1。由表1可知,最大载荷、最小载荷、载荷差、功图面积、上行电流、A项平均电流、周期内有功功率平均值等7项参数相关性系数的绝对值大于0.9,与井筒结蜡密切相关。其

表 1 300 口典型结蜡井属性数据相关性分析结果

Table 1 Correlation analysis of attribute data of 300 typical paraffin troubled wells

属性	相关系数																
	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10	Z1	Z2	Z3	Z4	J1	J2	J3
D1	1.000	-0.875	0.872	0.983	0.89	0.213	-0.819	0.975	0.898	0.879	0.955	-0.963	0.982	0.919	0.241	0.016	0.167
D2	-0.875	1.000	-0.762	-0.602	0.835	0.192	-0.824	-0.819	0.773	0.878	-0.829	0.821	-0.896	-0.748	0.169	0.071	0.172
D3	0.872	-0.762	1.000	0.886	0.891	0.663	-0.838	0.837	0.861	0.859	0.819	-0.823	0.869	0.804	0.321	0.021	0.116
D4	0.983	-0.602	0.886	1.000	0.892	0.812	-0.826	0.915	0.873	0.843	0.912	-0.917	0.962	0.943	0.371	0.018	0.132
D5	0.890	0.835	0.891	0.892	1.000	0.289	0.296	0.865	0.832	0.867	0.893	0.712	0.871	0.861	0.126	0.031	0.128
D6	0.213	0.192	0.663	0.812	0.289	1.000	0.278	0.263	0.389	0.363	0.219	0.132	0.267	0.389	0.131	0.021	0.127
D7	-0.819	-0.824	-0.838	-0.826	0.296	0.278	1.000	0.302	-0.886	-0.872	-0.761	-0.781	-0.769	-0.732	0.191	0.032	0.139
D8	0.975	-0.819	0.837	0.915	0.865	0.263	0.302	1.000	0.832	0.859	0.972	-0.959	0.971	0.929	0.221	0.036	0.137
D9	0.898	0.773	0.861	0.873	0.832	0.389	-0.886	0.832	1.000	0.886	0.781	0.486	0.792	0.625	0.132	0.042	0.069
D10	0.879	0.878	0.859	0.843	0.867	0.363	-0.872	0.859	0.886	1.000	0.812	0.638	0.831	0.781	0.256	0.062	0.136
Z1	0.955	-0.829	0.819	0.912	0.893	0.219	-0.761	0.972	0.781	0.812	1.000	-0.992	0.996	0.965	0.269	0.026	0.113
Z2	-0.963	0.821	-0.823	-0.917	0.712	0.132	-0.781	-0.959	0.486	0.638	-0.992	1.000	-0.986	-0.958	0.189	0.032	0.142
Z3	0.982	-0.896	0.869	0.962	0.871	0.267	-0.769	0.971	0.792	0.831	0.996	-0.986	1.000	0.993	0.306	0.019	0.201
Z4	0.919	-0.748	0.804	0.943	0.861	0.389	-0.732	0.929	0.625	0.781	0.965	-0.958	0.993	1.000	0.025	0.066	0.139
J1	0.241	0.169	0.321	0.371	0.126	0.131	0.191	0.221	0.132	0.256	0.269	0.189	0.306	0.025	1.000	0.021	0.136
J2	0.016	0.071	0.021	0.018	0.031	0.021	0.032	0.036	0.042	0.062	0.026	0.032	0.019	0.066	0.021	1.000	0.132
J3	0.167	0.172	0.116	0.132	0.128	0.127	0.139	0.137	0.069	0.136	0.113	0.142	0.201	0.139	0.136	0.132	1.000

注: D1为上行电流; D2为下行电流; D3为A项电流; D4为A项平均电流; D5为耗电量; D6为AB项电压; D7为功率因数; D8为周期内有功率平均值; D9为无功功率; D10为周期内无功功率平均值; Z1为最大载荷; Z2为最小载荷; Z3为载荷差; Z4为功图面积; J1为井口回压; J2为井口套压; J3为井口温度。

中, 最小载荷负相关, 其余参数正相关。综合典型结蜡井属性数据相关性分析结果, 将这 7 项参数作为预测油井结蜡程度的主控参数。

### 2.2 结蜡预警规则模型的建立

在相关性分析的基础上, 结合专业知识和实践经验, 总结提炼结蜡井预警主控参数的变化规律, 建立结蜡预警规则模型。

用上升趋势、持续上升、超上限、稳定区间、下降趋势等规则定义指标变化趋势, 用趋势连续变化时间、变化速率阈值以及载荷差阈值、冲次稳定区间阈值等规则定义趋势变化程度, 将 7 项结蜡主控参数的变化规则进行组合, 建立结蜡预警规则模

型。受泵型、泵挂深度、原油黏度、含水、结蜡程度等参数的影响, 不同油井指标的变化趋势和趋势变化程度等规则不同, 需要结合油井的实际井况进行“一井一策”的规则设置。该结蜡预警规则模型融合了业务机理和专家经验, 能够量化表征结蜡主控参数的变化规律, 对结蜡井进行实时、定性预警提示, 其运行示意图见图 1。在实际应用时, 现场采集的实时生产数据自动加载至计算机, 按照预警规则模型设定的规则, 利用计算引擎进行数据变化趋势拟合和趋势变化程度阈值判断, 若符合模型设定规则, 则给出结蜡预警提示信息, 技术人员对预警信息准确性进行分析判断, 准确的预警信息进入结蜡井样本库。

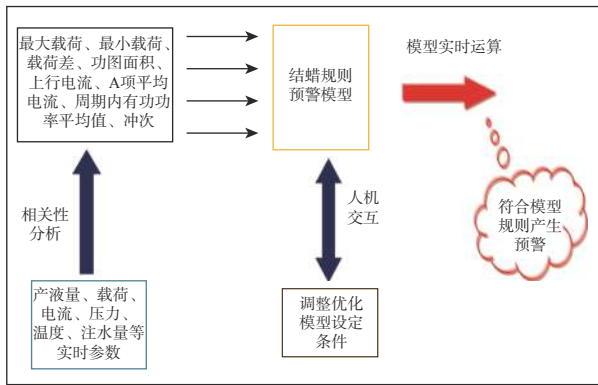


图 1 结蜡预警规则模型运行示意

Fig.1 Operation schematic diagram of wax deposition early warning rule model

以 HJH82-X11 井为例, 创建的结蜡预警规则模型共包括 11 项规则(见图 2), 分别为最大载荷上升

速率阈值 0.2、最小载荷下降速率阈值 0.2、载荷差上升速率阈值 0.3、功图面积上升速率阈值 0.1、上行电流上升速率阈值 0.1、A 项平均电流上升速率阈值 0.1、周期内有功功率平均值上升速率阈值 0.1; 根据该井杆管泵组合, 经计算和分析, 设定最大载荷上限阈值为 40 kN、载荷差值上限阈值为 5 kN; 为消除调整参数的影响, 增加了冲次稳定的条件, 稳定区间阈值 0.2。在该井工作制度不变的情况下, 利用该模型可定性预警油井结蜡。

### 3 抽油机井结蜡机器学习模型的建立

对结蜡预警主控参数值进行加权处理, 建立一项反映结蜡程度的综合特征指标, 采用神经网络建立结蜡综合特征指标预测模型, 利用结蜡规则

结蜡预警规则模型	<p>【HJH82-X11】: 30 min的【最大载荷】上升趋势, 时间跨度为15 d, 变化速度阈值为0.2;</p> <p>【HJH82-X11】: 30 min的【最小载荷】下降趋势, 时间跨度为15 d, 变化速度阈值为0.2;</p> <p>【HJH82-X11】: 30 min的【载荷差值】上升趋势, 时间跨度为15 d, 变化速度阈值为0.3;</p> <p>【HJH82-X11】: 30 min的【载荷差值】超上限, 时间跨度为1 d, 阈值为40 kN, 符合率为90%;</p> <p>【HJH82-X11】: 30 min的【载荷差值】差值上限, 时间跨度为2 h, 阈值为5;</p> <p>【HJH82-X11】: 30 min的【功图面积】上升趋势, 时间跨度为1 d, 变化速度阈值为0.1;</p> <p>【HJH82-X11】: 30 min的【功图面积】持续上升, 时间跨度为2 d;</p> <p>【HJH82-X11】: 30 min的【上行电流】上升趋势, 时间跨度为15 d, 变化速度阈值为0.1;</p> <p>【HJH82-X11】: 1 min的【A相平均电流】上升趋势, 时间跨度为15 d, 变化速度阈值为0.1;</p> <p>【HJH82-X11】: 1 min的【周期总有功平均值】上升趋势, 时间跨度为15 d, 变化速度阈值为0.1;</p> <p>【HJH82-X11】: 30 min的【冲次】稳定区间, 时间跨度为15 d, 阈值为0.2;</p>
----------	---

图 2 HJH82-X11 井结蜡预警规则模型

Fig.2 Wax deposition early warning rule model of Well HJH82-X11

模型产生的结蜡井样本数据对该模型进行训练, 利用训练后的模型可以预测油井结蜡综合特征指标, 从而精确定清蜡时机。

#### 3.1 结蜡综合特征指标的建立

为定量描述油井结蜡程度与生产数据之间的关系, 利用主成分分析方法(PCA), 计算最大载荷、最

小载荷、载荷差、功图面积、上行电流、A 项平均电流、周期内有功功率平均值等 7 个结蜡预警主控参数的权重。

PCA 方法采用方差度量信息量, 样本集合为  $\{x_j = [X_{1j}, X_{2j}, \dots, X_{nj}]^T \quad 1 \leq j \leq m\}$ ,  $m$  为样本数量,  $n$  为参数数量, 所有样本可以表示成一个  $n \times m$  的矩阵, 对应的协方差矩阵  $A$  为:

$$A = \frac{1}{m-1} \begin{bmatrix} \sum_{j=1}^m (x_{1j} - \bar{x}_1)(x_{1j} - \bar{x}_1) & \sum_{j=1}^m (x_{1j} - \bar{x}_1)(x_{2j} - \bar{x}_2) & \dots & \sum_{j=1}^m (x_{1j} - \bar{x}_1)(x_{nj} - \bar{x}_n) \\ \sum_{j=1}^m (x_{2j} - \bar{x}_2)(x_{1j} - \bar{x}_1) & \sum_{j=1}^m (x_{2j} - \bar{x}_2)(x_{2j} - \bar{x}_2) & \dots & \sum_{j=1}^m (x_{2j} - \bar{x}_2)(x_{nj} - \bar{x}_n) \\ \vdots & \vdots & \ddots & \vdots \\ \sum_{j=1}^m (x_{nj} - \bar{x}_n)(x_{1j} - \bar{x}_1) & \sum_{j=1}^m (x_{nj} - \bar{x}_n)(x_{2j} - \bar{x}_2) & \dots & \sum_{j=1}^m (x_{nj} - \bar{x}_n)(x_{nj} - \bar{x}_n) \end{bmatrix} \quad (3)$$

式中:  $x$  为样本属性值; 下标  $i$  为属性索引 ( $i=1, 2, \dots, n$ ), 下标  $j$  为样本索引 ( $j=1, 2, \dots, m$ );  $x_{ij}$  为第

$j$  个样本的第  $i$  个属性对应的数据。

利用收集整理的 300 口结蜡样本井的 7 项参

$$B = \begin{bmatrix} 0.147 & -0.033 & 0.18 & 0.381 & -0.002 & 0.015 & 0.011 \\ -0.033 & 0.085 & -0.118 & -0.247 & -0.015 & -0.009 & -0.021 \\ 0.180 & -0.118 & 0.297 & 0.628 & 0.013 & 0.023 & 0.032 \\ 0.381 & -0.247 & 0.628 & 1.570 & 0.043 & 0.059 & 0.108 \\ -0.002 & -0.015 & 0.013 & 0.043 & 0.071 & 0.001 & 0.007 \\ 0.015 & -0.009 & 0.023 & 0.059 & 0.001 & 0.002 & 0.004 \\ 0.011 & -0.021 & 0.032 & 0.108 & 0.007 & 0.004 & 0.095 \end{bmatrix} \quad (4)$$

将协方差矩阵进行对角化处理, 得到协方差矩阵的特征值, 即为各项参数的权重: 载荷差、最小载荷、最大载荷、功图面积、上行电流、A 项平均电流和周期内有功率平均值的权重分别为 0.887 0, -0.143 8, 0.224 1, 0.367 9, 0.093 2, 0.060 3 和 0.053 8。将 7 项结蜡主控参数的权重进行加权计算得到一个合并指标(即 7 项结蜡主控参数的权重分别与其参数值相乘后相加), 进行归一化处理得到一个能够反映结蜡程度的结蜡综合特征指标(WPSC), 该指标介于 0~1 之间, 越接近 1 蜡卡躺井风险越大。

对收集整理的 300 口结蜡井中, 120 口井蜡卡躺井前一个月的 WPSC 数值进行计算, 分析计算结果发现: 当结蜡井的 WPSC 数值约达到 0.950 后, WPSC 数值曲线变化率出现拐点, 上升速度明显加快, 3~5 d 后出现蜡卡躺井情况。因此, 在 WPSC 的数值约达到 0.950 后应立即采取清蜡措施, 以避免蜡卡躺井。以 GN24P102 井为例, 从该井躺井前一个月的 WPSC 数值可以看出(见图 3), 2016 年 11 月 2 日 15:30 时(即第 26 天)的 WPSC 数值为 0.946, 2016 年 11 月 6 日 10:25 时(即第 30 天)的 WPSC 数值快速升至 0.989, 该井发生蜡卡躺井。




图 3 GN24P102 井躺井前 30 d 的 WPSC 数值曲线

Fig. 3 WPSC numerical curve of 30 days before Well GN24P102 fails

对结蜡预警规则模型产生的样本数据进行计算处理, 建立结蜡井 WPSC 样本集, 作为人工智能预测模型的学习样本。

数, 建立  $7 \times 300$  的样本矩阵, 代入式(3), 计算得到结蜡样本井协方差矩阵  $B$  为:

### 3.2 结蜡综合特征指标机器学习模型的建立

针对油井生产数据及结蜡程度随时间变化的特征, 选用长短时记忆神经网络(LSTM), 建立 WPSC 机器学习模型。LSTM 是在通用循环神经网络(RNN)的基础上, 在各隐藏层神经单元中加入记忆单元, 实现时间序列上的记忆信息可控, 适合于处理和预测时间序列中间隔和延迟相对较长的重要事件<sup>[19-20]</sup>, 是一种基于深度学习的人工智能预测算法。

LSTM 的计算节点包括输入门、输出门、遗忘门和 Cell。其中 Cell 是 LSTM 计算节点的核心, 主要用于记录当前时刻状态, 计算公式为:

$$a_c(t) = \sum_i^I x_i(t)w_{ic} + \sum_h^H b_h(t-1)w_{hc} \quad (5)$$

式中:  $a_c$  为遗忘门;  $t$  为时间;  $I$  为输入门样本数量;  $i$  为输入门样本序号;  $x_i$  为输入门样本;  $w_{ic}$  为输入门权重;  $\sum_i^I x_i(t)w_{ic}$  为  $t$  时刻输入门的输入;  $H$  为遗忘门样本数量;  $h$  为遗忘门样本序号;  $b_h$  为遗忘门样本;  $w_{hc}$  为遗忘门权重;  $\sum_h^H b_h(t-1)w_{hc}$  为  $t-1$  时刻遗忘门的输入。

此外, 有:

$$s_c(t) = b_\phi(t) s_c(t-1) + b_l(t) g[a_c(t)] \quad (6)$$

式中:  $b_l(t)g[a_c(t)]$  为  $t$  时刻遗忘门与  $a_c(t)$  映射的乘积;  $b_\phi(t) s_c(t-1)$  为  $t$  时刻遗忘门与  $t-1$  时刻 Cell 状态输出的乘积;  $g(\cdot)$  为映射函数;  $s_c(t)$  为  $t$  时刻 Cell 的状态输出。

WPSC 机器学习模型建立及训练方法为:

1) 调用接口创建模型, 设置超参数。调用 Tensor Flow 上的接口创建 LSTM 模型, 设置预训练次数、激活函数、优化函数等超参数。

2) 根据模型结构, 建立测试集和训练集。按照 LSTM 模型结构, 提取结蜡样本集数据, 设置时间序列, 根据设定输入时间长度对样本数据进行分割处理, 创建结蜡井 WPSC 训练集和测试集, 其中每口样本井 80% 数据用于模型训练, 20% 数据用于模型测试。

3) 模型训练。利用训练集数据进行模型训练,

利用测试集数据进行模型预测精度评价,根据预测精度调整和优选超参数。Wpsc 机器学习模型选用 tanh 函数作为激活函数、Adam 函数作为优化函数,设定模型输入时间长度(样本输入时间步长)为 50 d,模型输出时间长度(模型输出时间步长)为 20 d。

4)模型发布。用测试集数据评价 Wpsc 机器学习模型的预测精度,当预测结果的均方根误差小于 0.01 时,模型训练完成,发布为正式预测模型。

利用发布的预测模型,预测结蜡井 Wpsc 随着时间的变化情况,指导技术人员精确把握油井结蜡趋势、发展程度和清蜡时机。当 Wpsc 值大于 0.95 时,结合油井现场情况及时采取清蜡措施,最大程度地提高油井生产效益。

### 4 现场应用效果

从 2017 年 7 月开始,基于人工智能的油井结蜡预警方法在胜利油田桩 23 区块进行了现场试验,截至 2018 年 12 月,该区块未出现蜡卡躺井问题。目前,该预警方法已经在胜利油田河口、现河等采油厂的 550 多口易结蜡抽油机井进行了推广应用,技术人员利用模型预测结果,超前把握结蜡趋势和程度,及时采取清蜡措施,累计 12 口井避免了蜡卡躺井,节约作业费用 100 多万元。下面以 H148 井为例,介绍该预警方法的现场应用情况。

该井在 2017 年 7 月 2 日—12 月 3 日生产期间,根据实测数据计算得到的 Wpsc 实际值从 0.4 逐步升至 0.8 以上,并筒有结蜡趋势。为此,应用 LSTM 建立该井的 Wpsc 预测模型,输入步长为 50 d,输出步长为 20 d,利用 7 月 2 日—9 月 30 日的 Wpsc 数据训练预测模型,训练好后预测 Wpsc 值,图 4 和图 5 分别为该井 10 月 20—11 月 8 日、11 月 9 日—28 日 Wpsc 计算值与预测值的对比曲线。从图 4 和图 5 可以看出,Wpsc 预测值与实际值基本吻合,Wpsc 实际值由 0.860 升至 0.936。11 月 29 日,该模型预测出该井 4 d 后的 Wpsc 值为 0.954 并且有继续增大的趋势(见图 6),系统发出清蜡预警,经过综合分析该井生产情况,于 12 月 3 日对该井实施热洗清蜡措施,实施后该井各项指标恢复正常,避免了蜡卡躺井的发生。

### 5 结论

1)通过皮尔逊相关系数分析方法对自动采集生

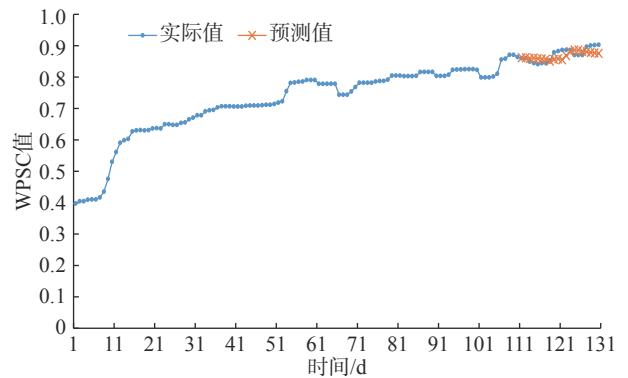


图 4 H148 井 Wpsc 实际值与预测值对比曲线(10月20日—11月8日)

Fig. 4 Correlation curve between actual and predicted values of Wpsc in Well H148 (October 20–November 8)




图 5 H148 井 Wpsc 实际值与预测值对比曲线(11月9日—28日)

Fig. 5 Correlation curve between actual and predicted values of Wpsc in Well H148 (November 9–28)




图 6 H148 井 Wpsc 预测值曲线

Fig. 6 Wpsc predictive value curve of Well H148

产数据进行关联性分析,确定了 7 项预测油井结蜡程度的主控参数,结合采油工程理论与实践经验,建立了结蜡预警规则模型。该模型能够对结蜡程度相关参数变化规律进行量化表征。

2)综合 7 项主控参数提出了结蜡综合特征指标

(WPSC), 利用结蜡预警规则模型产生的样本数据建立了结蜡井 WPSC 样本集, 选用长短时记忆神经网络(LSTM)对样本集进行训练得到了 WPSC 机器学习模型。

3) 现场应用效果表明, 基于人工智能的结蜡预警方法改变了传统的按周期进行热洗清蜡的管理模式, 实现了基于数据驱动的预测性管理、油井结蜡程度和清蜡时机的定量化预测及预警, 降低了生产成本, 提高了油井生产效益。

4) 基于人工智能的结蜡预警方法对于人工智能技术在油水井工况诊断及超前治理、油气生产设备预测性维护等方面的应用具有借鉴意义。

## 参 考 文 献

### References

- [ 1 ] 钟张起, 侯读杰, 王建飞, 等. 抽油机井结蜡定量化分析新技术[J]. 石油机械, 2014, 42(5): 68-71.  
ZHONG Zhangqi, HOU Doujie, WANG Jianfei, et al. Quantitative analysis of paraffining in rod pumped well[J]. *China Petroleum Machinery*, 2014, 42(5): 68-71.
- [ 2 ] 邢敦通, 张金元. 原油结蜡规律及清防蜡工艺的研究[J]. 石化技术, 2017, 24(2): 15-22.  
XING Duntong, ZHANG Jinyuan. Rules of wax deposit in crude oil and wax removal[J]. *Petrochemical Industry Technology*, 2017, 24(2): 15-22.
- [ 3 ] 宋君. 油井结蜡影响因素及防蜡技术研究[J]. 当代化工, 2015(1): 78-79, 82.  
SONG Jun. Research on factors influencing oil well paraffin deposit and paraffin control technology[J]. *Contemporary Chemical Industry*, 2015(1): 78-79, 82.
- [ 4 ] 郝世彦, 樊平天, 张新涛. 油井远程监控与计量技术在延长油田的应用[J]. 石油钻探技术, 2010, 38(2): 84-87.  
HAO Shiyan, FAN Pingtian, ZHANG Xintao. Application of remote well monitoring and measurement technique in Yanchang Oilfield[J]. *Petroleum Drilling Techniques*, 2010, 38(2): 84-87.
- [ 5 ] 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.
- [ 6 ] 焦春晶. 油井生产状态智能识别及辅助决策系统的研究[J]. 石油知识, 2019(2): 36-37.  
JIAO Chunjing. Research on intelligent recognition and assistant decision-making system of oil well production state[J]. *Petroleum Knowledge*, 2019(2): 36-37.
- [ 7 ] 张春琳, 唐道临, 孙成. 基于模式识别技术的油井工况诊断[J]. 现代计算机, 2018(27): 65-68, 100.  
ZHANG Chunlin, TANG Daolin, SUN Cheng. Diagnosis of oil well condition based on pattern recognition technology[J]. *Modern Computer*, 2018(27): 65-68, 100.
- [ 8 ] 赵可新, 马晓辉, 马彦芬, 等. 人工神经网络在油井故障诊断中的优化[J]. 煤炭技术, 2011, 30(5): 196-198.  
ZHAO Kexin, MA Xiaohui, MA Yanfen, et al. Optimization of ANN in fault diagnosis of oil wells[J]. *Coal Technology*, 2011, 30(5): 196-198.
- [ 9 ] MANSHAD A K, ROSTAMI H. Prediction of wax precipitation in crude oil systems using gaussian processes[J]. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 2015, 37(1): 84-91.
- [ 10 ] MANSHAD A K, ASHOORI S, MANSHAD M K, et al. The prediction of wax precipitation by neural network and genetic algorithm and comparison with a multisolid model in crude oil systems[J]. *Petroleum Science and Technology*, 2012, 30(13): 1369-1378.
- [ 11 ] 李华, 刘帅, 李茂, 等. 数据挖掘理论及应用研究[J]. 断块油气田, 2010, 17(1): 88-91.  
LI Hua, LIU Shuai, LI Mao, et al. Theory and application of data mining[J]. *Fault-Block Oil & Gas Field*, 2010, 17(1): 88-91.
- [ 12 ] 王光宏, 蒋平. 数据挖掘综述[J]. 同济大学学报(自然科学版), 2004, 32(2): 246-252.  
WANG Guanghong, JIANG Ping. Survey of data mining[J]. *Journal of Tongji University(Natural Science)*, 2004, 32(2): 246-252.
- [ 13 ] 薛茹. 数据挖掘技术在油田中的应用[J]. 微型电脑应用, 2018, 34(5): 26-28.  
XUE Ru. Application of data mining technology in oilfield[J]. *Microcomputer Applications*, 2018, 34(5): 26-28.
- [ 14 ] 郭学增. 钻井工程人工智能十年谈[J]. 石油钻探技术, 1999, 27(5): 25-26.  
GUO Xuezheng. Review of ten years' development of artificial intelligence in drilling engineering[J]. *Petroleum Drilling Techniques*, 1999, 27(5): 25-26.
- [ 15 ] 王小龙. 浅析人工智能在油气行业中的应用[J]. 现代信息技术, 2017, 1(2): 117-119.  
WANG Xiaolong. Application of artificial intelligence in oil and gas industry[J]. *Modern Information Technology*, 2017, 1(2): 117-119.
- [ 16 ] 孙志远, 鲁成祥, 史忠植, 等. 深度学习研究与进展[J]. 计算机科学, 2016, 43(2): 1-8.  
SUN Zhiyuan, LU Chengxiang, SHI Zhongzhi, et al. Research and advances on deep learning[J]. *Computer Science*, 2016, 43(2): 1-8.
- [ 17 ] 余凯, 贾磊, 陈雨强, 等. 深度学习的昨天、今天和明天[J]. 计算机研究与发展, 2013, 50(9): 1799-1804.  
YU Kai, JIA Lei, CHEN Yuqiang, et al. Deep learning: yesterday, today, and tomorrow[J]. *Journal of Computer Research and Development*, 2013, 50(9): 1799-1804.
- [ 18 ] 俞祝良. 人工智能技术发展概述[J]. 南京信息工程大学学报(自然科学版), 2017, 9(3): 297-304.  
YU Zhuliang. Review of progress on artificial intelligence[J]. *Journal of Nanjing University of Information Science & Technology(Natural Science Edition)*, 2017, 9(3): 297-304.
- [ 19 ] 李泽龙, 杨春节, 刘文辉, 等. 基于 LSTM-RNN 模型的铁水硅含量预测[J]. 化工学报, 2018, 69(3): 992-997.  
LI Zelong, YANG Chunjie, LIU Wenhui, et al. Research on hot metal Si-content prediction based on LSTM-RNN[J]. *CIESC Journal*, 2018, 69(3): 992-997.
- [ 20 ] 倪铮, 文韬. 一种基于 CNN 和 RNN 深度神经网络的天气预测模型: 以北京地区雷暴的 6 小时临近预报为例[J]. 数值计算与计算机应用, 2018, 39(4): 299-309.  
NI Zheng, WEN Tao. A weather prediction model based on CNN and RNN deep neural network: an example is the 6 hour forecast of thunderstorm in Beijing[J]. *Journal on Numerical Methods and Computer Applications*, 2018, 39(4): 299-309.