

# 成品油管道停输压力实时监控研究

郑坚钦, 杜渐, 梁永图\*

中国石油大学(北京)机械与储运工程学院, 北京 102249

\* 通信作者, liangyt21st@163.com

收稿日期: 2020-11-24

国家自然科学基金面上项目“成品油供应链物流系统优化及供给侧可靠性研究”(No. 51874325)资助

**摘要** 成品油管道停输期间, 由于管内外温差导致管道压力下降, 另外打孔盗油也会使得管道压力下降, 因此现场难以分辨是否发生盗油事故。本文为实现管道压力变化实时监控、有效指导现场管理的目标, 开展了成品油管道停输压力预测研究。首先从机理模型出发, 确定了压力变化的影响因素(停输时长、油品温度、环境温度); 基于SCADA数据和天气数据构建了停输压力样本数据库; 为提高预测精度, 考虑了压力变化的时间序列特性, 建立了基于PSO优化的LSTM压力预测模型(PSO-LSTM); 以MAE、RMSE、MAPE为指标, 以国内3条不同停输时长的成品油管道为例, 并对比了基本LSTM、SVR、DT、RF、ANN等预测模型; 算例结果表明基于PSO-LSTM的压力预测模型效果最好, 特别当停输时长较短时, 其效果更突出, RMSE、MAE和MAPE分别为0.009、0.008和0.167。本文建立的压力预测模型能动态预测管道压力变化情况, 实现管道压力实时监控, 提高现场运行管理效率。当预测值与检测值相差较大时, 可认为管道发生异常情况, 需现场排查。

**关键词** 成品油管道; 停输; 压力变化; PSO-LSTM; 实时监控

## Research into real-time monitoring of shutdown pressures in multi-product pipelines

ZHENG Jianqin, DU Jian, LIANG Yongtu

College of Mechanical and Transportation Engineering, China University of Petroleum-Beijing, Beijing 102249, China

**Abstract** During the shutdown of a multi-product pipeline, the pipeline pressure will drop due to the temperature difference inside and outside the pipeline. In addition, some abnormal accidents, such as oil theft will also reduce the pipeline pressure. Therefore, it is difficult to distinguish whether there has been an oil theft accident or not. When the pipeline pressure drops, on-site personnel often mistakenly think that abnormal accidents have happened, such as pipeline leakage or oil theft, increasing the management burden on the site. In order to achieve the goal of real-time monitoring of pipeline pressure changes and effective guidance of on-site management, we have carried out research on shutdown pressure prediction of a multi-product pipeline. First, based on the mechanism model, the influencing factors of the pipeline pressure change (shutdown time, oil temperature, and ambient temperature) were determined by an empirical formula. Based on pipeline SCADA data and weather condition data, a sample database of shutdown pressure was constructed. In order to improve the prediction accuracy, the characteristics of the time series of pressure change were considered, and a particle swarm optimization (PSO) algorithm is used to optimize the hyperparameters of a long short-term memory (LSTM) model. Finally, a pressure prediction model is established for a

引用格式: 郑坚钦, 杜渐, 梁永图. 成品油管道停输压力实时监控研究. 石油科学通报, 2021, 04: 648-656

ZHENG Jianqin, DU Jian, LIANG Yongtu. Research into real-time monitoring of shutdown pressures in multi-product pipelines. Petroleum Science Bulletin, 2021, 04: 648-656. doi: 10.3969/j.issn.2096-1693.2021.04.046

multi-product pipeline during the shutdown. Taking mean absolute error (MAE), root mean squared error (RMSE), and mean absolute percentage error (MAPE) as the model indicators, three domestic multi-product pipelines with different shutdown periods were taken as examples and compared with other prediction models such as basic LSTM, support vector regression (SVR), decision tree (DT), random forest (RF), and artificial neural network (ANN). The results of the examples show that the pressure prediction model based on PSO-LSTM has the best effect, especially when the duration of shutdown is shorter, and its effect is more prominent. For pipeline A, RMSE, MAE, and MAPE are 0.009, 0.008, and 0.167 respectively. For pipeline B, RMSE, MAE, and MAPE are 0.008, 0.007, and 0.309 respectively. For pipeline C, RMSE, MAE, and MAPE are 0.018, 0.015, and 0.128 respectively. The pressure prediction model established in this paper can dynamically predict pipeline pressure changes, realize real-time monitoring of pipeline pressure, and improve the efficiency of on-site operation management. When the difference between the predicted value and the detected one is large, it can be considered that an abnormal condition has occurred in the pipeline and needs to be checked on site.

**Keywords** multi-product pipeline; shutdown; pressure change; PSO-LSTM; real-time monitoring

**doi:** 10.3969/j.issn.2096-1693.2021.04.046

## 0 研究背景

停输操作在成品油管道投产和运行过程中是不可避免的<sup>[1-2]</sup>, 停输再启动过程中管内压力变化剧烈。管道停输期间, 现场人员对于管内压力变化无法提前预知, 当管内压力下降时, 经常误以为是管道发生泄漏或出现打孔盗油等事故, 需人员巡检排查, 这严重降低了工作效率。因此, 十分有必要对成品油管道停输期间的压力变化开展研究, 监控压力变化, 指导现场运行管理。研究的难点可总结如下:

(1) 提前预测压力变化趋势, 实时监控, 当预测值与检测值差别较大时, 实现预警功能;

(2) 精准分析管道停输压力变化的影响因素, 建立基于现场检测数据的压力预测模型。

目前, 学者对成品油管道停输压力变化开展研究, 探索管道停输压力变化的原因<sup>[3-6]</sup>。郭祎等<sup>[3]</sup>基于港枣成品油管道的相关数据, 分析了温度对管内油品体积和管道压力的影响程度, 得出油品温度的降低是使港枣成品油管道频繁出现管内压力大幅下降的主要原因。陈春<sup>[4]</sup>基于传热学、热力学理论和现场实际数据, 建立江阴—无锡成品油管道油品压力与温度的变化模型, 通过仿真模拟, 获得该段成品油管道停输后的压力变化模型。张强等<sup>[5]</sup>结合西部成品油管道的现场数据展开研究, 分析了油品温度和地形对停输管道压力的影响, 基于模拟分析结果, 制定了西部成品油管道的停输保压方案。安顺等<sup>[6]</sup>通过对比研究分析, 得出兰郑庆阳支线停输压力安全范围, 为大落差成品油管道运行提供参考。Gong和Zhang<sup>[25]</sup>提出了停输压力的计算方法, 并提供了一些具体的保压方式以保证管道安全。根据油品膨胀性和温度对压力的影响, Xu<sup>[26]</sup>以中国某成品油管道为例, 分析了停输压力变化的原因。

目前研究的不足可总结如下:

(1) 前人主要依靠经验公式, 开展数值模拟<sup>[3-5]</sup>, 其中相关参数取值不精准, 无法动态更新, 如环境温度;

(2) 目前基本都是针对单一管道开展研究<sup>[3-9]</sup>, 尚无通用的成品油管道停输压力分析模型。

为了建立通用的成品油管道停输压力分析模型, 通过停输机理分析, 依托SACDA数据, 可建立基于数据驱动的压力预测模型。随着大数据和智能算法的快速发展, 基于数据驱动的预测模型在能源领域发挥着越来越重要的作用<sup>[10-12]</sup>。由于管道压力的变化具有时间序列特性, 为了更好地描述其变化规律, 需将时间序列关系考虑在内。目前深度学习中比较成熟的、能处理时间序列关系的预测算法主要是循环神经网络(RNN)<sup>[13]</sup>, 其克服了传统神经网络无法处理时间序列数据信息传递的难题, 但其最大的缺点是会出现梯度消失的问题<sup>[14]</sup>。在这样的背景下, Hochreiter和Schmidhuber提出了长短期记忆网络(LSTM)<sup>[15]</sup>, 通过门控制在一定程度上解决了梯度消失的问题, 保证了预测的准确性。目前LSTM在语音识别<sup>[16]</sup>、自然语言处理<sup>[17]</sup>以及翻译<sup>[18]</sup>等诸多领域有着成熟的应用。基于前期研究, 可通过粒子群算法(PSO)优化LSTM网络结构, 提高模型的预测精度<sup>[12]</sup>。因此, 本文将引入PSO-LSTM模型来捕捉压力变化的时间序列关系, 建立成品油管道停输压力预测模型, 监控管道压力变化情况。

本文的研究思路如图1所示:

(1) 从机理模型出发, 分析管道停输机理, 利用目前成熟的经验公式分析并确定影响管道压力变化的相关因素。

(2) 从SCADA系统导出管道停输期间压力、油温等数据, 同时通过天气网站获得对应的环境温度, 构

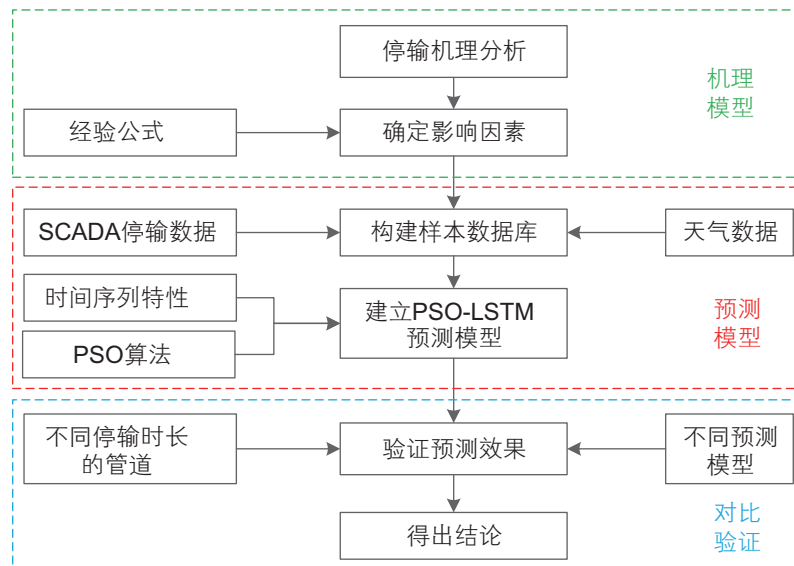


图1 本研究的流程图

Fig. 1 The framework of this research

建管道压力样本库，考虑压力变化的时间序列特性，利用PSO算法优化LSTM网络参数，建立基于PSO-LSTM的压力预测模型。

(3) 选用3条不同停输时长的成品油管道作为算例，同时对比目前常用的机器学习算法、神经网络来验证压力预测模型的准确性和通用性。

## 1 停输压力通用预测模型

### 1.1 机理分析

成品油管道通常采用常温密闭输送，成品油具有膨胀性和压缩性的物理特性。由于油品的物理特性使得油品的温度和体积之间存在一定关系，体积的改变又与管道压力有关，因此认为，管输油品和管道环境温度的差异是引起管道压力变化的主要因素。目前用于描述管道停输后油品温度随时间变化的经验公式如(1)所示<sup>[5]</sup>。油品温度的变化也会引起油品体积的变化，导致管内压力的变化。用于描述管道压力随油品温度变化的公式如(2)、(3)所示<sup>[5]</sup>。

$$T_i = T_{e_i} + (T_0 - T_{e_i}) \times \exp \left[ -\frac{4584K_1\pi Dt}{c_y\rho_y D_1^2 + c_g\rho_g(D_2^2 - D_1^2)} \right] \quad (1)$$

$$\Delta P = \frac{\beta - \alpha}{\frac{1}{K_2} + \frac{1}{A}} (T_{i-1} - T_i) \quad (2)$$

$$A = \delta \cdot \frac{E}{D} \quad (3)$$

式中：

$K_1$ ——总传热系数，W/(m·°C)

$D$ 、 $D_1$ 、 $D_2$ ——管道平均直径、管道内径和管道外径，m

$c_y$ 、 $c_g$ ——油和钢材的比热容，J/(kg·°C)

$\rho_y$ 、 $\rho_g$ ——油和钢材的密度，kg/m<sup>3</sup>

$T_{e_i}$ ——环境温度，°C

$T_i$ ——停输  $t$  小时后的油品温度，°C

$T_0$ ——开始停输时的油品温度，°C

$t$ ——停输时长，h

$\alpha$ ——管道的体积膨胀系数，管道为钢管时， $\alpha \approx 3.3 \times 10^{-5} \text{ } ^\circ\text{C}^{-1}$

$\delta$ ——管道壁厚，mm

$E$ ——管材的杨氏弹性模量， $E \approx 2 \times 10^{11}$  Pa

$\beta$ ——油品的体积膨胀系数， $^\circ\text{C}^{-1}$

$K_2$ ——油品的弹性系数，Pa

$T_i$ ——第  $i$  时刻的油品温度，°C

$T_{i-1}$ ——第  $i-1$  时刻的油品温度，°C

$\Delta P$ ——第  $i$  时刻与第  $i-1$  时刻的压差，Pa

由以上公式可以得到停输期间管道压力变化的相关影响因素。为方便分析，将这些影响因素分为2类，第1类是短期内基本不会发生变化的，如总传热系数等土壤属性、管道基本参数、初始油温  $T_0$ 。这一类部分因素的取值较难获取，一般是通过估算得到，且对

于不同管道其取值有所不同,但通过以上分析,发现该类因素基本不随时间变化,因此,可不考虑在基于数据驱动的预测模型中,减少了计算的工作量。第2类是随停输时间变化的,分别是停输时长 $t$ 、环境温度 $Te_t$ 、油品温度 $T_t$ 。通过以上分析,可以确定影响管道压力 $P_t$ 变化的因素为 $t$ 、 $Te_t$ 和 $T_t$ 。

### 1.2 PSO-LSTM模型

LSTM是基于RNN演化而来的。如图2所示,RNN通过形成自循环结构,来将每个时刻提取到的信息继续传递给下一时刻,可将时间序列特性考虑在内。但RNN自身也存在一定缺点,如梯度消失以及无法处理长依赖问题,而前者也正是导致后者的根本原因。在LSTM中,3个门的输出都是以sigmoid函数来进行计算的,输出介于0到1之间。如果接近0,说明上一时刻的信息对此刻并无较大影响,则此时也没有必要通过梯度下降返回调整权值;如果接近1,则此时梯度能够顺利在网络中传播,很大程度上避免了梯度降为零最后发生梯度消失的情况。通过这种巧妙的门控制,在一定程度上解决了梯度消失的问题。

LSTM的基本单元结构如图3所示,在 $t$ 时刻,传




图2 RNN自循环结构

Fig. 2 RNN self-looping structure

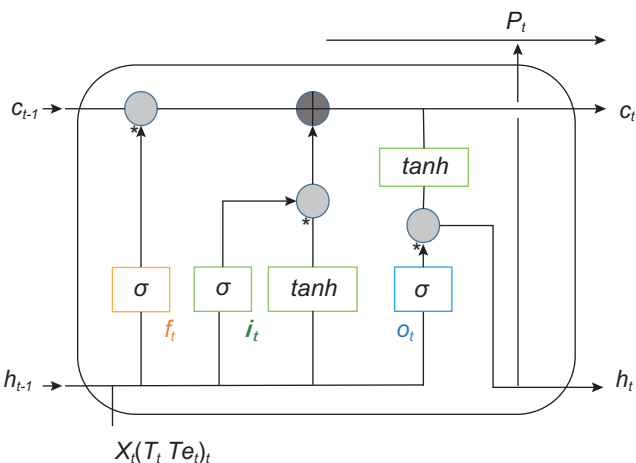


图3 基本LSTM单元

Fig. 3 Basic LSTM cell

入LSTM的是 $t-1$ 时刻的单元状态 $c_{t-1}$ 、隐状态 $h_{t-1}$ 以及输入的新信息 $(t, Te_t, T_t)$ ,为了方便后续描述,用 $x_t$ 来代表 $(t, Te_t, T_t)$ 。当整个单元处于激活状态时,3个主要组件(忘记门、输入门以及输出门)会根据各自的运算属性对输入信息进行计算。各个门的激活函数会将门的输出值限定在0到1之间。

LSTM的信息计算及传递分为以下几步:

(1)LSTM首先确定需要保留上一时刻单元状态的哪些信息,这一步骤在忘记门中完成。忘记门中的sigmoid函数会查看上一时刻的 $h_{t-1}$ 以及新输入信息 $x_t$ ,并以此来输出一个介于0到1之间的向量 $f_t$ ,向量的大小表示保留信息的多少,0表示将上一时刻的信息全部丢弃,1则表示将上一时刻的信息全部保留。其中sigmoid的函数式如式(4), $f_t$ 的计算如式(5)所示。

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

$$f_t = \sigma(W_{xf} \cdot x_t + W_{hf} \cdot h_{t-1} + b_f) \quad (5)$$

(2)在确定了上一时刻需要保留的信息之后,下一步便确定要为单元状态添加哪些新信息。这一步骤由两小步组成,首先通过分析传入的 $h_{t-1}$ 和 $x_t$ 来计算输入门 $i_t$ ,以此决定需要更新哪些信息。之后通过tanh计算得到候选信息 $\bar{c}_t$ ,这些候选信息会根据上一步计算所得的需要更新的信息来决定是否要更新到新的单元状态中。

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (6)$$

$$i_t = \sigma(W_{xi} \cdot x_t + W_{hi} \cdot h_{t-1} + b_i) \quad (7)$$

$$\bar{c}_t = \tanh(W_{xc} \cdot x_t + W_{hc} \cdot h_{t-1} + b_c) \quad (8)$$

(3)得到需要更新的信息以及候选的新信息后,需要对上一时刻信息进行更新,即用于输出的单元状态 $c_t$ 。在第1步中我们通过忘记门保留了旧的单元状态 $c_{t-1}$ 的部分信息,第2步中计算了用于更新的候选信息 $\bar{c}_t$ 。具备了以上几个基础信息之后,便可以对此刻的单元状态信息进行更新。更新的具体方法如(9)式所示。

$$c_t = f_t * c_{t-1} + i_t * \bar{c}_t \quad (9)$$

(4)上一步完成了单元状态的更新,还需要确定最终的输出内容。将新信息 $x_t$ 的和上一时刻的隐状态 $h_{t-1}$ 传递给输出门,利用sigmoid函数和tanh函数决定此刻隐状态的输出,同时输出 $t$ 时刻压力的最终预测结果 $P_t$ 。具体的计算过程如下所示。

$$o_t = \sigma(W_{xo} \cdot x_t + W_{ho} \cdot h_{t-1} + b_o) \quad (10)$$

$$h_t = o_t * \tanh(c_t) \quad (11)$$

$$P_t = \sigma(W_{hy} \cdot h_t + b_y) \quad (12)$$



自1995年提出后<sup>[19]</sup>, PSO算法被广泛运用于优化领域。本文, 基于PSO强大的搜索能力, 用于优化得到LSTM最优的网络参数, 具体细节可参考前期成果<sup>[12]</sup>, 优化过程如图4所示。流程如下:

- (1) 开始执行流程;
- (2) 首先初始化PSO算法的粒子;
- (3) 计算每个粒子对应的LSTM模型的训练误差, 并将误差作为各粒子的适应度;
- (4) 找到PSO算法的两个极值, 即个体最优和全局最优;
- (5) 判断是否满足收敛条件, 如是否达到一定迭代次数;
- (6) 若满足收敛条件则输出最优LSTM参数, 反之更新粒子返回第(3)步, 重复至收敛;
- (7) 结束优化流程。

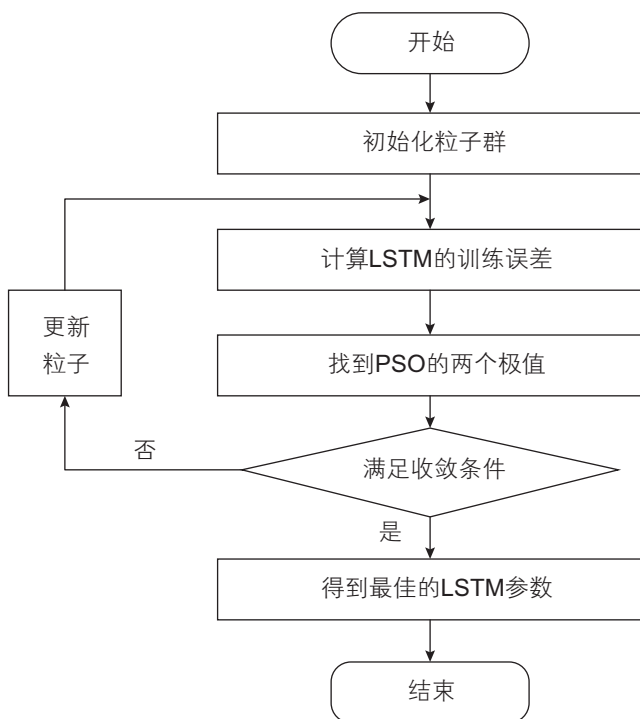


图4 PSO算法优化LSTM参数的流程

Fig. 4 The process of PSO algorithm to optimize the parameters of LSTM

表1 三条管道对应的停输信息

Table 1 Shutdown information corresponding to the three pipelines

管道	管道A	管道B	管道C
停输开始时间	2019-5-5 21:00:00	2019-6-10 23:00:00	2019-3-30 16:00:00
停输结束时间	2019-5-7 12:00:00	2019-6-15 23:00:00	2019-4-11 15:00:00
停输时长/h	39	120	287

### 1.3 数据预处理

目前成品油管道的SCADA系统已十分成熟, 停输期间的管道压力、油温数据都存储在SCADA中, 环境温度可通过天气网站(<https://www.wunderground.com/>)获取。因此, 可分别获取预测模型的自变量和因变量数据, 搜集整理并建立停输管道压力变化数据库。

数据归一化是将不同范围内的数据处理为一致的范围, 可在保持相关性的同时加速预测模型收敛。由于 $P_i$ 和 $t$ ,  $Te_i$ ,  $T_i$ 的取值范围不同, 因此有必要进行数据归一化。采用最小-最大归一化方法处理, 将各个维度的数值约束到0-1范围。归一化公式如下所示:

$$x_{\text{norm}} = \frac{x_{\text{orig}} - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}} \quad (13)$$

其中 $x_{\text{norm}}$ 是各变量归一化后的值,  $x_{\text{orig}}$ 是各变量的原始值,  $x_{\text{max}}$ 和 $x_{\text{min}}$ 分别是各变量的最大值和最小值。

### 1.4 模型评价指标

为了评估预测模型的有效性, 需定义相关的误差评价指标。本文采用平均绝对误差(Mean Absolute Error, MAE)、均方根误差(Root Mean Square Error, RMSE)和平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)作为预测模型的性能指标。公式定义如下所示:

$$MAE = \frac{1}{n} \sum_{i=1}^n |p_i - r_i| \quad (14)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (p_i - r_i)^2} \quad (15)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{p_i - r_i}{r_i} \right| \quad (16)$$

式中,  $n$ 为预测样本总个数,  $r_i$ 为第 $i$ 个样本的真实值,  $p_i$ 为第 $i$ 个样本的预测值。

## 2 模型验证

为了验证基于PSO-LSTM的停输压力预测模型的

准确性和通用性, 选用国内 3 条不同停输时长的管道作为算例分析。停输信息如表 1 所示, 管道 A、B、C 的停输时长依次增加, 分别用来代表停输周期的短、中、长。同时为了说明考虑时间序列特性的优越性, 选用人工神经网络(ANN), 以支持向量机(SVR)、决策树(DT)和随机森林(RF)为代表的传统机器学习算法作为比较, 同时对比优化前(LSTM)和优化后(PSO-LSTM)模型的预测精度。ANN 包含输入层、隐藏层以及输出层<sup>[20]</sup>, 信息从各个层之间依次流过, 但不会在同一层的网络神经元之间进行传递, 这样便导致输出信息只与输入值的大小相关而无法和输入值的输入顺序相关联在一起。SVR 可用于分类和回归, 基本思想是找到一个最大间隔的“超平面”使得现有数据样本到“超平面”的距离最大<sup>[21]</sup>。DT 的基本思想是将特征空间划分成不同单元, 根据划分确定对应的输出, 类似建立树的过程<sup>[22]</sup>。RF 是一种集成学习算法, 是利用多个决策树组合而成的, 综合考虑所有决策树确定最终预测结果<sup>[23]</sup>。

为保持管道停输压力原有的时间序列特性, 基于 LSTM 的预测模型不打乱样本数据; 相反, 为提高 ANN、SVR、DT 和 RF 模型的准确性, 打乱样本数据。

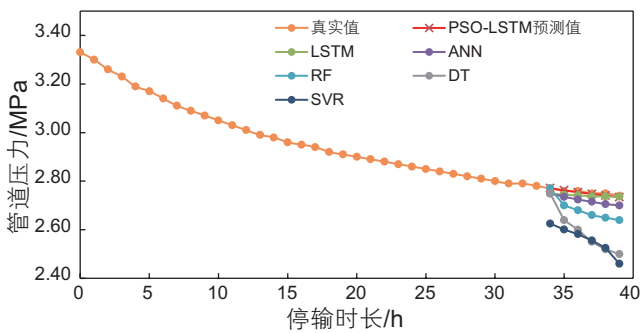


图 5 管道 A 压力随停输时间的变化情况  
Fig. 5 The pressure change of pipeline A with the shutdown time

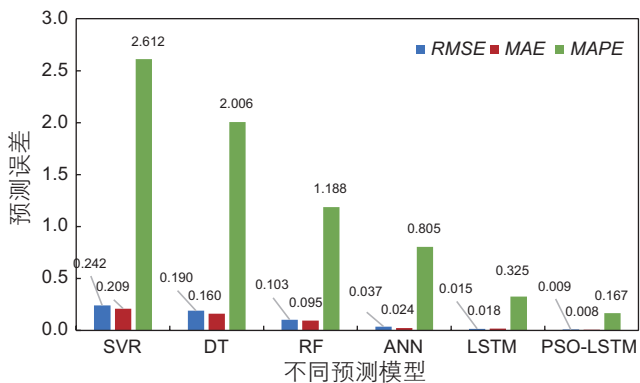


图 6 不同预测模型在管道 A 的预测误差  
Fig. 6 The prediction errors of different models for pipeline A

参考机器学习模型中数据集划分的经验总结<sup>[24]</sup>, 训练集和测试集的比例分别为 80% 和 20%, 预测模型的实现环境为开源的 scikit-learn 和 Tensorflow 库, 并以测试集的误差作为模型评价指标进行对比。

以管道 A 在 2019 年 5 月 5 日到 5 月 7 日停输末站压力变化为例, 停输时长为 39 h, 压力变化趋势如图 5 所示。由图 5 可看出, 压力一直呈下降趋势, 很大可能是由于油品温度一直大于环境温度, 油品与土壤发生热交换而使得管内压力下降。将基于 2.3 构建的样本库代入到 PSO-LSTM 模型及其他预测模型, 预测误差如图 6 所示。可以明显看出, 传统机器学习算法的预测误差较大, ANN、LSTM 次之, PSO-LSTM 的 MAE 和 RMSE 接近于 0, 其预测效果最佳。为了直观展示 PSO-LSTM 的预测效果, 将验证集的预测值与真实值在图 5 中做比较, 可看出 PSO-LSTM 的预测结果与真实值几乎重叠, 进一步说明预测结果的可靠性。

同理, 以管道 B 在 2019 年 6 月 10 日到 6 月 15 日停输为例, 停输时长为 120 h, 压力变化如图 7 所示。管道压力先下降后几乎趋于平稳, 有可能是油品温度逐渐下降后与环境温度相差不大。为更好展示各模型的预测结果, 只展示测试集的压力对比, 如图 8 所




图 7 管道 B 压力随停输时间的变化情况  
Fig. 7 The pressure change of pipeline B with the shutdown time




图 8 不同预测模型在管道 B 的预测结果  
Fig. 8 The prediction values of different models for pipeline B

示, 预测误差如图9所示。可以看出, 虽然在 $MAE$ 、 $RMSE$ 上,  $PSO-LSTM$ 与其他算法相比优势不大, 但在 $MAPE$ 上,  $PSO-LSTM$ 明显最小, 优势更加突出。

以管道C在2019年3月30日到4月11日停输为例, 停输时长为287 h, 压力变化如图10所示。管道压力先下降、平缓后上升, 有可能是油品温度先下降后与环境温度相差不大时压力趋于平缓, 但由于季

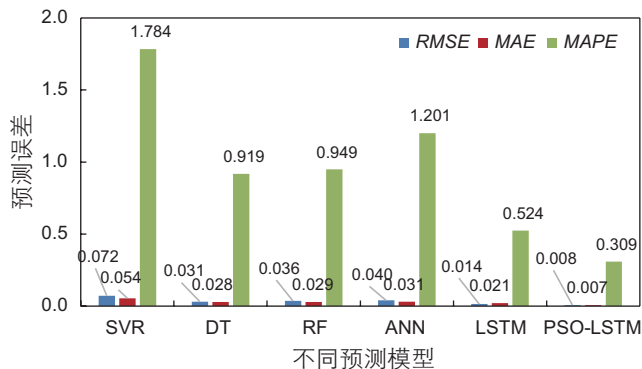


图9 不同预测模型在管道B的预测误差

Fig. 9 The prediction errors of different models for pipeline B

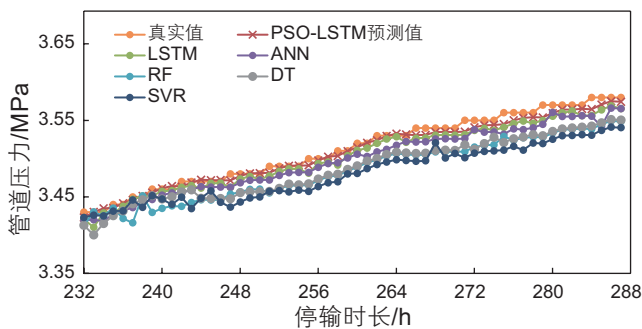


图11 不同预测模型在管道C的预测结果

Fig. 11 The prediction values of different models for pipeline C

的通用性。特别当停输时长较短时, 样本数据较少, 其他预测模型表现更差, 但 $PSO-LSTM$ 能考虑时间序列特性, 预测效果好、鲁棒性强。

### 3 结论与建议

本文就成品油管道停输期间管道压力变化开展研究。基于机理模型分析, 确定了影响压力变化的变量为停输时长、油品温度、环境温度。基于SCADA数据和天气数据构建管道停输压力预测样本库, 考虑到压力变化的时间序列特性, 建立了 $PSO-LSTM$ 预测模型。为验证模型的准确性和通用性, 选择了国内

节的变化(3月到4月), 环境温度上升, 导致热交换从环境温度向油品温度传递, 进而使管道压力上升。不同模型的预测结果与预测误差如图11、12所示。 $PSO-LSTM$ 在3个指标中依然是最小的, 表现最佳。

通过以上3条不同停输时长管道的比较, 可以得出基于 $PSO-LSTM$ 的管道停输压力模型在不同管道、不同停输周期上预测效果突出, 准确性高, 具有较强




图10 管道C压力随停输时间的变化情况

Fig. 10 The pressure change of pipeline C with the shutdown time

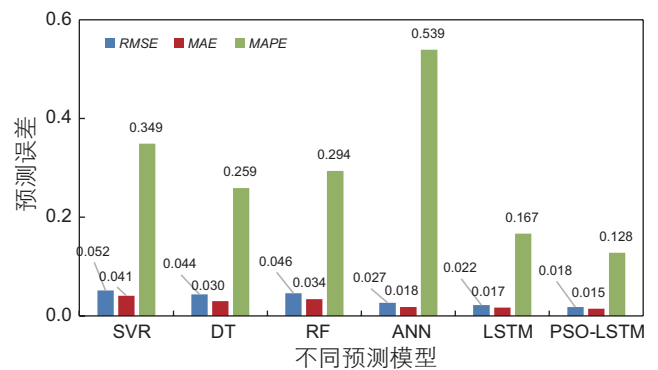


图12 不同预测模型在管道C的预测误差

Fig. 12 The prediction errors of different models for pipeline C

3条不同停输时长的成品油管道, 并对比了以SVR、DT、RF为代表的传统机器学习和以ANN模型。对于管道A,  $MAE$ 、 $RMSE$ 、 $MAPE$ 分别为0.008, 0.009, 0.167%; 对于管道B,  $MAE$ 、 $RMSE$ 、 $MAPE$ 分别为0.007, 0.008, 0.309%; 对于管道C,  $MAE$ 、 $RMSE$ 、 $MAPE$ 分别为0.015, 0.018, 0.128%。结果验证了 $PSO-LSTM$ 模型对于成品油管道停输压力预测的准确性和通用性。该模型能实现成品油管道停输期间管道压力的实时预测和监控, 当预测值与检测值相差较大时, 有可能是管道发现异常情况, 实现预警, 指导现场运行管理。

## 参考文献

- [1] 梁永图, 刘增哲. 成品油管网运行优化[J]. 中国石油大学学报(自然科学版), 2011, 35(03): 115-118. [LIANG Y T, LIU Z Z. Operation optimization of refined oil pipeline network [J]. Journal of China University of Petroleum (Edition of Natural Science), 2011, 35 (03): 115-118.]
- [2] 梁永图, 鲁岑, 方涛. 成品油管道运行调度研究综述[J]. 石油天然气学报, 2010, 32(05): 355-359. [LIANG Y T, LU C, FANG T. Summary of Research on Operation and Scheduling of Multi-Product Pipelines [J]. Journal of Oil and Gas Technology, 2010, 32 (05): 355-359.]
- [3] 郭祎, 许玉磊, 刘佳, 等. 港枣成品油管道停输后管内压力下降原因[J]. 油气储运, 2010, 29(09): 687-688. [GUO Y, XU Y L, LIU J, et al. The Causes of the Inner-pipe Pressure Drop after Shutdown of Hongkong and Zaojiang Product Oil Pipelines [J]. Oil & Gas Storage and Transportation, 2010, 29 (09): 687-688.]
- [4] 陈春. 江阴-无锡成品油管道停输后压力变化分析[J]. 辽宁化工, 2017, 46(09): 886-888. [CHEN C. Analysis of pressure change of Jiangyin-Wuxi multi-product pipeline after shutdown [J]. Liaoning Chemical Industry, 2017, 46 (09): 886-888.]
- [5] 张强, 宫敬, 闵希华, 等. 成品油管道停输时段压力变化分析[J]. 油气储运, 2009, 28(12): 14-18. [ZHANG Q, GONG J, MIN X H, et al. Analysis of pressure changes during the shutdown period of refined oil pipelines [J]. Oil & Gas Storage and Transportation, 2009, 28 (12): 14-18.]
- [6] 安顺, 张小俊, 苏豪育, 等. 大落差成品油管道停输期间压力波动分析[J]. 石油管材与仪器, 2018, 4(02): 82-84. [AN S, ZHANG X J, SU H Y, et al, Yang Hucheng. Analysis of pressure fluctuation during the stoppage of large drop product oil pipeline[J]. Petroleum Pipes and Instruments, 2018, 4(02): 82-84.]
- [7] 曾景荣. 成品油管道停输状态时压力与温度的关系[J]. 化工管理, 2019(31): 220-222. [ZENG J. Relationship between pressure and temperature when multi-product pipelines are out of operation [J]. Chemical Industry Management, 2019 (31): 220-222.]
- [8] 廖小花. 南宁-百色段成品油管道停输后管内压力下降原因分析[J]. 山东工业技术, 2017(09): 84. [LIAO X H. Analysis of the reason for the pressure drop in the pipeline after the Nanning-Baise oil product pipeline was stopped [J]. Shandong Industrial Technology, 2017(09): 84.]
- [9] 邱东. 九江-樟树成品油管道停输后压力下降分析[J]. 石油库与加油站, 2015, 24(05): 8-10+2-3. [QIU D. Analysis of the pressure drop after the shutdown of Jiujiang-Zhangshu oil product pipeline[J]. Petroleum Depot and Gas Station, 2015, 24(05): 8-10+2-3.]
- [10] ZHENG J, ZHANG H, YIN L, et al. A voyage with minimal fuel consumption for cruise ships. Journal of Cleaner Production. 2019, 215: 144-153.
- [11] WANG Z, LI S. Data-driven risk assessment on urban pipeline network based on a cluster model. Reliability Engineering & System Safety. 2020, 196: 106781.
- [12] ZHENG J, ZHANG H, DAI Y, et al. Time series prediction for output of multi-region solar power plants. Applied Energy. 2020, 257: 114001.
- [13] SU H, ZIO E, ZHANG J, et al. A hybrid hourly natural gas demand forecasting method based on the integration of wavelet transform and enhanced Deep-RNN model. Energy. 2019, 178: 585-597.
- [14] Pascanu R, Mikolov T, Bengio Y. On the difficulty of training recurrent neural networks. International conference on machine learning. 2013. p. 1310-8.
- [15] Hochreiter S, Schmidhuber J. Long short-term memory. Neural computation. 1997;9: 1735-80.
- [16] Fayek HM, Lech M, Cavedon L. Evaluating deep learning architectures for Speech Emotion Recognition. Neural Networks. 2017;92: 60-8.
- [17] Liu Y, Zhang X, Huang F, Tang X, Li Z. Visual question answering via Attention-based syntactic structure tree-LSTM. Applied Soft Computing. 2019;82: 105584.
- [18] Costa-jussà MR, Allauzen A, Barrault L, Cho K, Schwenk H. Introduction to the special issue on deep learning approaches for machine translation. Computer Speech & Language. 2017;46: 367-73.
- [19] Kennedy J, Eberhart R. Particle swarm optimization. IEEE international conference on neural networks, 1995 proceedings, vol. 4; 2002. p. 1942-8.
- [20] Wen K, He L, Liu J, Gong J. An optimization of artificial neural network modeling methodology for the reliability assessment of corroding natural gas pipelines. Journal of Loss Prevention in the Process Industries. 2019;60: 1-8.
- [21] Li F, Wang W, Xu J, Yi J, Wang Q. Comparative study on vulnerability assessment for urban buried gas pipeline network based on SVM and ANN methods. Process Safety and Environmental Protection. 2019;122: 23-32.
- [22] Sabah M, Talebkeikhah M, Agin F, Talebkeikhah F, Hasheminasab E. Application of decision tree, artificial neural networks, and



- adaptive neuro-fuzzy inference system on predicting lost circulation: A case study from Marun oil field. *Journal of Petroleum Science and Engineering*. 2019;177: 236–49.
- [23] Ao Y, Li H, Zhu L, Ali S, Yang Z. The linear random forest algorithm and its advantages in machine learning assisted logging regression modeling. *Journal of Petroleum Science and Engineering*. 2019;174: 776–89.
- [24] 周志华. 机器学习. 清华大学出版社, 2016. [ZHOU Z H. Machine Learning. Tsinghua University Press, 2016.]
- [25] Jing, G. and Z. Qiang. Analyses of the Process Control and Technical Scheme of Urumchi—Lanzhou Multi-Products Pipeline. in *International Pipeline Conference*. 2008.
- [26] Xu, Y. L., The Analysis Pressure Drop between Initial Station and 1#valve when Lan-Zheng-Chang Product Pipeline Shutdown. *Applied Mechanics and Materials*, 2014. 628: p. 142–145.

(责任编辑 王雨墨 编辑 马桂霞)