

基于数据挖掘的输油管道智能化研究

于 涛^{1,2} 李传宪¹ 李龙东³ 郑琬郁² 于 瑶²

1. 中国石油大学(华东)储运与建筑工程学院, 山东 青岛 266580;
2. 中国石油北京油气调控中心, 北京 100007;
3. 中国石油西部管道公司, 新疆 乌鲁木齐 830013

摘要:针对长输液体管道调度员实际生产过程中无法实时有效地判断工况,以及以往理论公式对实际生产的应用存在局限性等问题,提出管道智能化研究,辅助调度员日常工作,降低工作压力和减少工作量,提高工作及决策效率。通过建立管道智能化架构,分析获得的数据挖掘层为核心层,核心层的构建需要根据管道业务需求,由业务专家和数据挖掘专家共同完成。对比理论公式和数据挖掘算法获得各自优势特点,基于实际生产数据的数据挖掘算法可根据业务需求建立相应的预测、识别模型,从而构建数据挖掘层。将数据挖掘算法应用于 HY 热油管道,建立 GA-BP 油温预测模型,其分析及预测结果相比理论公式计算更准确,可有效指导 HY 热油管道工艺调整。可见,基于数据挖掘算法的管道智能化研究可有效提升管道安全优化管控水平,并为管道智能化控制奠定基础。

关键词:长输管道;智能化;数据挖掘;BP 神经网络;GA 算法

DOI:10.3969/j.issn.1006-5539.2020.02.001

Research on Intelligentization of Long-Distance Pipeline Based on Data Mining Technology

Yu Tao^{1,2}, Li Chuanxian¹, Li Longdong³, Zheng Wanyu², Yu Yao²

1. College of Pipeline and Civil Engineering, China University of Petroleum, Qingdao, Shandong, 266580, China;
2. PetroChinaBeijing Oil & Gas Transportation Center, Beijing, 100007, China;
3. China Petroleum West Pipeline Co., Ltd., Urumchi, Xinjiang, 830013, China

Abstract: For the dispatcher's actual production process, it is impossible to judge the working condition in real time. The previous theoretical formula has limitations on the actual production guidance, and the pipeline intelligent research is proposed. In addition, it assists the dispatcher in daily work, gradually reduces the dispatcher's work pressure and workload, and improves work and decision-making efficiency. Through the establishment of the pipeline intelligent architecture, the analysis obtains its technical support layer as the core layer. The construction of the core layer needs to be completed by technical experts and data mining according to the pipeline business requirements. Respective advantages are obtained by theoretical formulas with data mining algorithms, data mining algorithms based on actual production data can establish

收稿日期:2019-09-09

基金项目:中国博士后科学基金“博士后特别资助”(2019 TQ 0354);国家自然科学基金“表面可控接枝聚合物降凝剂分子的复合 PSQ 微球对蜡油体系析蜡特性与流变行为的调控机理研究”(51774311)

作者简介:于 涛(1982-),男,山东青岛人,高级工程师,硕士,主要从事长输液体管道调控运行管理与数据分析工作。
E-mail:124114004@qq.com

corresponding prediction and recognition models according to business needs. Application of data mining method to HY hot oil pipeline, statistical analysis of oil temperature and ground temperature and the GA-BP oil temperature prediction model is established. The analysis and prediction results are more accurate than the theoretical formula calculation, which can effectively guide the process adjustment of HY hot oil pipeline. The intelligent research of pipeline based on data mining algorithm can effectively improve the pipeline safety optimization control level and lay a foundation for intelligent control of pipelines.

Keywords: Long-distance pipeline; Intelligent; Data mining; BP neural network; GA

0 前言

长输液体管道作为国家经济发展动脉,目前多采用 Supervisory Control And Data Acquisition (SCADA) 系统进行远程控制,日常运行中调度员通过分析压力、流量等参数,结合设备状态变化实现管道监控。近年来,随着长输液体管道的自控通讯技术发展,SCADA 系统实时数据及历史数据的分析应用,通过参数及设备的自动监测、调节保护、参数预测及工况实时捕捉的管道智能化,逐渐被生产部门重视并投入建设^[1-3]。

管道智能化建设是一个综合性工程,人员包括业务专家、数据挖掘专家及软件开发人员等,涉及业务需求的提出、数学模型构建应用等工作。国内外的石油公司在物联网、机器学习、人工智能等管道智能化方面持续开展了大量研究工作,并在管网负荷预测^[4]、运营效率及业务优化等方面取得了一定成果^[5]。国内石油公司目前多侧重于数据采集与展示,对于数据挖掘和应用主要应用于管道完整性建设^[6]、内检测^[7-9]、泄漏监测、管道安全识别等方面^[10-11],但未打通不同业务之间的界限,信息孤岛现象明显,没有形成统一的数据平台^[12]。本文研究并提出了长输液体管道智能化架构,给出架构的核心为数据挖掘层及其相应的数据挖掘算法,通过 HY 原油管道应用案例,获得基于数据挖掘技术建立的油温预测模型,为未来管道不同业务的智能化应用探索道路。

1 管道智能化架构

长输液体管道的智能化研究应用架构,从下到上分为物理层、数据层、数据挖掘层、应用层和用户层五个^[13],见图 1。在系统的总体架构中,需充分结合国家、行业及企业标准规范,形成系统需要的标准规范体系。同时考虑系统建设过程中的网络、数据安全,建立安全保障体系,确保系统的安全性。

1.1 物理层

物理层是系统运行的基础硬件环境,主要包括硬件、软件和通讯设备,其中硬件包括服务器,如:应用服务器、数据库服务器、磁盘阵列等设备,通过这些硬件设

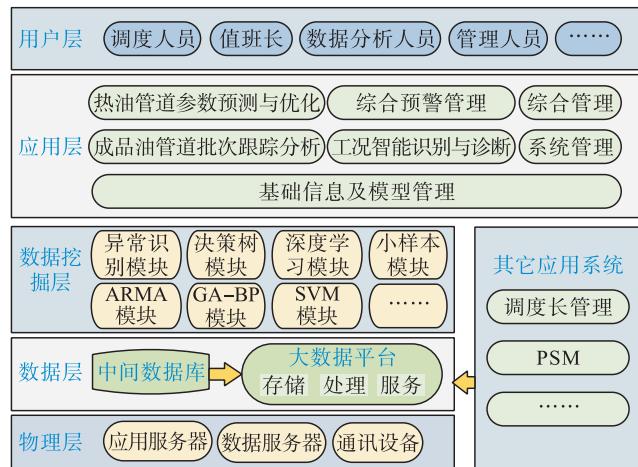


图 1 管道智能化系统架构图

Fig. 1 Pipeline intelligent system architecture

备为系统提供物理设备支撑;软件主要包括部署在服务器设备上的操作系统,通过软件系统,实现人机界面的交互,为用户提供方便快捷的操作界面;网络通讯设备包括网络交换机、防火墙等设备,为应用系统的运行提供通信保障。

1.2 数据层

主要对各类数据源的采集、存储与管理,通过部署数据采集程序、手动录入、数据上传等多种方式,将生产数据、文档数据、GPS 数据等上传到数据库内,对各类数据进行统一管理,为系统应用、分析提供基础数据源。

1.3 数据挖掘层

根据业务需求,利用理论公式、数据回归、数据挖掘等方式,将基础数据进行加工处理,变成可为系统提供支撑的数据或预测模型,如参数的趋势预测,工况识别算法等模型。

1.4 应用层

利用数据挖掘层提供的技术与服务开展各项业务应用,包括:热油管道参数预测与优化、成品油管道批次界面跟踪、异常工况智能识别等。

1.5 用户层

提供多种数据集成、图形报表展现及多维数据分析,以满足用户分类汇总、统计分析、决策支持的需要,为管理人员以及相关业务人员提供决策依据。

2 数据挖掘方法与应用

管道智能化架构研究中,数据挖掘层是通过理论及数据挖掘算法,将业务需求理论化、模型化,是管道未来智能化管理控制的核心。由于长输液体管道运行过程产生大量的实时数据,发生的事件工况、报警信息具有复杂多样、变化快、多维度、多时域频域等特点。以往理论研究方法在数据挖掘层的适用性较差,需采用更为实用的数据挖掘算法建立预测模型。与传统实验研究和数值分析不同,应用于大数据挖掘技术中的神经网络、机器学习及深度学习等算法模型,能够挖掘不同参数之间的隐性关系,实现参数的有效预测,如电网负荷预测、设备故障在线预测与诊断等^[14-16]。数据挖掘方法与传统理论研究方法相比,各自的特点,见图2。

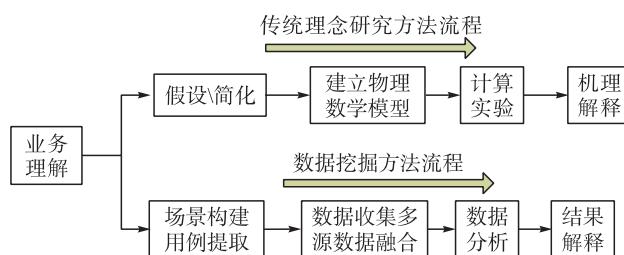


图2 传统理论研究方法与数据挖掘方法流程对比图

Fig. 2 Process comparison between traditional theoretical research method and data mining method

以热油管道苏霍夫油温计算公式为例^[17],因公式受影响因素较多,实际应用适应性较差。其主要局限性一是模型构建过程需要对参数进行理想假设和简化,影响误差;二是实际应用过程中,因影响参数的变化,导致模型适用性差;三是分析较片面,局部难以反映宏观时空关联特性。数据挖掘方法不依赖于机理,可将历史和实时数据综合分析,得到多维度宏观时空关联特性。数据挖掘方法与传统理论研究方法并不矛盾,研究过程中数据挖掘方法通过使用传统理论研究方法确定输入参数,建立时空关联特性,提升研究效率,同时也进一步完善科学的研究体系,推动研究方法的发展。

3 应用实例分析

HY热油管道主要外输长庆油田高含蜡原油,油品物性见表1,管道全长132.4 km,管径Φ457 mm,设计压カ6.3 MPa(局部10 MPa),设计输量500×10⁴ t/a,全线共设1#首站、2#热站、3#热站和4#末站共4座站场。根据沿线地温和油品物性特点,管道采用综合热处理、热处理、加热和常温输送等不同工艺,保证全线油温高于凝点3℃,具有运行工艺复杂,动力及燃料油费用高等特点。生产过程中管道油温是重点关注参数。

表1 HY热油管道外输油品物性表

Tab. 1 Oil properties of HY hot oil pipeline

原油名称	凝点 / °C	密度 / (kg·m ⁻³)	含蜡量 / (%)	胶质沥青质含量 / (%)	析蜡点 / °C	反常点 / °C
外输油品	18	847.8	16.4	8.1	36.4	25

HY热油管道下游站场进站油温与输量、地温、上游站场出站油温等参数是一种复杂且相互影响的内部关系,BP神经网络具有实现任意复杂非线性映射的能力,适合于求解此类复杂问题。但BP神经网络同时存在容易陷入局部极小值,网络收敛速度慢,网络结构及参数的选择缺乏统一标准等问题。本文研究使用遗传算法(Genetic Algorithm,GA)优化BP神经网络的初始权值和阈值^[18-19],主要包括种群初始化、适应度函数、选择操作、交叉操作和变异操作等,提升模型的准确性和效率。

3.1 GA-BP油温预测模型构建

GA具有自组织、自适应等特点,在运行过程中处理参数编码集,而非参数本身,不受优化函数连续性、可导性约束,此外BP神经网络擅长局部搜索,GA擅长全局搜索。模型构建过程中首先通过GA优化神经网络初始权值,定位获得较优搜索空间,再通过BP神经网络在较优的搜索空间产生最优值,从而较好地确定输入值与期望输出值之间的非线性关系,提高模型预测精度^[20]。GA优化程序见图3。

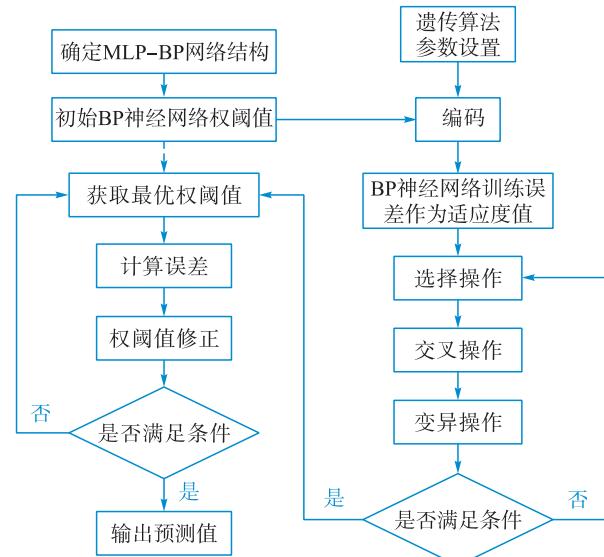


图3 GA优化程序框图

Fig. 3 Genetic Algorithm Optimization Program

由图3可知,GA优化的步骤如下:

第一步,网络初始化与遗传编码。初始化BP神经网络,随机产生一个 $X_{m \times n}$ 种群,确定网络输入、输出节点数 s_1, s_2 ,训练次数 N 和隐含层数 H ,训练误差 ε 等参数,个体长度即为神经网络权值个数。确定种群规模 m 、最大迭代

次数 T 、交叉概率 P_c 和变异概率 P_m , 其长度 n 为:

$$n = H \times (s_1 + s_2) + H + s_2 \quad (1)$$

第二步, 遗传进化。通过迭代求解最佳结构权值和阈值, 包括选择、交叉、变异等操作。若第 i 个个体的适应度值为 f_i , 则选中概率为:

$$P_i = f_i / \sum_{i=1}^m f_i \quad (2)$$

交叉由 2 个个体通过线性组合产生新个体。交叉概率产生新个体为:

$$X_i(k+1) = \alpha X_i(k) + (1 - \alpha) X_{i+1}(k) \quad (3)$$

$$X_{i+1}(k+1) = \alpha X_{i+1}(k) + (1 - \alpha) X_i(k) \quad (4)$$

式中: α 为 0~1 之间的随机值, 由变异概率 P_m 所对应的取值范围内, 随机值替换原值, 即:

$$X_i = X_i(p) + s_1 \times q + X_i(n-p-1) \quad (5)$$

式中: q 为第 $p+1$ 个基因所对应阈值范围, 通过遗传进化, 可利用父辈种群产生新一代子种群 X' 。

第三步, 适应度值计算。根据流程计算模型适应度值, 判断迭代次数和精度, 确定是否返回计算。在遗传结束后, 通过解码获得最优个体作为 BP 神经网络初始权值和阈值。

通过 GA 对 BP 神经网络在权值和阈值的优化选择, 结合 BP 神经网络算法特点, 建立热油管道 GA-BP 油温预测模型, 其架构见图 4。

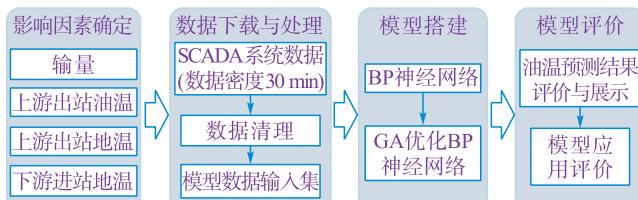


图 4 HY 热油管道油温预测模型架构图

Fig. 4 Oil temperature prediction architecture of HY hot oil pipeline

3.2 数据预处理

通过 SCADA 系统历史数据库下载相关数据, 数据密度为 30 min, 剔除非稳态数据与错误数据, 即对数据进行清洗、预处理, 提升数据质量, 将数据矩阵集成, 以便 GA-BP 油温预测模型学习使用。为了模型训练和提高程序运行时收敛效率, 对数据进行归一化处理, 把数据映射到 0~1 范围内, 本文采用 min-max 标准化 (Min-Max Normalization)……, 见式(6):

$$X^* = \frac{X - \min}{\max - \min} \quad (6)$$

式中: X^* 为标准化后的数据; \max 为样本数据最大值; \min 为样本数据最小值。

3.3 模型验证

本文使用均方根误差 RMSE、平均绝对误差 MAD 和

相关系数 R 评估模型精度, 见式(7)~(9)。使用绝对误差和相对误差分析油温的预测值与真实值。

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_i - \hat{x}_i)^2}{N}} \quad (7)$$

$$MAD = \frac{\sum_{i=1}^N |x_i - \hat{x}_i|}{N} \quad (8)$$

$$R = \frac{\sum_{i=1}^N (x_i - \bar{x})(\hat{x}_i - \bar{\hat{x}})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^N (\hat{x}_i - \bar{\hat{x}})^2}} \quad (9)$$

式中: x_i 和 \hat{x}_i 分别为真实值和预测值; \bar{x} 和 $\bar{\hat{x}}$ 分别为真实值和预测值的平均值; N 为样本数。

3.4 模型对比分析

梳理分析完成 SCADA 系统生产数据, 选取 70% 样本数据作为训练集, 30% 作为测试集, 利用建立的 BP 神经网络模型, GA-BP 油温预测模型对数据集进行训练和测试。模型均设 5 个隐藏层, 迭代 200 次, 各模型达到最低训练误差时的迭代次数和训练时间, BP、GA-BP 油温模型测试结果对比见表 2。

表 2 BP 神经网络模型、GA-BP 油温预测模型测试结果对比表
Tab. 2 Comparison of test results of BP neural network model and GA-BP oil temperature prediction model

内容	BP 神经网络模型			GA-BP 油温预测模型		
	训练误差 / °C	迭代次数 / 次	训练时间 / s	训练误差 / °C	迭代次数 / 次	训练时间 / s
1 次	0.004 370	96.0	8	0.002 836	87.0	4.0
2 次	0.003 580	72.0	7	0.002 582	65.0	3.0
3 次	0.006 770	56.0	6	0.002 113	107.0	5.0
4 次	0.693 610	79.0	7	0.002 473	110.0	5.0
5 次	0.005 450	82.0	7	0.002 929	87.0	4.0
6 次	0.004 470	83.0	7	0.001 843	48.0	3.0
7 次	0.037 630	79.0	7	0.002 823	26.0	2.0
8 次	0.003 530	113.0	9	0.002 019	71.0	3.0
9 次	0.004 290	93.0	8	0.002 092	80.0	4.0
10 次	0.853 750	85.0	7	0.001 751	72.0	3.0
平均训练误差	0.161 745	83.8	7.3	0.002 346	75.3	3.6
MAD	0.244 800	—	—	0.000 380	—	—
RMS	0.324 880	—	—	0.000 440	—	—

由表 2 可知, GA-BP 油温预测模型训练时平均训练误差、迭代次数和训练时间分别为 0.002 346 °C、75.3 次、3.6 s。相比未优化前 BP 神经网络模型, 训练过程精度、迭代次数和时间均有较大提升。GA-BP 油温预测模型训练结果的 RMS、MAD 分别为 0.000 38.0 °C 和 0.000 440 °C。在此基础上利用 BP 神经网络模型、GA-BP 油温预测模

型,对油温数据进行预测,预测结果见表3,输出误差趋势和各模型预测结果与真实值相关性曲线见图5~6。

表3 不同模型预测结果对比表

Tab. 3 Comparison of prediction results of different models

内容	误差对比	
	BP 神经网络 模型	GA - BP 油温 预测模型
误差 < 0.5 ℃ 样本 / 个	819.00	867.00
误差 < 0.5 ℃ 占比 / (%)	81.82	86.61
误差 < 1 ℃ 样本数 / 个	925.00	959.00
误差 < 1 ℃ 占比 / (%)	92.41	95.80
最大绝对误差 / ℃	5.44	3.08
RMSE / ℃	0.89	0.48
MAD / ℃	0.88	0.02
R	0.92	0.96

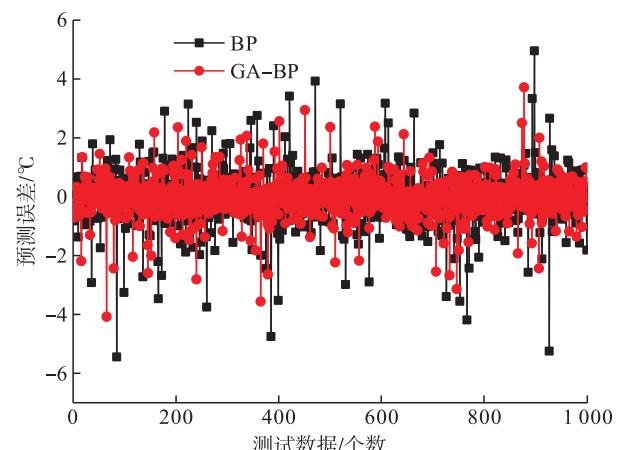
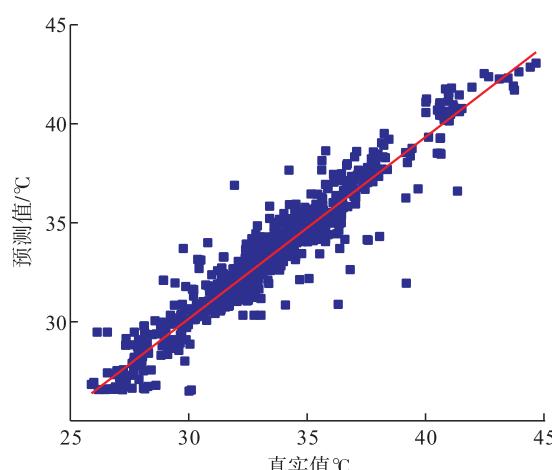


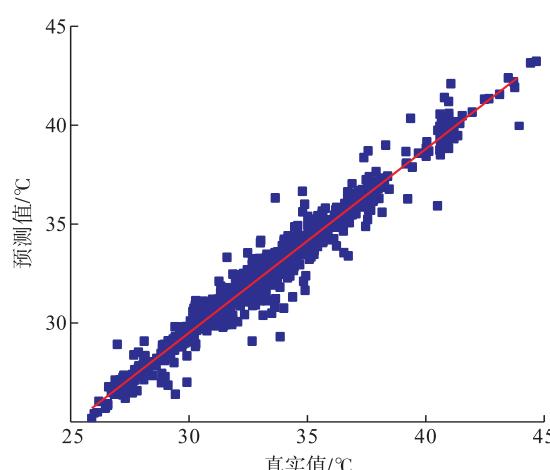
图5 油温预测误差对比图

Fig. 5 Comparison of oil temperature prediction errors



a) BP 神经网络模型的预测值与真实值

a) Predictive values and true values of the BP neural network model



b) GA - BP 油温预测模型的预测值与真实值

b) Predictive values and true values of GA-BP oil temperature prediction model

图6 各模型预测结果与真实值相关性曲线图

Fig. 6 Correlation curve between model prediction results and true values

由表3和图5可知,GA - BP 油温预测模型,预测误差较小,误差小于0.5 ℃和1 ℃的数据分别占总预测数据的86.61%和95.8%,最大绝对误差、RMSE、MAD和R分别为3.08 MPa、0.48 ℃、0.02 ℃和0.96,相比BP 神经网络模型,预测结果的准确性和稳定性提高较大。由图6可知,GA - BP 油温预测模型的预测值与实际值的离散度较小,预

测结果与实际数据的相关性较好,满足实际生产运行需要。

3.5 模型应用

将BP 神经网络模型和GA - BP 油温预测模型应用于HY热油管道各站场的油温预测,同时使用苏霍夫公式反算油温,将预测结果与实际工况数据进行误差对比,计算结果及误差对比见表4。

表4 BP 神经网络和GA - BP 油温预测模型预测值与真实值对比表

Tab. 4 Comparison of predictive values and true values of BP neural network model and GA-BP oil temperature prediction model

站场	实际油 温 /℃	BP 神经网络模型 /℃		GA - BP 油温预测模型 /℃		苏霍夫公式 /℃	
		预测值	MSE	预测值	MSE	预测值	MSE
2#站进站	26.61	27.53	3.46%	27.11	1.88%	23.08	13.27%
3#站进站	23.40	22.58	3.5%	23.77	1.58%	20.13	13.97%
末站进站	23.07	23.87	3.47%	23.39	1.39%	19.23	16.64%
误差均值	—	0.85	—	0.40	—	3.55	—

由表4可知,使用苏霍夫公式反算油温数值与真实值平均绝对误差 3.55°C ,而BP神经网络模型预测得到的绝对误差平均值为 0.85°C ,经过GA优化后预测精度进一步提高,平均绝对误差 0.40°C ,能够满足管道日常运行的使用要求。将GA-BP预测模型应用于管道智能化架构的数据挖掘层,可实现热油管道油温数据的实时在线预测,进而指导热油管道加热炉的优化调整等工作。

4 结论

1)通过研究建立管道智能化架构,架构包括物理层、数据层、数据挖掘层、应用层和用户层,其中数据挖掘层是管道智能化的核心。数据挖掘层是将生产数据,通过业务专家和数据挖掘专家将数据算法模型理论化、模型化。

2)经实际应用和对比分析,传统理论公式在数据挖掘层适用性较差,需通过基于数据挖掘算法,对实际生产数据建立相应的预测模型。

3)利用GA-BP油温预测模型,可准确预测HY热油管道油温,指导工艺运行调整。即根据业务需求,基于数据挖掘算法建立的算法模型可满足业务需求,并应用于未来管道智能化研究。

参考文献:

- [1] 唐大为,朱静.智能化管道数据采集系统设计思路初探[J].价值工程,2015,34(5):220-222.
Tang Dawei, Zhu Jing. Design Thought of Intelligence Pipeline Data Acquisition System [J]. Value Engineering, 2015, 34 (5): 220 - 222.
- [2] 徐善丹.关于智能化与数字化长输管道的探讨[J].广东化工,2015,41(11):121-122.
Xu Shandan. A Discussion About Digital and Intelligent Pipeline [J]. Guangdong Chemical Industry, 2015, 41 (11): 121 - 122.
- [3] 于达,熊毅,朱婷婷,等.输油气管道智能化事故应急体系建设[J].油气储运,2015,34(10):1038-1041.
Yu Da, Xiong Yi, Zhu Tingting, et al. An Intelligent Emergency Response System for Failure of Oil and Gas Pipeline [J]. Oil & Gas Storage and Transportation, 2015, 34 (10): 1038 - 1041.
- [4] DNV GL Group. Snam Looks to Data Science for Improved Gas Transport [EB/OL]. (2017-06-28) [2018-06-20]. <https://ers.dnvg.com/oilgas/perspectives/snam-looks-to-data-science-for-improved-gas-transport.html>.
- [5] Hochstein A, Horn E, Palomino M. Intelligent Pipeline Solution: Leveraging Breakthrough Industrial Internet Technologies and Big Data Analytics for Safer, More Efficient Oil and Gas Pipeline Operations [C]//Proceedings of the Pipeline Technology Conference 2015, 8 - 10 June, 2015, Estrel, Berlin, Germany. Berlin: Pipeline Technology Conference, 2015: 1-12.
- [6] 董绍华,安宇.基于大数据的管道系统数据分析模型及应用[J].油气储运,2015,34(10):1027-1032.
Dong Shaohua, An Yu. Data Analysis Model for Pipeline System and Its Application Based on Big Data [J]. Oil & Gas Storage and Transportation, 2015, 34 (10): 1027 - 1032.
- [7] 宋志强,张莹,张清民,等.管道裂纹漏磁检测信号WPES特征提取方法[J].天然气与石油,2015,33(3):18-22.
Song Zhiqiang, Zhang Ying, Zhang Qingmin, et al. Extraction Method for Improved MFL Signal Wavelet Packet Energy Spectrum Feature [J]. Natural Gas and Oil, 2015, 33 (3): 18 - 22.
- [8] 宿兰花,陈晓文,马晓红.一种模糊推理网络及在管道腐蚀诊断中的应用[J].天然气与石油,2010,28(1):17-19.
Su Lanhua, Chen Xiaowen, Ma Xiaohong. A Fuzzy Reasoning Network and Its Application in Pipeline Corrosion Diagnosis [J]. Natural Gas and Oil, 2010, 28 (1): 17 - 19.
- [9] 任顺顺.油气长输管道泄漏检测技术研究[J].天然气与石油,2014,32(6):25-28.
Ren Shunshun. Study on Long-Distance Oil and Gas Pipeline Leak Detection Technology [J]. Natural Gas and Oil, 2014, 32 (6): 25 - 28.
- [10] 曲志刚,封皓,靳世久,等.基于支持向量机的油气管道安全监测信号识别方法[J].天津大学学报(自然科学与工程技术版),2009,42(5):465-470.
Qu Zhigang, Feng Hao, Jin Shijiu, et al. An SVM-Based Recognition Method for Safety Monitoring Signals of Oil and Gas Pipeline [J]. Journal of Tianjin University (Science and Technology), 2009, 42 (5): 465 - 470.
- [11] 苗永梅.基于大数据分析的异常检测技术应用于石油催化[J].电子测量技术,2017,40(7):170-172.
Miao Yongmei. Anomaly Detection Based on Large Data Analysis Applied to Petroleum Catalysis [J]. Electronic Measurement Technology, 2017, 40 (7): 170 - 172.
- [12] 吴潜.大数据背景下石化工业实现智能制造的思考[J].化学工业,2016,34(2):15-18.
Wu Qian. Big Data Utilization Aiming at Smarter Manufacturing of Petrochemical Industry [J]. Chemical Industry, 2016, 34 (2): 15 - 18.
- [13] 王维斌.长输油气管道大数据管理架构及应用[J].油气储运,2015,34(3):229-232.
Wang Weibin. Big Data Management Framework and Its Application in Long-Distance Oil /Gas Pipeline [J]. Oil & Gas Storage and Transportation, 2015, 34 (3): 229 - 232.

- [14] 李冬辉,尹海燕,郑博文. 基于 MFOA-GRNN 模型的年电力负荷预测[J]. 电网技术,2018,42(2):585–590.
Li Donghui, Yin Haiyan, Zheng Bowen. An Annual Load Forecasting Model Based on Generalized Regression Neural Network with Multi-Swarm Fruit Fly Optimization Algorithm [J]. Power System Technology, 2018, 42 (2) : 585 – 590.
- [15] 唐云辉. 基于高斯过程回归的电力负荷预测算法[J]. 电子器件,2018,41(6):1436–1440.
Tang Yunhui. Load Forecasting Algorithm Based on Gauss Process Regression [J]. Chinese Journal of Electron Devices, 2018 , 41 (6) : 1436 – 1440.
- [16] 贾鹏. CBTC 车载设备在线故障诊断系统研究[J]. 铁道运输与经济,2018,40(11):94–98.
Jia Peng. A Research on Online Fault Diagnosis System of CBTC On-Board Equipment [J]. Railway Transport and Economy, 2018 , 40 (11) : 94 – 98.
- [17] 杨筱衡. 输油管道设计不与管理[M]. 东营:中国石油大学出版社,2006.
- Yang Xiaoheng. Design and Management of Oil Pipeline [M]. Dongying: China University of Petroleum Press , 2006.
- [18] Salajegheh E, Gholizadeh S. Optimum Design of Structures by an Improved Genetic Algorithm Using Neural Networks [J]. Advances in Engineering Software, 2005 , 36 (11 – 12) : 757 – 767.
- [19] Venkatesan D, Kannan K, Saravanan R. A Genetic Algorithm-Based Artificial Neural Network Model for the Optimization of Machining Processes [J]. Neural Computing and Applications, 2009 , 18 (2) : 135 – 140.
- [20] 刘润,张绍良,侯湖平,等. 基于思维进化优化 BP 神经网络的大豆叶片叶绿素含量高光谱反演[J]. 江苏农业科学,2018,46(13):212–216.
Liu Run, Zhang Shaoliang, Hou Huping, et al. Hyperspectral Retrieval Model of Chlorophyll Contents in Soybean Leaves Based on Mind Evolutionary Algorithm Optimization-BP Neural Network [J]. Jiangsu Agricultural Sciences, 2018 , 46 (13) : 212 – 216.



中国石油工程建设有限公司西南分公司获国际专利授权

2020年3月,中国石油工程建设有限公司西南分公司(以下简称“CPECC 西南分公司”)研发的“一种采用阶式制冷的天然气乙烷回收装置及方法”获得由俄罗斯知识产权局颁发的发明专利证书(专利号 2708667)。

“一种采用阶式制冷的天然气乙烷回收装置及方法”专利是100亿方/年天然气乙烷回收工艺包研发过程中产生的核心成果之一,可将单组分制冷剂多级节流,提高制冷效率,在一定程度上减小乙烷回收装置制冷部分的制冷剂压缩机负荷;具有设计简单,采购容易,单台压缩机功率较低,降低投资、能耗低和操作简单灵活的优点。

该专利的成功授权是CPECC 西南分公司技术领先战略实施具有里程碑式的重要意义,不仅标志着西南分公司研发成果获得国际权威认可,影响力从国内逐渐向国外扩展和凸显,而且该技术将为西南分公司开拓海外市场具有重要的支撑作用。

(周璇供稿)