

*Д.П. Кармачев (АО «ТомскНИПИнефть»,
Национальный исследовательский Томский политехнический университет)*

ПРИМЕНЕНИЕ МЕТОДОВ ИНТЕЛЛЕКТУАЛЬНОГО АНАЛИЗА ЭКСПЛУАТАЦИОННЫХ СТАТИСТИЧЕСКИХ ДАННЫХ ДЛЯ ПРОГНОЗИРОВАНИЯ ВРЕМЕНИ НАРАБОТКИ НА ОТКАЗ ПРОМЫСЛОВЫХ ТРУБОПРОВОДОВ

Представлены результаты исследования, направленного на создание экспертной системы выбора материального исполнения и способа внутренней антикоррозионной защиты промысловых трубопроводов в части применения различных интеллектуальных методов оценки статистических эксплуатационных данных об отказах промысловых трубопроводов. Приведены основные сведения об исходной выборке и проведенном разведочном анализе. Описаны процессы создания и оценки регрессоров, основанных на различных алгоритмах.

Ключевые слова: отказы промысловых трубопроводов, прогнозирование отказов, интеллектуальный анализ, случайный лес, градиентный бустинг, регрессионные модели.

*Кармачев Денис Павлович – ведущий инженер отдела АСУТП АО «ТомскНИПИнефть»,
Национальный исследовательский Томский политехнический университет.*

Список литературы

1. Кармачев Д.П. Определение признаков пространств в рамках разведочного анализа эксплуатационных статистических данных об отказах и условиях эксплуатации простых участков промысловых трубопроводов // Автоматизация в промышленности. 2020. №11. с. 12-16.
2. Рашка С. Python и машинное обучение. Перевод А.В. Логунова. М: ДМК Пресс, 2017. 418 с.
3. Leo Breiman. Random Forest // Machine Learning (journal): journal. 2001, Vol.45. no 1. P. 5-32.
4. Hastie T., Tibshirani R., Friedman J. Chapter 15. Random Forest//The Elements of Statistical Learning: Data Mining, Inference, and Prediction. 2nd ed. Springer-Verlag. 2009. 746p.
5. Терехов В.А., Ефимов Д.В., Тюкин И.Ю. Нейросетевые системы управления. М.: Высшая школа, 2002. 184 с.
6. Guolin Ke, Qi Meng, Thomas Finley, Taifeng Wang, Wei Chen, Weidong Ma, Qiwei Ye, Tie-Yan Liu. LightGBM: A Highly Efficient Gradient Boosting Decision Tree // Advances in Neural Information Processing Systems 30 (NIPS 2017), pp. 3149-3157.
7. Кинякин В.Н., Милевская Ю.С. Некоторые предостережения по проверке качества модели регрессии с помощью коэффициента детерминации // Вестник Московского университета МВД России. 2014. №8. с. 200-204.
8. Erin LeDell and Sebastien Poirier. H2O AutoML: Scalable Automatic Machine Learning // 7th ICML Workshop on Automated Machine Learning, 2020. <https://www.automl.org>
9. Prokhorenkova L., Gusev G., Vorobev A., Dorogush A.V., Gulin A. CatBoost: unbiased boosting with categorical features//NeurIPS, 2018, arXiv:1706.09516. <https://arxiv.org/abs/1706.09516>.

10. Dorogush A.V., Ershov V., Gulin A. CatBoost: gradient boosting with categorical features support // Workshop on ML Systems at NIPS. 2017. <http://learningsys.org>.
11. Созыкин А.В. Обзор методов обучения глубоких нейронных сетей // Вестник ЮУрГУ. Серия «Вычислительная математика и информатика». 2017. Т. 6. №3.

Karmachev D.P. Field data mining in field pipeline life prediction

The paper presents the results of the research aimed at the development of an expert system for selecting the material and internal corrosion protection of field pipelines based on pipeline failure data mining. Basic information about the initial sample and the exploration analysis undertaken is provided. The development and assessment of regressors by various algorithms is described.

Keywords: field pipeline failures, failure prediction, data mining, random forest, gradient boosting, regression models.