

Received: 22.01.2026

Revised: 28.04.2026

Accepted: 22.05.2026

DOI: 10.17804/2410-9908.2026.4.088-115

THE DEVELOPMENT TRENDS IN FAULT DETECTION METHODS FOR HYDRAULIC DRIVE SYSTEMS AND CHANGES IN INTELLIGENT DIAGNOSIS TECHNOLOGY

Zhou Zitian

*Baltic State Technical University "VOENMEH" named after D. F. Ustinov,
1 Pervaya Krasnoarmeiskaya St., Saint-Petersburg, 190005, Russia*

 <https://orcid.org/0009-0004-7776-9202>  chzhou_tszytian@voenmeh.ru

Email: chzhou_tszytian@voenmeh.ru

Address for correspondence: ul. Pervaya Krasnoarmeiskaya, 1, Saint-Petersburg, 190005, Russia

Currently, hydraulic system fault diagnosis technologies are transitioning from traditional methods to intelligent ones. This change is an inevitable result driven by the real-time interaction of objective circumstances rather than an isolated technological event. The state-of-the-art artificial intelligence algorithm technologies, popularization of computational algorithms, as well as the rapid development of detection technologies and information technologies, provide a technical foundation for the creation and development of intelligent fault diagnosis technologies. The high-quality demand in the market has driven the wave of industrial system development towards intelligence. In this context, intelligent fault diagnosis has significant advantages over traditional fault diagnosis methods. The transition from traditional diagnostic technologies to intelligent ones is a systematic change driven by industrial technological progress trends, a massive database, the underlying technological support, and, ultimately, market demand. This paper analyzes the transition trends of hydraulic systems from traditional diagnostic technologies to intelligent ones, the advantages and disadvantages of intelligent diagnostic technologies, the technical support required for comprehensive implementation of intelligent diagnostic systems, as well as the development path of intelligent systems. It thoroughly analyzes the core technologies of intelligent systems (artificial intelligence algorithms), the specific problems that need to be solved in intelligent diagnostic systems, and their specific mature technologies (algorithms, models, etc.). The main challenges currently faced by intelligent diagnosis are discussed, as well as future lines of research that will reveal the inherent logic and inevitability of this technological transformation.

Keywords: hydraulic system, fault diagnosis, intelligent diagnosis, predictive maintenance, Industry 4.0, convolutional neural networks, learning transfer, signal processing, traditional diagnosis

Acknowledgment

Thanks are due to Roman V. Melnikov, my research supervisor, for his assistance in writing this paper.

References

1. Dai, J., Tang, J., Huang, S., and Wang, Y. Signal-based intelligent hydraulic fault diagnosis methods: review and prospects. *Chinese Journal of Mechanical Engineering*, 2019, 32 (1), 75. DOI: 10.1186/s10033-019-0388-9.

2. Sun, J., Ding, H., Li, N., Sun, X., and Dong, X. Intelligent fault diagnosis of hydraulic system based on multiscale one-dimensional convolutional neural networks with multi attention mechanism. *Sensors (Basel)*, 2024, 24 (22), 7267. DOI: 10.3390/s24227267.
3. Kong, X., Cai, B., Yu, Y., Yang, J., Wang, B., Liu, Z., Shao, X., and Yang, C. Intelligent diagnosis method for early faults of electric-hydraulic control system based on residual analysis. *Reliability Engineering and System Safety*, 2025, 261 (C), 111142. DOI: 10.1016/j.ress.2025.111142.
4. Yin, H., Wang, Y., Sun, W., and Wang, L. Fault diagnosis of hydraulic system based on DS evidence theory and SVM. *International Journal of Hydromechatronics*, 2024, 7 (1), 1–15. DOI: 10.1504/IJHM.2024.135976
5. Gonzalez-Jimenez, D., del-Olmo, J., Poza, J., Garramiola, F., and Madina, P. Data-driven fault diagnosis for electric drives: a review. *Sensors*, 2021, 21 (12), 4024. DOI: 10.3390/s21124024.
6. Qiu, S., Cui, X., Ping, Z., Shan, N., Li, Z., Bao, X., and Xu, X. Deep learning techniques in intelligent fault diagnosis and prognosis for industrial systems: a review. *Sensors*, 2023, 23 (3), 1305. DOI: 10.3390/s23031305.
7. Dai, J., Tang, J., Huang, S., and Wang, Y. Signal-based intelligent hydraulic fault diagnosis methods: review and prospects. *Chinese Journal of Mechanical Engineering*, 2019, 32 (1), 75. DOI: 10.1186/s10033-019-0388-9.
8. Leite, D., Andrade, E., Rativa, D., and Maciel, A.M.A. Fault detection and diagnosis in industry 4.0: a review on challenges and opportunities. *Sensors (Basel)*, 2024, 25 (1), 60. DOI: 10.3390/s25010060.
9. Hinton, G.E. and Salakhutdinov, R.R. Reducing the dimensionality of data with neural networks. *Science*, 2006, 313 (5786), 504–507. DOI: 10.1126/science.1127647.
10. Zhou, X. and Lei, X. Fault diagnosis method of the construction machinery hydraulic system based on artificial intelligence dynamic monitoring. *Mobile Information Systems*, 2021, 2021 (1), 1093960. DOI: 10.1155/2021/1093960.
11. Peng, K.-X., Ma, L., and Zhang, K. Review of quality-related fault detection and diagnosis techniques for complex industrial processes. *Acta Automatica Sinica*, 2017, 43 (3), 349–365. DOI: 10.16383/j.aas.2017.c160427.
12. Liu, Y., Zhang, R., He, Z., Huang, Q., Zhu, R., Li, H., and Fu, Q. The study of hydraulic machinery condition monitoring based on anomaly detection and fault diagnosis. *Measurement*, 2024, 230, 114518. DOI: 10.1016/j.measurement.2024.114518.
13. Keleko, A.T., Kamsu-Foguem, B., Ngouna, R.H., and Tongne, A. Artificial intelligence and real-time predictive maintenance in industry 4.0: a bibliometric analysis. *AI and Ethics*, 2022, 2 (4), 553–577. DOI: 10.1007/s43681-021-00132-6.
14. Zhu, Y., Dai, W., Sun, L., Yao, Y., Chang, C., Guo, W., Zhang, Z., and Chen, Y. CN 119474787 A, 2025.
15. Fawwaz, D.Z. and Chung, S.H. Real-time and robust hydraulic system fault detection via edge computing. *Applied Sciences*, 2020, 10 (17), 5933. DOI: 10.3390/app10175933.
16. Kong, X., Cai, B., Zou, Z., Wu, Q., Wang, C., Yang, J., Wang, B., and Liu, Y. Three-model-driven fault diagnosis method for complex hydraulic control system: subsea blowout preventer system as a case study. *Expert Systems with Applications*, 2024, 247, 123297. DOI: 10.1016/j.eswa.2024.123297.
17. Khaziev, E.L. and Khaziev, M.L. Intelligent diagnostic system for hydraulic actuator. In: *International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM)*, Sochi, Russia, 2019, IEEE, pp. 1–6. DOI: 10.1109/ICIEAM.2019.8742779.
18. Zhang, Z. and Li, J. A review of artificial intelligence in embedded systems. *Micromachines*, 2023, 14 (5), 897. DOI: 10.3390/mi14050897.
19. Gheibi, O., Weyns, D., and Quin, F. Applying machine learning in self-adaptive systems: a systematic literature review. *ACM Transactions on Autonomous and Adaptive Systems (TAAS)*, 2021, 15 (3), 1–37. DOI: 10.1145/3469440.

20. Leskovets, I.V., Grats, A.A., and Rogozhyn, V.D. Diagnostics of hydraulic drive of airfield equipment. *Vestnik SibADI*, 2025, 22 (3), 356–367. (In Russian). DOI: 10.26518/2071-7296-2025-22-3-356-367.
21. Chernukhin, A.V. *Avtomatizirovannaya sistema prognozirovaniya tekhnicheskogo sostoyaniya promyshlennogo oborudovaniya na baze metodov iskusstvennogo intellekta* [An AI-Based Automated System for Predicting the Technical Condition of Industrial Equipment: Cand. Thesis]. Moscow, 2025, 186 p. (In Russian).
22. Yablokov, A.E. *Nauchno-prakticheskie osnovy sozdaniya avtomatizirovannykh sistem tekhnicheskogo monitoringa i diagnostiki oborudovaniya zernopererabatyvayushchikh predpriyatiy na baze neyrosetevykh metodov analiza dannykh* [Scientific and Practical Foundations for Creating Automated Systems for Technical Monitoring and Diagnostics of Equipment at Grain Processing Plants with the Application of Neural Network Data Analysis Methods : Doctoral Thesis]. Moscow, 2022, 377 p. (In Russian).
23. Fenton, W.G., McGinnity, T.M., and Maguire, L.P. Fault diagnosis of electronic systems using intelligent techniques: a review. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 2001, 31 (3), 269–281. DOI: 10.1109/5326.971655.
24. Dai, X. and Gao, Z. From model, signal to knowledge: a data-driven perspective of fault detection and diagnosis. *IEEE Transactions on Industrial Informatics*, 2013, 9 (4), 2226–2238. DOI: 10.1109/TII.2013.2243743.
25. Isermann, R. *Fault-Diagnosis Systems: An Introduction from Fault Detection to Fault Tolerance*, Springer, Berlin, Heidelberg, 2005, 475 p. DOI: 10.1007/3-540-30368-5.
26. Yan, W., Wang, J., Lu, S., Zhou, M., and Peng, X. A review of real-time fault diagnosis methods for industrial smart manufacturing. *Processes*, 2023, 11 (2), 369. DOI: 10.3390/pr11020369.
27. Klingenberg, C.O., Viana Borges, M.A., and do Vale Antunes, J.A. Industry 4.0: What makes it a revolution? A historical framework to understand the phenomenon. *Technology in Society*, 2022, 70, 102009. DOI: 10.1016/j.techsoc.2022.102009.
28. Martinelli, A., Mina, A., and Moggi, M. The enabling technologies of industry 4.0: examining the seeds of the fourth industrial revolution. *Industrial and Corporate Change*, 2021, 30 (1), 161–188. DOI: 10.1093/icc/dtaa060.
29. Ghobakhloo, M. Industry 4.0, digitization, and opportunities for sustainability. *Journal of Cleaner Production*, 2020, 252, 119869. DOI: 10.1016/j.jclepro.2019.119869.
30. Javaid, M., Haleem, A., Singh Pratap, R., Suman, R., and Santibañez Gonzalez, E. Understanding the adoption of Industry 4.0 technologies in improving environmental sustainability. *Sustainable Operations and Computers*, 2022, 3, 203–217. DOI: 10.1016/j.susoc.2022.01.008.
31. Angelopoulos, A., Michailidis, E.T., Nomikos, N., Trakadas, P., Hatziefremidis, A., Voliotis, S., and Zahariadis, T. Tackling faults in the Industry 4.0 era – a survey of machine-learning solutions and key aspects. *Sensors*, 2020, 20 (1), 109. DOI: 10.3390/s20010109.
32. O'Donovan, P., Gallagher, C., Bruton, K., and O'Sullivan, D.T.J. A fog computing industrial cyber-physical system for embedded low-latency machine learning Industry 4.0 applications. *Manufacturing Letters*, 2018, 15, part B, 139–142. DOI: 10.1016/j.mfglet.2018.01.005.
33. Wan, J., Yang, J., Wang, Z., and Hua, Q. Artificial intelligence for cloud-assisted smart factory. *IEEE Access*, 2018, 6, 55419–55430. DOI: 10.1109/ACCESS.2018.2871724.
34. Lee, H. Framework and development of fault detection classification using IoT device and cloud environment. *Journal of Manufacturing Systems*, 2017, 43 (2), 257–270. DOI: 10.1016/j.jmsy.2017.02.007.
35. Zonta, T., Da Costa, C.A., Da Rosa Righi, R., De Lima, M.J., Da Trindade, E.S., and Li, P.G. Predictive maintenance in the Industry 4.0: a systematic literature review. *Computers & Industrial Engineering*, 2020, 150, 106889. DOI: 10.1016/j.cie.2020.106889.

36. Li, L., Ota, K., and Dong, M. Deep learning for smart industry: efficient manufacture inspection system with fog computing. *IEEE Transactions on Industrial Informatics*, 2018, 14 (10), 4665–4673. – DOI: 10.1109/TII.2018.2842821.
37. Lavassani, M., Forsström, S., Jennehag, U., and Zhang, T. Combining fog computing with sensor mote machine learning for industrial IoT. *Sensors*, 2018, 18 (5), 1532. DOI: 10.3390/s18051532.
38. Sodhro, A.H., Pirbhulal, S., and de Albuquerque, V.H.C. Artificial intelligence-driven mechanism for edge computing-based industrial applications. *IEEE Transactions on Industrial Informatics*, 2019, 15 (7), 4235–4243. DOI: 10.1109/TII.2019.2902878.
39. Wu, D., Liu, S., Zhang, L., Terpenney, J., Gao, R., Kurfess, T., and Guzzo, J. A fog computing-based framework for process monitoring and prognosis in cyber-manufacturing. *Journal of Manufacturing Systems*, 2017, 43 (1), 25–34. DOI: 10.1016/j.jmsy.2017.02.011.
40. Raptis, T.P., Passarella, A., and Conti, M. Data management in industry 4.0: state of the art and open challenges. *IEEE Access*, 2019, 7, 97052–97093. DOI: 10.1109/ACCESS.2019.2929296.
41. Tsanousa, A., Bektsis, E., Kyriakopoulos, C., González, A.G., Leturiondo, U., Gialampoukidis, I., Karakostas, A., Vrochidis, S., and Kompatsiaris, I. A review of multisensor data fusion solutions in smart manufacturing: systems and trends. *Sensors*, 2022, 22 (5), 1734. DOI: 10.3390/s22051734.
42. Kok, S.P., Go, Y.I., Wang, X., and Wong, M.L.D. Advances in fiber Bragg grating (FBG) sensing: a review of conventional and new approaches and novel sensing materials in harsh and emerging industrial sensing. *IEEE Sensors Journal*, 2024, 24 (19), 29485–29505. DOI: 10.1109/JSEN.2024.3434351.
43. arXiv:2411.02086v1 [cs.NI]
44. Georgiou, T., Liu, Y., Chen, W., and Lew, M. A survey of traditional and deep learning-based feature descriptors for high dimensional data in computer vision. *International Journal of Multimedia Information Retrieval*, 2020, 9 (3), 135–170. DOI: 10.1007/s13735-019-00183-w.
45. Raju, S., Jagtap, V., Kulkarni, P., Ravikanth, M., and Rafeeq, M. Speech recognition to build context: a survey. In: *2020 International Conference on Computer Science, Engineering and Applications (ICCSEA)*, Gunupur, India, 13–14 March 2020, IEEE, 2020, pp. 1–7. DOI: 10.1109/ICCSEA49143.2020.9132848.
46. Chowdhary, K.R. Natural language processing. In: *Fundamentals of Artificial Intelligence*, Springer, New Delhi, 2020, pp. 603–649. DOI: 10.1007/978-81-322-3972-7_19.
47. Ye, Z. and Yu, J. Multi-level features fusion network-based feature learning for machinery fault diagnosis. *Applied Soft Computing*, 2022, 122, 108900. DOI: 10.1016/j.asoc.2022.108900.
48. Hou, H., Ding, S., and Xu, X. A deep clustering by multi-level feature fusion. *International Journal of Machine Learning and Cybernetics*, 2022, 13 (10), 2813–2823. DOI: 10.1007/s13042-022-01557-z.
49. Taye, M.M. Theoretical understanding of convolutional neural network: concepts, architectures, applications, future directions. *Computation*, 2023, 11 (3), 52. DOI: 10.3390/computation11030052.
50. Kulin, M., Kazaz, T., Moerman, I., and De Poorter, E. End-to-end learning from spectrum data: a deep learning approach for wireless signal identification in spectrum monitoring applications. *IEEE Access*, 2018, 6, 18484–18501. DOI: 10.1109/ACCESS.2018.2818794.
51. Li, Y., Gu, X., and Wei, Y. A deep learning-based method for bearing fault diagnosis with few-shot learning. *Sensors*, 2024, 24 (23), 7516. DOI: 10.3390/s24237516.
52. Liu, Y., Shu, Y., Xu, Z., Han, S., Zhang, C., and Chen, M. One-dimensional convolutional neural network model driven intelligent operation phases identification of hydraulic press using energy data. *Engineering Applications of Artificial Intelligence*, 2025, 155, 111079. DOI: 10.1016/j.engappai.2025.111079.

53. Portnoff, M. Time-frequency representation of digital signals and systems based on short-time Fourier analysis. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1980, 28 (1), 55–69. DOI: 10.1109/TASSP.1980.1163359.
54. Alsberg, B.K., Woodward, A.M., and Kell, D.B. An introduction to wavelet transforms for chemometricians: a time-frequency approach. *Chemometrics and Intelligent Laboratory Systems*, 1997, 37 (2), 215–239.
55. Wang, H., Zhou, J., Chen, H., Xu, B., and Shen, Z. Hydraulic system fault diagnosis decoupling method based on 2D time-series modeling and self-attention fusion. *Scientific Reports*, 2024, 14 (1), 15620. DOI: 10.1038/s41598-024-66541-9.
56. Zhang, P., Cheng, J., Chen, Q., Zheng, Z., Wei, C., Zou, T., Sun, W. and Huang, Y. Near-infrared spectroscopy coupled with Gramian angular field two-dimensional convolutional neural network for white tea adulteration detection. *Journal of the Science of Food and Agriculture*, 2025, 105, 6269–6279. DOI: 10.1002/jsfa.14353.
57. Fan, L., Dang, B., Wang, Z., and Zhang, R. Multimodal 1D-to-2D signal transformation and pulse disease recognition. In: *AIPR '23: Proceedings of the 2023 6th International Conference on Artificial Intelligence and Pattern Recognition*, 2024, pp. 324–330. DOI: 10.1145/3641584.3641632.
58. Li, Q., Zou, Y., Long, G.H., and Wu, W. Ferromagnetic resonance over-voltage identification method based on Gram angle field. *Energy Reports*, 2022, 8 (6), 546–558. DOI: 10.1016/j.egyr.2022.03.156.
59. Long, Y, Zhou, W, and Luo, Y. A fault diagnosis method based on one-dimensional data enhancement and convolutional neural network. *Measurement*, 2021, 180, 109532. DOI: 10.1016/j.measurement.2021.109532.
60. Zhao, H, Sun, S, and Jin, B. Sequential fault diagnosis based on LSTM neural network. *IEEE Access*, 2018, 6, 12929–12939. DOI: 10.1109/ACCESS.2018.2794765.
61. Mienye, I.D., Swart, T.G., and Obaido, G. Recurrent neural networks: a comprehensive review of architectures, variants, and applications. *Information*, 2024, 15 (9), 517. DOI: 10.3390/info15090517.
62. Ahmed, I., Ahmad, M., Chehri, A., and Jeon, G. A smart-anomaly-detection system for industrial machines based on feature autoencoder and deep learning. *Micromachines*, 2023, 14 (1), 154. DOI: 10.3390/mi14010154.
63. Shao, S., McAleer, S., Yan, R., and Baldi, P. Highly accurate machine fault diagnosis using deep transfer learning. *IEEE Transactions on Industrial Informatics*, 2018, 15 (4), 2446–2455. DOI: 10.1109/TII.2018.2864759.
64. arXiv:1608.08614 [cs.CV]
65. Zhang, S., Zhang, S., Wang, B., and Habetler, T.G. Deep learning algorithms for bearing fault diagnostics – a comprehensive review. *IEEE Access*, 2020, 8, 29857–29881. DOI: 10.1109/ACCESS.2020.2972859.
66. Han, T., Li, Y.F., and Qian, M. A hybrid generalization network for intelligent fault diagnosis of rotating machinery under unseen working conditions. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70, 3520011, 1–11. DOI: 10.1109/TIM.2021.3088489.
67. Lee, J., Ni, J., Singh, J., Jiang, B., Azamfar, M., and Feng, J. Intelligent maintenance systems and predictive manufacturing. *Journal of Manufacturing Science and Engineering*, 2020, 142 (11), 110805. DOI: 10.1115/1.4047856.
68. Zhang, K., Xu, J., Min, M. R., Jiang, G., Pelechris, K., and Zhang, H. Automated IT system failure prediction: a deep learning approach. In: *2016 IEEE International Conference on Big Data (Big Data)*, IEEE, 2016, 1291–1300. DOI: 10.1109/BigData.2016.7840733.
69. Cvetković, V.M., Renner, R., and Jakovljević, V.R. Industrial disasters and hazards: From causes to consequences – a holistic approach to resilience. *International Journal of Disaster Risk Management*, 2024, 6 (2), 149–168. DOI: 10.18485/ijdrm.2024.6.2.10.

70. Park, J. and Kang, D. Artificial intelligence and smart technologies in safety management: a comprehensive analysis across multiple industries. *Applied Sciences*, 2024, 14 (24), 11934. DOI: 10.3390/app142411934.
71. Luo, L., Song, Y., Liu, Y., and Jiang, X. The research on intelligent safety risk assessment and early warning mechanisms for power systems based on big data and artificial intelligence technology. *Advances in Resources Research*, 2025, 5 (2), 666–688. DOI: 10.50908/arr.5.2_666.
72. Owens, J.D., Houston, M., Luebke, D., Green, S., Stone, J.E., and Phillips, J.C. GPU computing. In: *Proceedings of the IEEE*, IEEE, 2008, 96 (5), 879–899. DOI: 10.1109/JPROC.2008.917757.
73. arXiv:2412.06044v1 [cs.DC]
74. Duan, S., Wang, D., Ren, J., Lyu, F., Zhang, Y., and Wuet, H. Distributed artificial intelligence empowered by end-edge-cloud computing: a survey. *IEEE Communications Surveys & Tutorials*, 2022, 25 (1), 591–624. DOI: 10.1109/COMST.2022.3218527.
75. Landaluce, H., Arjona, L., Perallos, A., Falcone, F., Angulo, I., and Muralter, F. A review of IoT sensing applications and challenges using RFID and wireless sensor networks. *Sensors*, 2020, 20 (9), 2495. DOI: 10.3390/s20092495.
76. Sehrawat, D. and Gill, N.S. Smart sensors: analysis of different types of IoT sensors. In: *2019 3rd International Conference on Trends in Electronics and Informatics (ICOEI)*, Tirunelveli, India, 2019, IEEE, 2019, pp. 523–528. DOI: 10.1109/ICOEI.2019.8862778.
77. Alahmad, T., Neményi, M., and Nyéki, A. Applying IoT sensors and big data to improve precision crop production: a review. *Agronomy*, 2023, 13 (10), 2603. DOI: 10.3390/agronomy13102603.
78. arXiv:2111.06061v3 [cs.LG]
79. Yazdi, M., Mohammadpour, J., Li, H., Huang, H.-Z., Zarei, E., Pirbalouti, R.G., and Adu-mene, S. Fault tree analysis improvements: a bibliometric analysis and literature review. *Quality and Reliability Engineering International*, 2023, 39 (5), 1639–1659. DOI: 10.1002/qre.3271.

Подана в журнал: 22.01.2026

УДК 621.22

OECD 2.03

DOI: 10.17804/2410-9908.2026.4.088-115

ТЕНДЕНЦИИ РАЗВИТИЯ МЕТОДОВ ОБНАРУЖЕНИЯ НЕИСПРАВНОСТЕЙ СИСТЕМ ГИДРАВЛИЧЕСКОГО ПРИВОДА И ИЗМЕНЕНИЯ В ТЕХНОЛОГИИ ИНТЕЛЛЕКТУАЛЬНОЙ ДИАГНОСТИКИ

Чжоу Цзытянь

Федеральное государственное бюджетное образовательное учреждение высшего образования
«Балтийский государственный технический университет ВОЕНМЕХ» им. Д. Ф. Устинова,
ул. 1-я Красноармейская, д. 1, г. Санкт-Петербург, 190005, Россия

 <https://orcid.org/0009-0004-7776-9202>  chzhou_tszytian@voenmeh.ru

Электронная почта: chzhou_tszytian@voenmeh.ru

Адрес для переписки: ул. 1-я Красноармейская, д. 1, г. Санкт-Петербург, 190005, Россия

В настоящее время технологии диагностики неисправностей гидравлических систем переходят от традиционных методов к интеллектуальным, и это изменение является не изолированным технологическим событием, а неизбежным результатом взаимодействия объективных обстоятельств в реальном времени. Современные компьютерные алгоритмические технологии искусственного интеллекта, популяризация вычислительных алгоритмов, быстрое развитие технологий обнаружения и информационных технологий обеспечивают техническую основу для создания и развития интеллектуальных технологий диагностики неисправностей. Высокое качество спроса на рынке способствует волне интеллектуального развития промышленных систем. Интеллектуальная технология диагностики неисправностей в этом контексте имеет значительные преимущества по сравнению с традиционными методами диагностики неисправностей. Переход от традиционных диагностических технологий к интеллектуальным – это систематическое изменение, вызванное тенденциями научно-технического прогресса в промышленности, массивной базой данных, базовой технологической поддержкой и в конечном итоге рыночным спросом. В этой статье анализируются тенденции перехода гидравлических систем от традиционных диагностических технологий к интеллектуальным диагностическим технологиям, преимущества и недостатки интеллектуальных диагностических технологий, техническая поддержка, необходимая для всесторонней реализации интеллектуальных диагностических систем, а также путь развития интеллектуальных систем, тщательный анализ основных технологий интеллектуальных систем (алгоритмов искусственного интеллекта), которые нуждаются в решении проблем в интеллектуальных диагностических системах и их конкретных зрелых технологиях (алгоритмы, модели и т. д.). Рассматриваются основные проблемы, с которыми сталкивается интеллектуальная диагностика в настоящее время, и будущие направления исследований, которые позволят выявить внутреннюю логику и неизбежность этого изменения типа технологии.

Ключевые слова: гидравлическая система, диагностика неисправностей, умная диагностика, прогнозируемое обслуживание, Индустрия 4.0, сверточные нейронные сети, перемещение обучения, обработка сигналов, традиционная диагностика

1. Введение

Гидравлическая система является одним из основных типов привода и трансмиссий современного промышленного оборудования. Надежность ее работы напрямую связана с безопасностью производства, сроком службы оборудования и экономическими показателями.

ми. С развитием промышленного оборудования в направлении высокой скорости, высокого давления, высокой точности и высокой степени интеграции сложность гидравлической системы растет с каждым годом, режимы отказов также становятся все более скрытыми и сложными. В этом контексте эффективные и точные методы диагностики неисправностей стали ключом к обеспечению безопасной и стабильной работы системы и достижению прогнозного обслуживания [6, 8].

Традиционная технология диагностики неисправностей гидравлической системы в основном зависит от физических моделей, классической обработки сигналов и экспертного опыта. Такие методы основаны на причинно-следственных связях и правилах суждений (например, анализ дерева неисправностей) [79], хотя они имеют высокую интерпретируемость, но их диагностическая эффективность в значительной степени зависит от накопления опыта профессионалов. Им присущи ограничения, такие как трудности извлечения характеристик, низкая степень автоматизации, недостаточная способность распознавать сложные неисправности и ранние слабые неисправности [3], особенно перед лицом нелинейных современных гидравлических систем с большим числом степеней свободы, адаптивность и обобщение данных традиционных методов сталкиваются с серьезными проблемами.

В последние годы глобальная волна развития промышленного интеллекта, представленная Индустрией 4.0 и промышленным интернетом [27], глубоко перестраивает технологическую систему производства. Быстрое развитие современных компьютерных технологий, технологий обнаружения и информационных технологий обеспечивает основу для применения искусственного интеллекта (ИИ) [1]. Интеллектуальные методы диагностики неисправностей, особенно алгоритмы ИИ, представленные машинным обучением и глубоким обучением, демонстрируют значительные преимущества благодаря своим мощным возможностям распознавания сложных режимов и автоматического обучения характеристикам [10]. Это технологическое изменение – не единичное событие, а системный процесс, движимый тенденциями научно-технического прогресса в макропромышленности, массивными данными, лежащими в их основе технологиями и в конечном итоге рыночным спросом [28]. Распространение недорогих датчиков и IoT делает возможным всепогодный и многомерный сбор данных с нескольких источников в гидравлических системах [41, 42]. Этот большой и всесторонний сбор многомерных данных обеспечивает «топливо» для интеллектуальной диагностики, основанной на данных, в то время как инновации алгоритмов и прорывы вычислительных алгоритмов дают отличную способность обрабатывать большие объемы данных и создавать модели глубоких неисправностей.

В настоящее время диагностика неисправностей гидравлических систем находится на решающем этапе эволюции от традиционных методов к интеллектуальным методам. Интеллектуальная диагностика приносит значительные результаты в повышении точности диагностики, уровня автоматизации и возможностей раннего предупреждения. Например, точность диагностики на основе сверточных нейронных сетей [52], моделей обучения миграции [63] может превышать 95 %. Тем не менее ее развитие по-прежнему сталкивается с рядом проблем, таких как качество и дефицит промышленных данных [5], проблемы интерпретируемости, вызванные модельным «черным ящиком» [13], и сложность применения – от лаборатории до промышленного применения на месте. Поэтому систематическое и географическое выяснение технических характеристик, преимуществ и ограничений традиционной и интеллектуальной диагностики и изучение пути их интеграции имеют важное теоретическое и инженерное значение для содействия здоровому развитию технологий в этой области.

Цель этой статьи – систематически проанализировать тенденции развития технологии диагностики неисправностей гидравлических систем (переход от традиционной диагностики к интеллектуальной). В статье произведено сравнение основных принципов двух технологических маршрутов, их технологической зависимости, возможностей обработки данных, а также уточнены их существенные различия и взаимодополняющие связи. Основываясь на

углубленном анализе основных технологий, поддерживающих интеллектуальную диагностику, включая алгоритмы ИИ (такие как анализ временной частоты во временном диапазоне, преобразование формы данных, модели глубокого обучения) и вспомогательные технологии (вычислительная сила, сенсорное зондирование, облачная боковая архитектура), можно изучить основные проблемы, стоящие перед текущей интеллектуальной диагностикой, и будущие направления исследований. Благодаря комплексному анализу интерпретируется внутренняя логика и неизбежность перехода от традиционных методов диагностики неисправностей к интеллектуальным методам диагностики, а также обозначены возможные направления последующих исследований и возможное практическое применение.

2. Достижения и преимущества интеллектуальных методов диагностики (по сравнению с традиционной диагностикой)

Выявление и диагностика ранних неисправностей в традиционных методах диагностики является важной темой исследований, и из-за высокой степени скрытности и случайности ранних неисправностей их ранние проявления часто являются незначительными изменениями или неприемлемыми аномальными сигналами. Таким образом, традиционные методы диагностики могут не улавливать эти незначительные изменения вовремя, и обычно характеристики неисправности на ранних стадиях неочевидны. Раннее распознавание сигналов и определение характеристик неисправностей имеют сложности, которые трудно преодолеть с помощью традиционных технологий. К таким сложностям относятся слабость сигналов и их скрытность вследствие шумового фона, неопределенность локализации и проблемы интерпретации.

Основные проблемы, влияющие на адекватность диагностики традиционными методами, следующие.

Характерная слабость и шумовое маскирование: ранняя неисправность имеет низкую интенсивность сигнала, разное отношение величины целевого сигнала к шуму, в общем фоне сигналов часто доминируют сигналы самого диагностируемого устройства и шум окружающей среды. Это создает огромные трудности для традиционных методов обработки сигналов при извлечении слабых характеристик неисправности из сложного фона, что приводит к недостаточной чувствительности алгоритмов идентификации [3].

Неопределенность и проблема воспроизведения: ранняя неисправность имеет значительную неопределенность, которая проистекает из случайных факторов, таких как деградация материалов и различия в сборке, и в значительной мере зависит от нелинейности системы. Эта неопределенность затрудняет точное моделирование и выявление неисправности в лаборатории, что, в свою очередь, приводит к недостаточному пониманию эволюционных закономерностей и типичных характеристик этой неисправности и создает проблемы для построения точных диагностических моделей [3].

Для вышеуказанных двух проблем, которые трудно решить с помощью традиционных методов диагностики, интеллектуальная диагностика имеет высокую эффективность. Интеллектуальный метод диагностики может обнаруживать признаки неисправности, которые трудно уловить человеческим глазом или простым алгоритмом. Например, есть исследования, которые усиливают слабые сигналы раннего отказа с помощью анализа остатков и в сочетании с байесовой сетью (BN). Созданная модель диагностики неисправностей, основанная на периодических, шумовых, линейных и нелинейных характеристиках в раздельном сигнале, на основе анализа чувствительности характеристик устанавливает причинно-следственную связь между неисправностью и характеристикой, значительно улучшает диагностируемость ранней неисправности системы электрогидравлического управления подводным превентором путем создания модели оценки факторов коррекции на основе анализа характеристик остатков и использования этого фактора для коррекции результатов ранней диагностики неисправностей [3].

Ни традиционные, ни интеллектуальные методы диагностики не могут развиваться независимо от компьютерных сетевых технологий, в то время как традиционные методы диагностики гидравлических систем имеют серьезные недостатки в технологии использования сигнальных методов диагностики неисправностей нейронных сетей. Основные недостатки следующие [1]:

1) характеристики были обработаны вручную, поэтому может отсутствовать объективность;

2) в процессе обработки сигналов (при извлечении характеристик и распознавании образов) используются отдельные модели, которые не могут быть совместно оптимизированы в глобальном масштабе;

3) эти методы используют менее глубокую архитектуру алгоритмов машинного обучения, что затрудняет глубокое изучение основных характеристик неисправности.

В то время как глубокое обучение, на которое опираются интеллектуальные диагностические технологии, изменяет диагностический процесс и может достигать сквозной автоматической диагностики, модели, такие как сверточные нейронные сети (CNN), могут автоматически изучать характеристики неисправности непосредственно из исходного вибрационного сигнала или звукового сигнала, достигая сквозной диагностики и уменьшая отклонения, вводимые искусственным формированием характеристик [1]. И Хинтон предложил неконтролируемый алгоритм обучения для глубоких сетей доверия (DBN) [9], который решил проблему глубины обучения модели и вызвал бурный рост исследований в этой области [1]. Недавнее исследование 2024 года также создало крупномасштабную одномерную сверточную нейронную сеть (MA-MS1DCNN) и представило механизм множественного внимания, который может более эффективно обрабатывать данные с различными частотами дискретизации в гидравлических системах. Она даже может демонстрировать превосходные диагностические характеристики по сравнению с существующими методами, такими как Shapelet, MCIFM и CNN [2]. Эти технологические прорывы подготовили почву для зрелости и полного внедрения интеллектуальных диагностических технологий.

Результаты диагностики неисправностей гидравлической системы показали, что эти неисправности в основном являются сложными комплексными неисправностями, связанными с переплетением различных факторов, что не позволяет точно и эффективно обрабатывать сложные неисправности и является основной проблемой в традиционных методах диагностики. Различные частоты сбора данных в гидравлических системах и сложные взаимозависимости внутри данных создают проблемы для существующих алгоритмов диагностики неисправностей [4]. Интеллектуальные методы диагностики, такие как сочетание теории доказательств D-S с моделью, поддерживающей векторную машину (SVM), могут эффективно интегрировать информацию с нескольких датчиков, выносить комплексное суждение о сложных неисправностях, повышать надежность и точность диагностических выводов, основанных на теории доказательств D-S, на информации, полученной с нескольких датчиков; по сравнению с методом диагностики PCA-SVM, основанным на информации с одним датчиком, точность диагностики может быть увеличена примерно на 3,26 %. [4]. Из этого можно видеть, что переход от традиционной диагностики к интеллектуальной является практическим шагом вперед, который может не только решить проблему ограничений традиционных методов диагностики, но и повысить точность диагностики неисправностей и эффективность работы системы.

3. Обоснование и поддержка перехода от традиционных диагностических технологий к интеллектуальным

Для более эффективного решения проблемы диагностики неисправностей промышленного оборудования необходим переход от традиционных диагностических технологий к интеллектуальным диагностическим технологиям, который является основным направле-

нием развития современного научно-технического прогресса и имеет множество вспомогательных предпосылок.

- *Индустрия 4.0 и эпоха больших данных.* Интеллектуальные диагностические технологии опираются на базы данных и экспертную информацию, и важной целью разработки системы диагностики неисправностей гидравлического привода является обеспечение экспертам более высокого уровня оперативной эффективности при решении задач гидравлической диагностики. Экспертная система диагностики неисправностей гидравлических систем может успешно решать различные проблемы в гидравлической области. По качеству и скорости решения проблем, а также способности использовать эвристические правила она достигла уровня экспертов в этой области. Фундаментальная причина заключается в том, что система хранит большой объем экспертных знаний [10]. Интеллектуальная диагностическая система отвечает высоким требованиям эффективности диагностики неисправностей гидравлической системы, а большой объем экспертных знаний, хранящихся в гидравлической системе, также соответствует экспертной базе данных и информации, необходимой для разработки интеллектуальной системы. Эти два аспекта имеют взаимодополняющую связь в развитии. В контексте Индустрии 4.0 Интернет вещей (IoT) и технологии больших данных позволяют собирать и хранить огромные массивы данных об эксплуатации гидравлических систем [5, 6]. Это обеспечивает достаточную «подпитку» для интеллектуальных методов диагностики, основанных на данных, позволяя интеллектуальной диагностике изучать сложные режимы неисправностей на основе огромных массивов данных.

- *Прорывы в алгоритмах и вычислительной мощности.* Благодаря постепенному распространению граничных вычислений [15], некоторые вычислительные задачи могут быть перенесены на периферию для интеллектуальной обработки ближе к источнику данных; в то же время путем объединения системы проверки, разработанной на основе модели диагностики состояния, и встроенного оборудования [16, 17], посредством совместной оптимизации программного и аппаратного обеспечения становится возможным достижение эффективной и надежной диагностики в реальном времени в условиях ограниченных ресурсов. Успех глубокого обучения и других алгоритмов в области распознавания изображений и речи вдохновил на их применение в промышленной диагностике [7]. Между тем, повышение вычислительной мощности сделало возможным обучение сложных моделей глубоких нейронных сетей [6].

- *Стремление к надежности и эффективности.* Растущая потребность в повышении эффективности производства и надежности оборудования привела к росту спроса на прогнозирующее и проактивное техническое обслуживание [6, 8]. С точки зрения международных исследований, технология диагностики неисправностей гидравлических систем претерпевает кардинальные изменения, переходя от традиционной диагностики к интеллектуальной. Такие промышленные державы, как США, Германия и Япония, лидируют в области интеллектуальных технологий мониторинга и диагностики гидравлических систем. Исследования в области диагностики неисправностей гидравлических систем сосредоточены на системах прогнозирующего технического обслуживания на основе РНМ (прогнозирование и управление состоянием). Развивающиеся индустриальные страны, такие как Китай, также наращивают свои исследовательские усилия, особенно в применении алгоритмов глубокого обучения, где достигнут значительный прогресс [11]. Согласно текущим международным тенденциям исследований, технология интеллектуальной диагностики является ключом к реализации перехода от «технического обслуживания после события» к «прогнозирующему техническому обслуживанию».

Переход от традиционной диагностики к интеллектуальной – это давно ожидаемый технологический прогресс. Его направление давно ясно, но вопрос о том, как его достичь, остается крайне важным. Сегодня развитие техники и компьютерных наук, вычислительной мощности и алгоритмов, эра больших данных, интернет 5G и чиповые технологии создают основу для реализации интеллектуальных промышленных систем. Направление развития

гидравлических приводных систем также должно сместиться от традиционной диагностики к интеллектуальной диагностике.

4. Основные тенденции технологического развития (комплексная интеллектуальная модернизация промышленных систем и оборудования)

В современном технологическом развитии большое количество новых технологий развивается вокруг Интернета, больших данных и других направлений. Это явление создает основу и исследовательскую базу для интеллектуального развития промышленных систем. Методы диагностики неисправностей гидравлических систем должны опираться на эту основу для достижения систематического обновления в направлении интеллектуальных систем и следовать современному развитию для достижения более эффективных и точных методов диагностики.

4.1. Интеграция Индустрии 4.0 и интеллектуального развития

Таблица 1

Облачные/туманные/периферийные архитектурные цели Индустрии 4.0
и соответствующие решения машинного обучения [31]

Ссылка	Соответствующая рамочная цель	ML Решение
О'Донован и др., 2018 [26]	Минимизация сбоев и снижение задержки	SVM
Ван и др., 2018 [27]	Улучшение связи D2C и D2D и оптимизация управления ресурсами	Универсальный подход к различным решениям искусственного интеллекта / машинного обучения
Ли и др., 2017 [28]	Улучшение качества процесса и динамическое управление потоком данных	SVR, RBF и DBL-DL
Ли и др., 2018 [29]	Определение типа и степени дефекта	CNN
Лавассани и др., 2018 [30]	Сокращение использова- ния спектра и потребления энергии	Обучение с распределенными датчиками
Содро и др., 2019 [31]	Понимание и обработка управления временем выполнения и снижение мощности передачи	Универсальный подход к различным решениям искусственного интеллекта / машинного обучения
Ву и др., 2017 [32]	Снижение задержки, повышение надежности и предустановка масшта- бируемости	RandF

Как основная парадигма четвертой промышленной революции, Индустрия 4.0 подчеркивает глубокую интеграцию киберфизических систем (КФС), то есть достижение интеллектуального производства посредством взаимодействия в реальном времени между цифровым пространством и физическими процессами [27]. В этом контексте, как ключевой компонент энерго- и трансмиссионной связи, модернизация технологий мониторинга состояния и диагностики неисправностей гидравлических систем и переход к систематическим интеллектуальным технологиям является необходимым шагом. Архитектура мониторинга машин, предлагаемая Индустрией 4.0 (например, облачные, туманные и периферийные совместные вычисления), предоставляет гидравлическим системам интегрированное решение для обработки разнородных данных [31]. Технология прогнозирующего технического обслуживания, используя статистические методы и методы машинного обучения, анализирует режимы работы оборудования и вероятность возникновения неисправностей, тем самым принимая решения до возникновения неисправностей, что может значительно сократить незапланированные простои [35]. Совместное использование этих технологий позволило комплексно оптимизировать гидравлические системы с точки зрения эксплуатационной надежности, эффективности производства и общей стоимости жизненного цикла [30].

4.2. Синергетическое развитие промышленного интернета и данных

Развитие промышленного интернета укрепило взаимодействие между оборудованием, данными и людьми, позволяя нам собирать, передавать и интеллектуально анализировать большие промышленные данные через открытые платформы (такие как ПоТ) и беспроводные сенсорные сети (WSAN) [40]. Эта цифровая и сетевая среда обеспечивает основные условия для осуществления удаленного мониторинга гидравлических систем, междоменной диагностики и обмена знаниями, а также повышает эффективность, использование ресурсов и устойчивость производственных систем в целом [29].

5. Поддержка данных и алгоритмов (зрелая технология сбора сигналов, применяемая в интеллектуальной диагностике)

Возможности гидравлических систем по сбору эксплуатационных данных совершили качественный скачок благодаря широкому внедрению сенсорных технологий и архитектуры IoT. Это расширение возможностей привело к переходу методов диагностики неисправностей от «диагностических моделей» к «диагностическим данным».

Широкое применение недорогих датчиков и технологий IoT позволяет осуществлять всепогодный многомерный сбор множества физических параметров гидравлических систем (таких как давление, расход, температура, вибрация и звук) [41, 42]. Эти данные больше не представляют собой единичное, изолированное наблюдение за переменной, а скорее слияние разнородной информации из множества источников, охватывающей динамическое поведение системы. Возможность сбора данных во всем временном диапазоне полностью регистрирует кривую жизненного цикла оборудования от исправного состояния до ухудшения производительности, обеспечивая основу данных для понимания механизмов развития неисправностей и построения стратегий прогнозирующего технического обслуживания.

Сформированная на этой основе промышленная система больших данных становится ключевым «топливом», приводящим в действие интеллектуальные диагностические модели. В отличие от традиционных методов, основанных на физическом моделировании и человеческом опыте, интеллектуальная диагностика на основе данных, использующая алгоритмы машинного обучения, позволяет напрямую изучать характеристики неисправностей и модели работы на основе огромных массивов исторических и реальных данных, тем самым обеспечивая более точные и адаптивные диагностические решения. Например, методы обнаружения неисправностей, основанные на облачно-граничных платформах для совместной работы (таких как SEC-PA), достигли точности 97,4 % на реальных наборах данных и продемон-

стрировали превосходные показатели эффективности вывода и отказоустойчивости системы (достигнув уменьшения общего времени вывода в 1,98–7,93 раза) [43], в полной мере демонстрируя технологический потенциал сочетания больших данных с интеллектуальными алгоритмами.

Поскольку современная тенденция технологического прогресса все больше акцентирует внимание на интеллекте, широкое внедрение вычислительных мощностей и алгоритмических технологий в сочетании с надежной системой обработки данных создало пространство для развития интеллектуальных алгоритмов (алгоритмов глубокого обучения ИИ), необходимых для интеллектуальных систем. Высокий уровень развития технологии алгоритмов ИИ имеет решающее значение для перехода от традиционной промышленной диагностики к интеллектуальной диагностике.

6. Высокий уровень развития технологии алгоритмов искусственного интеллекта

Алгоритмы ИИ являются ключевой технологией интеллектуальных диагностических систем. Развитие технологий алгоритмов ИИ решило множество важных проблем в различных областях интеллектуальных систем, обеспечив разнообразные технические основы для преобразования традиционной диагностики в интеллектуальную.

Суть технологии распознавания изображений заключается в извлечении эффективных признаков из многомерных нелинейных данных изображений, позволяющих машинам автономно идентифицировать абстрактные понятия, такие как «роботизированные манипуляторы», «компоненты системы» и «сигналы неисправностей». В настоящее время в качестве источников данных используются в основном изображения и видео, RGB-D-изображения и видео, а также трехмерные модели объектов (например, CAD-модели) [44]. Главное назначение этой технологии заключается в том, чтобы позволить машинам более эффективно распознавать трехмерные и четырехмерные данные (например, 3D-изображения и видео), тем самым значительно улучшая общую производительность системы.

Основная задача технологии распознавания речи – преобразование непрерывных звуковых волновых сигналов в текст или инструкции, понятные как людям, так и машинам. Наиболее важная проблема заключается в обработке контекстных зависимостей во временных рядах. Поскольку речевой ввод в значительной степени зашумлен, точность автоматического распознавания речи является серьезной проблемой. К представительным методам технологии распознавания речи относятся скрытые марковские модели, основанные на правилах нечеткие системы поддержки, классификаторы на основе шаблонов (такие как метод *k* ближайших соседей и машины опорных векторов) и искусственные нейронные сети, которые широко используются в последние годы [45]. Эти технологии обычно включаются в автоматическое распознавание речи (ASR), обеспечивая определенный уровень точности распознавания, преобразования и синтеза речи. Так, точность распознавания голосов неизвестных или незнакомых людей (например, в записях) составляет приблизительно 54 % [45].

Автоматизированная обработка естественного языка (NLP) направлена на понимание грамматической структуры, семантического содержания и контекстной логики человеческого языка для обработки неструктурированных текстовых последовательностей с эффективностью и точностью, близкими к человеческой [46]. Технология NLP позволяет людям извлекать эффективную информацию из Интернета за ограниченное время, улучшая «сотрудничество» (эффективность) между человеком и машиной.

Технология глубокого обучения, в отличие от традиционных методов, основанных на ручной разработанных признаках (таких как преобразование Фурье и вейвлет-анализ), может автоматически извлекать многоуровневые абстрактные представления признаков из исходных данных [47, 48]. Например, в распознавании изображений неглубокие сети обычно захватывают локальные признаки, такие как края и углы, в то время как глубокие сети дополнительно объединяют эти примитивы для формирования более дискриминативных высо-

коуровневых семантических признаков. Как эволюция традиционных нейронных сетей, технология глубокого обучения достигла значительного прогресса в выразительной мощности и производительности [49].




Рис. 1. Компоненты машинного обучения [49]

Технология ИИ достигла эффективности и точности сквозного обучения в глубоком обучении (машинное обучение и сверточные нейронные сети (CNN)). Благодаря построению прямого отображения от исходных данных (таких как пиксели изображения, аудиосигналы) к конечному результату (таким как метки классификации), она эффективно избегает многоуровневых промежуточных звеньев обработки в традиционном процессе, тем самым значительно уменьшая потери информации и ошибки, вносимые вмешательством человека. В исследовании распознавания модуляции на основе спектральных данных сравнивалась эффективность классификации сверточных нейронных сетей (CNN) при трех различных представлениях данных. Это исследование подтвердило эффективность и осуществимость технологии. Экспериментальные результаты показывают, что в условиях среднего и высокого отношения сигнал/шум модель CNN, обученная на основе данных амплитуды/фазы, имеет самую высокую точность распознавания, которая примерно на 2 и 10 % выше, чем у моделей, основанных, соответственно, на данных IQ и данных FFT. В условиях низкого отношения сигнал/шум модель, обученная на основе данных IQ, демонстрирует лучшую устойчивость [50]. В задачах обнаружения помех различные результаты обработки данных оказывают различное влияние на производительность различных моделей. В условиях низкого отношения сигнал/шум точность распознавания модели на основе данных БПФ на 20 % выше, чем на основе моделей, основанных на данных амплитуды/фазы и IQ. Даже в условиях среднего и высокого отношения сигнал/шум точность классификации сохраняет преимущество примерно в 5 % [50].

Технология ИИ использует глубокие нейронные сети, которые, благодаря своей многослойной вложенной нелинейной структуре, обладают мощной способностью аппроксимировать сложные нелинейные функции с высокой точностью. Суть большинства проблем в

неисправностях гидравлических систем может быть связана с сильно нелинейными динамическими процессами отклика. Для проверки эффективности моделей нейронных сетей ИИ в системах диагностики неисправностей в одном исследовании был предложен метод диагностики неисправностей, интегрирующий сети Колмогорова – Арнольда (KAN) и сверточные нейронные сети (CNN), и его производительность была сравнена в экспериментах по неисправностям подшипников. Результаты показывают, что производительность традиционного многослойного перцептрона (MLP) значительно ниже, чем у модели сверточной нейронной сети с использованием KAN. После всего 300 циклов обучения предложенная модель KANs-CNN показала хорошую сходимость со средней точностью 98,3 % при диагностике неисправностей подшипников [51].

Переход от традиционной диагностики к интеллектуальной диагностике – это не просто передача технологий. Он требует преобразования физических характеристик и механизмов неисправностей системы (например, гидравлической системы) в формальное системное выражение и структурированное представление данных, подходящее для обработки алгоритмами глубокого обучения в интеллектуальных системах. Это преобразование в компьютерный «язык», который могут понимать алгоритмы глубокого обучения в интеллектуальных системах, достигается в первую очередь за счет преобразования форматов данных, а также адаптации и оптимизации моделей алгоритмов.

Исследователи в основном используют частотно-временной анализ, кодирование углового поля Грама и методы многосенсорного суммирования сигналов для преобразования одномерных временных рядов сигналов (таких как сигналы вибрации и сигналы давления) гидравлических систем в двумерные изображения. Затем они используют зрелые модели распознавания изображений (такие как CNN) для преобразования гидравлической системы из одномерного временного ряда сигналов в модель глубокого обучения для интеллектуальных систем, которая может эффективно принимать входные данные. Преобразование формы данных является ключевым нововведением алгоритмов глубокого обучения в искусственном интеллекте. Основные технологии включают частотно-временной анализ, кодирование углового поля Грама и многосенсорное суммирование сигналов.

Методы частотно-временного анализа преобразуют одномерные сигналы в частотно-временные спектрограммы с использованием вейлет-преобразования [54] или кратковременного преобразования Фурье [53], тем самым достигая цели одновременного отображения характеристик сигнала во временной и частотной областях в двумерном пространстве. В одном из связанных исследований на этой основе были представлены двумерные модели времени и механизмы внимания, обеспечивающие разделение признаков и комбинированное разделение неисправностей данных датчиков с различной частотой дискретизации. Диагностическая точность этого метода превысила 97 % [55]. В данном исследовании одномерный временной ряд преобразуется в двумерный и трансформируется из временной области в частотную для учета его периодичности, тем самым повышая способность гидравлических систем моделировать стабильные долговременные нагрузки, генерируемые в нормальных условиях эксплуатации, и случайные кратковременные нагрузки, генерируемые в условиях неисправности.

Методы преобразования одномерного временного ряда в двумерный [55]:

- для заданной длины $TCX_{1D} = (\vec{x}_1, \vec{x}_2, \dots, \vec{x}_C)$;
- для j-го канала имеем $T_j(X_{1D})_j = (X_{1D}^1, X_{1D}^2, \dots, X_{1D}^t, \dots, X_{1D}^{T_j})$,

$$X_{1D}^l = \text{Embedding}(X_{1D}^t),$$

$$A = \text{Mean} \left(\text{Amp} \left(\text{FFT}(X_{1D}^l) \right) \right),$$

$$\{f_1, \dots, f_k\} = \text{Topk}(A), p_i = \left\lfloor \frac{T}{f_i} \right\rfloor, i \in \{1, \dots, k\}.$$

В уравнении $X_{1D}^t\{A_{f_1}, A_{f_2}, \dots, A_{f_k}\}\{f_1, f_2, \dots, f_k\}$ на основе выбранной частоты $\{f_1, f_2, \dots, f_k\}\{p_1, p_2, \dots, p_k\}X_{1D}^l X_{2D}^{l,i}$

$$X_{2D}^{l,i} = \text{Reshape}_{p_i, f_i} \left(\text{Padding}(X_{1D}^l) \right), i \in \{1, \dots, k\}.$$

Заполнение (Padding) означает расширение временного ряда нулевыми значениями во временном измерении, чтобы его период соответствовал периоду исходного ряда $p_i p_i f_i X_{2D}^{l,i} p_i \{X_{2D}^{l,1}, \dots, X_{2D}^{l,k}\} p_i$.

Кодирование по Грамму может преобразовывать одномерные сигналы в двумерные текстурные изображения, отражающие периодичность и структуру, и имеет широкий спектр применимых технических областей. Например, в анализе ближней инфракрасной спектроскопии модель, сочетающая кодирование GAF и двумерную CNN (GAF-2D-CNN), достигла высокой точности прогнозирования на данных, смешанных с необученными данными, со средним коэффициентом детерминации R^2 на валидационном наборе 0,9754 и среднеквадратичной ошибкой 0,0349 [56]. Другое исследование в анализе медицинских сигналов, сочетающее кратковременное преобразование Фурье, GAF и другие методы множественного кодирования, достигло высокой точности классификации заболеваний в среднем без ручной предварительной обработки, со средней точностью до 92 % [57]. В идентификации неисправностей цепей модель на основе GAF и улучшенной CNN имеет точность 94,2, 93,8 и 90,5 % для идентификации высокочастотных, частотно-разделенных и основных частотных ферромагнитных резонансов соответственно [58].

Метод многосенсорного суммирования сигналов позволяет напрямую объединять сигналы нескольких одномерных датчиков в двумерную матрицу, формируя двумерный вход, похожий на изображение. В условиях ограниченного количества обучающих выборок метод объединения одномерной аугментации данных (с использованием многослойного автокодировщика (SAE), улучшенного нейронной сетью обратного распространения (BPNN) с классификатором softmax) с CNN может повысить точность обучения до 98,89 % и точность тестирования до 97,25 % [59]. Эти высокоточные технологии преобразования данных закладывают основу для реализации зрелых интеллектуальных систем и являются эффективным подспорьем для перехода от традиционных методов диагностики к интеллектуальным.

Для реализации перехода диагностики неисправностей гидравлических систем от традиционной к интеллектуальной можно использовать различные модели глубокого обучения для адаптации алгоритмической модели к промышленной механической среде и оптимизации структуры сети. Они могут играть значительную роль в различных типах характеристик данных и диагностических задачах. В настоящее время наиболее зрелыми технологиями являются сверточные нейронные сети (CNN), рекуррентные нейронные сети (RNN), автокодировщики, методы трансферного обучения и т. д.

Сверточные нейронные сети (CNN) в основном используются для обработки изображений, полученных путем преобразования, и извлечения пространственных признаков из данных датчиков. Например, одномерная модель CNN (1-DCNN) для прогнозирования состояния оборудования может напрямую извлекать глубинную информацию из данных о потреблении энергии и достигает точности 98,89 % в задаче прогнозирования точности классификации фазы работы. Эта модель превосходит традиционные модели машинного обучения (традиционные модели ML) [52].

Рекуррентные нейронные сети (RNN) и их варианты, нейронные сети с долгой краткосрочной памятью (LSTM), хорошо обрабатывают данные временных рядов и могут эффективно улавливать динамическую эволюцию неисправностей во временном измерении. LSTM могут адаптивно изучать динамические признаки из необработанных данных без специального ручного извлечения признаков и демонстрируют лучшие диагностические характери-

стики в различении типов неисправностей [60]. Возможности моделирования последовательностей в серии RNN делают их важными инструментами в обработке естественного языка, распознавании речи, прогнозировании временных рядов и связанных с этим инженерных приложениях [61].




Рис. 2. Последовательная диагностика неисправностей на основе нейронной сети LSTM [60]

Автокодировщики восстанавливают входные данные с помощью методов обучения без учителя. Они обычно используются для обнаружения аномалий и выявления ранних неисправностей, отклоняющихся от нормальных закономерностей. Исследование, основанное на шестислойной структуре глубокого обучения автокодировщика, показало, что общая точность этой структуры в обнаружении неисправностей может достигать 91 % [62], что указывает на направление оптимизации для других структур глубокого обучения для интеллектуальной диагностики промышленного оборудования.

Методы трансферного обучения эффективно решают проблему нехватки размеченных данных в промышленных сценариях путем предварительного обучения моделей на больших наборах данных (таких как ImageNet [64]) и последующей тонкой настройки их с использованием данных, специфичных для предметной области. В соответствующих исследованиях была достигнута точность тестирования, близкая к 100 %, на трех основных наборах данных по механике: двигателях, редукторах и подшипниках. Точность на данных редукторов увеличилась с 94,8 до 99,64 % [63].

Основываясь на методах глубокого обучения, связанных с адаптацией и оптимизацией модели алгоритма, интеллектуальная диагностическая система, построенная с использованием этих методов, демонстрирует три существенных преимущества по сравнению с традиционными методами:

- интеллектуальные диагностические системы обладают более высокой точностью, способны выявлять сложные неисправности и ранние, едва заметные неисправности [65], при этом общая точность диагностики превышает 95 %, а в некоторых сценариях и 99 %;

- интеллектуальные диагностические системы обладают более сильными возможностями обобщения, обученная модель может адаптироваться к различным условиям работы и аналогичному оборудованию, демонстрируя хорошую устойчивость; например, гибридные диагностические сети, основанные на обобщении предметной области, могут изучать признаки с возможностями обобщения, тем самым решая задачу диагностики неисправностей в неизвестных условиях работы [66];

- интеллектуальные диагностические системы обладают более ранними возможностями прогнозирования; благодаря высокой чувствительности к едва заметным признакам [68] система может обнаруживать аномальные признаки раньше, обеспечивая критически важное временное окно для прогнозирующего технического обслуживания [67].

Успех глубокого обучения и других алгоритмов в обработке изображений, речи и естественного языка продемонстрировал мощные возможности и надежность технологии искусственного интеллекта в обработке сложных закономерностей и распознавании проблем. Некоторые исследователи применили эти инновационные алгоритмы для диагностики неисправностей в гидравлических системах, достигнув результатов, превосходящих точность традиционных методов. Алгоритмы глубокого обучения на основе ИИ коренным образом решают технические проблемы перехода от традиционной диагностики к интеллектуальной, всесторонне прокладывая путь для интеллектуального развития традиционной диагностики и закладывая основу для полной интеллектуализации будущих промышленных систем.

7. Рыночный спрос (для повышения эффективности и снижения издержек)

Из-за чрезвычайно высоких затрат на простои в современной промышленности рынок стремится к максимальной эффективности производства, требуя от оборудования почти 100-процентной готовности к использованию по назначению. Традиционные модели «послеаварийного обслуживания» и «периодического обслуживания» больше не соответствуют требованиям, и насущной необходимостью стало предиктивное обслуживание. Интеллектуальные диагностические системы могут прогнозировать неисправности и предотвращать незапланированные простои. Применение интеллектуальных диагностических технологий не только повышает надежность системы, но и оказывает систематическое влияние на управление оборудованием, безопасность и охрану окружающей среды, а также на вспомогательные технологии (вычислительная мощность, датчики, архитектура «облако – периферия – устройства»), в частности, в следующих аспектах.

Интеллектуальная диагностика позволяет разрабатывать планы упреждающего обслуживания путем точного определения первопричины неисправностей и предиктивного обслуживания, эффективно предотвращая неожиданные простои, избыточное обслуживание и неправильную диагностику. Это не только снижает потребность в запасных частях и трудозатратах, но и оптимизирует решения по техническому обслуживанию за счет более качественного объединения данных [67], тем самым значительно снижая общие затраты на техническое обслуживание оборудования на протяжении всего жизненного цикла.

Сбои в гидравлических системах могут привести к серьезным производственным авариям или экологическим рискам [69]. Интеллектуальные диагностические технологии, основанные на больших данных и искусственном интеллекте, позволяют выявлять угрозы безопасности на ранних стадиях, создавать модели предотвращения рисков и реагирования на них [71] и осуществлять трансформацию гидравлических систем от пассивного управления к проактивному предотвращению и контролю. Интеллектуальные диагностические системы, выявляя дефекты на ранних стадиях, помогают постоянно соответствовать стандартам безопасности и охраны окружающей среды и повышают надежность работы системы [70], что делает их пригодными для все более строгих норм безопасности и охраны окружающей среды.

Переход от традиционной диагностики к интеллектуальной требует не только зрелых алгоритмических технологий, но и учета осуществимости интеллектуальных систем. Осуществимость интеллектуальной диагностики зависит от развития и зрелости множества базовых технологий и их межфункционального взаимодействия. К таким факторам можно отнести разработку алгоритмов вычислительной мощности и совместимого оборудования, интеграцию датчиков и технологий IoT, а также технологии межфункционального взаимодействия, такие как архитектура «облако – периферия – устройство».

Широкое распространение вычислительных мощностей и разработка специализированного оборудования повысили эффективность систем, ускорили разработку интеллектуальных систем и расширили возможности применения технологий. Например, разработка технологии облачных вычислений на основе графических процессоров и специализированных чипов для ИИ (таких как графические процессоры NVIDIA и облачные процессоры для ИИ) значительно ускорила обучение и вывод результатов для крупномасштабных сложных моделей. Одно исследование показало, что специальные методы оптимизации позволяют энергоэффективным вычислительным системам достигать скорости, в 15–30 раз большей, чем у традиционных ЦП/ГП, в задачах распределенного обучения и вывода результатов [72–74], что позволяет быстро и экономично развертывать в облаке модели обучения, ранее доступные только в лабораториях.

Интеграция датчиков и технологий IoT позволила гидравлическим системам получать высококачественные данные. Непрерывное совершенствование размеров, точности, стоимости и надежности беспроводных датчиков [75–77] позволило широко развертывать сети датчиков на сложных механических конструкциях. Технологии, такие как радиочастотная идентификация (RFID) и беспроводные сенсорные сети (WSN), обеспечивают основу для сбора данных в реальном времени из множества источников в гидравлических системах.

Архитектура взаимодействия облака, периферийных устройств и других устройств поддерживает отслеживание технического состояния в реальном времени на периферийных устройствах, одновременно обеспечивая обучение и оптимизацию сложных моделей в облаке, достигая баланса между улучшенными диагностическими возможностями и скоростью отклика. Например, в интеллектуальных транспортных системах структура взаимодействия облака и периферийных устройств повышает способность периферийных моделей к обобщению за счет визуальных подсказок и дистилляции знаний [78], усиливает глубокое обучение и периферийные вычисления, оптимизирует эффективность мониторинга в реальном времени в средах IoT, повышает стабильность системы и снижает частоту ее отказов [78].

Интеллектуальная трансформация технологии диагностики неисправностей гидравлических систем является неизбежным выбором для того, чтобы идти в ногу с технологическими тенденциями и удовлетворять требованиям рынка. Она эволюционирует из изолированного технического инструмента в ключевое звено, встроенное во всю экосистему интеллектуального производства. Его ценность уже не ограничивается лишь «ремонт оборудования», а способствует эффективной работе и многомерным инновациям всей модели развития механического оборудования.

В процессе перехода от традиционной диагностики к интеллектуальной крайне важно сохранить технологические преимущества традиционных методов диагностики. При сохранении этих преимуществ необходимо совершать прорывы в интеллектуальных технологиях, опираясь на специфические недостатки традиционных методов диагностики. Для достижения этой цели необходим детальный анализ и точное сравнение различий между традиционными и интеллектуальными диагностическими технологиями.

Таблица 2

Комплексное сравнение традиционных и интеллектуальных диагностических технологий для выявления неисправностей гидравлических систем

Серийный номер	Техническое сравнение	Традиционные методы диагностики	Интеллектуальные методы диагностики
1	Основные принципы	Основаны на физических моделях, традиционных методах обработки сигналов и человеческом опыте [23]	Основаны на подходах, учитывающих данные, и алгоритмах ИИ (машинное обучение, глубокое обучение)
2	Зависимость от знаний	Знания, в значительной степени зависящие от опыта экспертов и знаний в предметной области, трудно передать и количественно оценить	Опираясь на исторические данные [24] и алгоритмические модели [26], знания вносят в модель, и метод является воспроизводимым
3	Обработка признаков	Ручное извлечение признаков основано на разработанных экспертами методах обработки сигналов (таких как преобразование Фурье и вейвлет-анализ)	Автоматическое обучение признакам позволяет извлекать глубинные, неявные атрибуты признаков из исходных данных
4	Диагностическая логика	Причинно-следственное рассуждение и суждение, основанное на правилах (например, анализ дерева отказов (FTA)) [79]	Изучение сложных отображений неисправностей и признаков из данных с помощью взаимосвязанных системных отношений и моделей распознавания
5	Степень автоматизации	Низкий уровень: процесс диагностики в значительной степени зависит от ручного вмешательства и анализа, что приводит к низкой эффективности	Высокий уровень: может обеспечить автоматическую диагностику на стороне компьютера, мониторинг в реальном времени [25] и раннее предупреждение
6	Адаптивность и способность к обобщению	Слабый уровень: для конкретных систем или неисправностей диагностический эффект может снижаться после изменения условий эксплуатации	Сильный уровень, с инкрементным обучением и способностью к переносу обучения, способность адаптироваться к новым условиям работы и новым неисправностям
7	Способность обрабатывать сложные неисправности	Ограниченная способность диагностировать сложные неисправности и ранние слабые неисправности	Сильная способность, возможность эффективно решать нелинейные, высокоразмерные проблемы, точное позиционирование сложных неисправностей и ранних неисправностей
8	Прозрачность и интерпретируемость	Высокий уровень: процесс диагностики соответствует физической интуиции, а выводы ясны и могут быть подробно объяснены	Более низкие модели, такие как глубокое обучение, часто рассматриваются как «черный ящик» [26], процесс принятия решений трудно понять
9	Технические барьеры и затраты	Низкие первоначальные инвестиции, но высокие требования к опыту персонала [23] и высокие долгосрочные затраты на человеческие ресурсы	Первоначальное накопление данных и разработка моделей имеют высокий порог, но более поздние масштабируемые приложения с низкими предельными затратами
10	Использование данных	Обычно используется небольшое количество структурированных текущих данных	Способны обрабатывать огромные объемы исторических и текущих данных из множества источников (большие данные)

Сравнение характеристик традиционных и интеллектуальных диагностических технологий показывает, что диагностика неисправностей гидравлических систем эволюционирует от традиционных методов к интеллектуальным. Этот процесс в первую очередь отражает изменения в критериях принятия решений, методах обработки данных и диагностических парадигмах.

Изменение критериев принятия решений заключается в переходе от опоры на опыт экспертов и физические модели к автономному принятию решений на основе данных и алгоритмов. Изменение обработки данных заключается в переходе от ручного анализа и прямых измерений к углубленному анализу данных и интеллектуальной идентификации с использованием технологий больших данных и моделей ИИ (таких как трансферное обучение и глубокое обучение). Изменение диагностических парадигм заключается в переходе от постдиагностики и планового технического обслуживания к мониторингу в реальном времени, прогнозирующему техническому обслуживанию и интерактивной визуализации.

Традиционная диагностика работает по модели «врача», подобно опытному врачу, который определяет причину (источник неисправности) путем «наблюдения, прослушивания, обоняния, опроса и диагностики» (изучение манометров, прослушивание аномальных шумов и анализ принципиальных схем). Этот процесс основан на глубоких знаниях эксперта и логической цепочке диагностической системы. Интеллектуальная диагностика работает по «детективной» модели, подобно детективу, работающему с огромными массивами данных. Сравнивая миллиарды «баз данных отпечатков пальцев» (опытные и эксплуатационные данные о неисправностях), она быстро сопоставляет текущую подсказку (данные в реальном времени) с соответствующим виновником (типом неисправности). Ее суть заключается в сопоставлении образов и прогнозировании вероятности. В традиционной диагностике преобразование между обнаруженными данными и информацией о неисправностях системы происходит в основном в сознании эксперта. Однако в интеллектуальной диагностике преобразование между обнаруженными данными и информацией о неисправностях системы закодировано в алгоритмической модели.

8. Текущие проблемы и будущие направления

Несмотря на значительный прогресс в развитии интеллектуальной диагностики, ее разработка и применение по-прежнему сталкиваются с некоторыми проблемами, которые также являются важными направлениями для будущих исследований:

- *Качество и дефицит данных.* В промышленных условиях часто отсутствуют высококачественные данные о неисправностях, особенно трудно получаемые данные о серьезных неисправностях [5]. Данные об эксплуатации гидравлических систем страдают от шумовых помех, пропущенных сигналов и несоответствий. В частности, в промышленных условиях очень сложно получить высококачественные, полностью размеченные образцы неисправностей [12]. Многие интеллектуальные диагностические модели опираются на большой объем высококачественных данных, но в реальных промышленных условиях данные о неисправностях дефицитны, а характеристики данных различного оборудования и условий эксплуатации сильно различаются, что затрудняет обучение модели. В будущем необходимо изучить, как эффективно обучаться при несбалансированности данных [6].

- *Интерпретируемость модели (надежность).* Хотя интеллектуальные алгоритмы, такие как глубокое обучение, могут обеспечить высокоточную диагностику, процесс принятия решений в них подобен «черному ящику» (модели «черного ящика»). Персоналу по техническому обслуживанию сложно полностью понять и полностью доверять результатам диагностики модели [13]. При возникновении новых или неизвестных неисправностей модель может дать сбой и не сможет предоставить эффективные аналитические подсказки. Объяснительный ИИ (XAI) является ключом к решению этой проблемы и важным направлением исследований на будущее [8].

• *Сложность применения.* Развертывание интеллектуальных диагностических моделей из лаборатории на реальных промышленных периферийных устройствах требует, чтобы модели соответствовали требованиям легкости, низкого энергопотребления и работы в реальном времени [6]. Необходимо разработать «интеллектуальные алгоритмы», которые будут продолжать развиваться и совершенствоваться в направлении облегченной конструкции, чтобы их можно было развертывать на встроенных устройствах с ограниченными ресурсами [18]. В то же время необходимо постоянно повышать возможности самооптимизации и самоадаптации, чтобы система могла гибко справляться с динамически изменяющимися условиями работы [19]. Кроме того, интеллектуальные системы также должны усиливать глубокую интеграцию знаний предметной области (экспертиза в области гидравлических систем) и науки о данных [5]. Инженерные приложения должны быть подготовлены к применению интеллектуальных систем и должны уделять больше внимания «надежности» и «применимости». С появлением специализированных систем проверки, таких как интеллектуальные модели диагностики состояния гидравлических насосов [14], промышленность будет уделять больше внимания повышению достоверности диагностических моделей и надежности инженерных приложений посредством проверки, сочетающей аппаратное и программное обеспечение, тем самым ускоряя преобразование лабораторных результатов в промышленные образцы.

9. Заключение

Традиционная диагностика не устарела полностью, она остается незаменимой в быстром позиционировании известных неисправностей, системном механическом анализе и внезапном устранении неполадок без накопления данных, а также является важным средством проверки интеллектуальных диагностических результатов. Интеллектуальная диагностика лучше справляется с мониторингом массивных данных, ранним предупреждением о неисправностях, а также с трудно моделируемыми неисправностями сложных систем и промышленных площадок, требующими высокой параллельной и автоматизированной диагностики. Переход от традиционной диагностики к интеллектуальной является неизбежной тенденцией развития технологии диагностики неисправностей гидравлической системы, и этот переход реализует скачок от «зависимости от человека» к «зависимости от данных и алгоритмов», от «воспринимаемого представления» к «осмысленной коннотации», от «последующего ремонта» до «прогнозного обслуживания». Хотя процесс перехода от традиционной диагностики до интеллектуальной диагностики по-прежнему сопряжен с трудностями с точки зрения интерпретируемости, его прорывные преимущества с точки зрения эффективности, точности и автоматизации делают его основной силой современной промышленной интеллектуальной трансформации.

Судя по тенденциям международных исследований, технология диагностики неисправностей гидравлических систем необратимо переходит от традиционной диагностики к интеллектуальной, будущие диагностические системы анализируют не отдельные компоненты изолированно, а гидравлические системы в целом [20], в сочетании с данными многоисточниковых датчиков (давление, расход, температура, вибрация и т. д.) [21, 22] для более полной оценки и прогнозирования технического состояния. Интеллектуальная диагностика не только соответствует волне широкого применения промышленной цифровизации и искусственного интеллекта в контексте времени, но и демонстрирует превосходную способность избавляться от узких мест в традиционных диагностических технологиях на техническом уровне и постоянно решать новые проблемы в непрерывном развитии, чтобы двигаться к более зрелому прикладному будущему.

Благодарность

Автор выражает благодарность своему научному руководителю Мельникову Роману Вячеславовичу за помощь в работе над статьей.

Литература

1. Signal-based intelligent hydraulic fault diagnosis methods: review and prospects / J. Dai, J. Tang, S. Huang, Y. Wang // Chinese Journal of Mechanical Engineering. – 2019. – Vol. 32 (1). – Art. No 75. – DOI: 10.1186/s10033-019-0388-9.
2. Intelligent fault diagnosis of hydraulic system based on multiscale one-dimensional convolutional neural networks with multi attention mechanism / J. Sun, H. Ding, N. Li, X. Sun, X. Dong // Sensors (Basel). – 2024. – Vol. 24 (22). – P. 7267. – DOI: 10.3390/s24227267.
3. Intelligent diagnosis method for early faults of electric-hydraulic control system based on residual analysis / X. Kong, B. Cai, Y. Yu, J. Yang, B. Wang, Z. Liu, X. Shao, C. Yang // Reliability Engineering & System Safety. – 2025. – Vol. 261 (C). – 111142. – DOI: 10.1016/j.res.s.2025.111142.
4. Fault diagnosis of hydraulic system based on D-S evidence theory and SVM / H. Yin, Y. Wang, W. Sun, L. Wang // International Journal of Hydromechatronics. – 2024. – Vol. 7 (1). – P. 1–15. – DOI: 10.1504/IJHM.2024.135976.
5. Data-driven fault diagnosis for electric drives: a review / D. Gonzalez-Jimenez, J. del-Olmo, J. Poza, F. Garramiola, P. Madina // Sensors. – 2021. – Vol. 21 (12). – P. 4024. – DOI: 10.3390/s21124024.
6. Deep learning techniques in intelligent fault diagnosis and prognosis for industrial systems: a review / S. Qiu, X. Cui, Z. Ping, N. Shan, Z. Li, X. Bao, X. Xu // Sensors. – 2023. – Vol. 23 (3). – P. 1305. – DOI: 10.3390/s23031305.
7. Signal-based intelligent hydraulic fault diagnosis methods: review and prospects / J. Dai, J. Tang, S. Huang, Y. Wang // Chinese Journal of Mechanical Engineering. – 2019. – Vol. 32 (1). – P. 75. – DOI: 10.1186/s10033-019-0388-9.
8. Fault detection and diagnosis in industry 4.0: a review on challenges and opportunities / D. Leite, E. Andrade, D. Rativa, A. M. A. Maciel // Sensors (Basel). – 2024. – 25 (1). – P. 60. – DOI: 10.3390/s25010060.
9. Hinton G. E., Salakhutdinov R. R. Reducing the dimensionality of data with neural networks // Science. – 2006. – Vol. 313 (5786). – P. 504–507. – DOI: 10.1126/science.1127647.
10. Zhou X., Lei X. Fault diagnosis method of the construction machinery hydraulic system based on artificial intelligence dynamic monitoring // Mobile Information Systems. – 2021. – Vol. 2021 (1). – P. 1093960. – DOI: 10.1155/2021/1093960.
11. Peng K.-X., Ma L., Zhang K. Review of quality-related fault detection and diagnosis techniques for complex industrial processes // Acta Automatica Sinica. – 2017. – Vol. 43 (3). – P. 349–365. – DOI: 10.16383/j.aas.2017.c160427.
12. The study of hydraulic machinery condition monitoring based on anomaly detection and fault diagnosis / Y. Liu, R. Zhang, Z. He, Q. Huang, R. Zhu, H. Li, Q. Fu // Measurement. – 2024. – Vol. 230. – P. 114518. – DOI: 10.1016/j.measurement.2024.114518.
13. Artificial intelligence and real-time predictive maintenance in industry 4.0: a bibliometric analysis / A. T. Keleko, B. Kamsu-Foguem, R. H. Ngouna, A. Tongne // AI and Ethics. – 2022. – Vol. 2 (4). – P. 553–577. – DOI: 10.1007/s43681-021-00132-6.
14. CN 119474787 A. Verification system and method for intelligent hydraulic pump state diagnosis model / Zhu Y., Dai W., Sun L., Yao Y., Chang C., Guo W., Zhang Z., Chen Y.
15. Fawwaz D. Z., Chung S. H. Real-time and robust hydraulic system fault detection via edge computing // Applied Sciences. – 2020. – Vol. 10 (17). – P. 5933. – DOI: 10.3390/app10175933.
16. Three-model-driven fault diagnosis method for complex hydraulic control system: subsea blowout preventer system as a case study / X. Kong, B. Cai, Z. Zou, Q. Wu, C. Wang, J. Yang, B. Wang, Y. Liu // Expert Systems with Applications. – 2024. – Vol. 247. – Art. No 123297. – DOI: 10.1016/j.eswa.2024.123297.

17. Khaziev E. L., Khaziev M. L. Intelligent diagnostic system for hydraulic actuator // International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM), Sochi, Russia, 2019. – IEEE, 2019. – P. 1–6. – DOI: 10.1109/ICIEAM.2019.8742779.
18. Zhang Z., Li J. A review of artificial intelligence in embedded systems // Micromachines. – 2023. – Vol. 14 (5). – P. 897. – DOI: 10.3390/mi14050897.
19. Gheibi O., Weyns D., Quin F. Applying machine learning in self-adaptive systems: a systematic literature review // ACM Transactions on Autonomous and Adaptive Systems (TAAS). – 2021. – Vol. 15 (3). – P. 1–37. – DOI: 10.1145/3469440.
20. Лесковец И. В., Грац А. А., Рогожин В. Д. Диагностирование гидропривода аэродромной техники // Научный рецензируемый журнал «Вестник СибАДИ». – 2025. – Т. 22 (3). – С. 56–367. – DOI: 10.26518/2071-7296-2025-22-3-356-367.
21. Чернухин А. В. Автоматизированная система прогнозирования технического состояния промышленного оборудования на базе методов искусственного интеллекта : дис. ... канд. техн. наук : 2.3.3. – Москва, 2025. – 186 с.
22. Яблоков А. Е. Научно-практические основы создания автоматизированных систем технического мониторинга и диагностики оборудования зерноперерабатывающих предприятий на базе нейросетевых методов анализа данных : дис. ... докт. техн. наук : 2.3.3. – Москва, 2022. – 377 с.
23. Fenton W. G., McGinnity T. M., Maguire L. P. Fault diagnosis of electronic systems using intelligent techniques: a review // IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews). – 2001. – Vol. 31 (3). – P. 269–281. – DOI: 10.1109/5326.971655.
24. Dai X., Gao Z. From model, signal to knowledge: a data-driven perspective of fault detection and diagnosis // IEEE Transactions on Industrial Informatics. – 2013. – Vol. 9 (4). – P. 2226–2238. – DOI: 10.1109/TII.2013.2243743.
25. Isermann R. Fault-Diagnosis Systems: An Introduction from Fault Detection to Fault Tolerance. – Berlin, Heidelberg : Springer, 2005. – 475 p. – DOI: 10.1007/3-540-30368-5.
26. A review of real-time fault diagnosis methods for industrial smart manufacturing / W. Yan, J. Wang, S. Lu, M. Zhou, X. Peng // Processes. – 2023. – Vol. 11 (2). – P. 369. – DOI: 10.3390/pr11020369.
27. Klingenberg C. O., Viana Borges M. A., do Vale Antunes J. A. Industry 4.0: what makes it a revolution? A historical framework to understand the phenomenon // Technology in Society. – 2022. – Vol. 70. – P. 102009. – DOI: 10.1016/j.techsoc.2022.102009.
28. Martinelli A., Mina A, Moggi M. The enabling technologies of industry 4.0: examining the seeds of the fourth industrial revolution // Industrial and Corporate Change. – 2021. – Vol. 30 (1). – P. 161–188. – DOI: 10.1093/icc/dtaa060.
29. Ghobakhloo M. Industry 4.0, digitization, and opportunities for sustainability // Journal of Cleaner Production. – 2020. – Vol. 252. – 119869. – DOI: 10.1016/j.jclepro.2019.119869.
30. Understanding the adoption of Industry 4.0 technologies in improving environmental sustainability / M. Javaid, A. Haleem, R. Pratap Singh, R. Suman, E. Santibañez Gonzalez // Sustainable Operations and Computers. – 2022. – Vol. 3. – P. 203–217. – DOI: 10.1016/j.susoc.2022.01.008.
31. Tackling faults in the Industry 4.0 era – a survey of machine-learning solutions and key aspects / A. Angelopoulos, E. T. Michailidis, N. Nomikos, P. Trakadas, A. Hatziefremidis, S. Voliotis, T. Zahariadis // Sensors. – 2020. – Vol. 20 (1). – P. 109. – DOI: 10.3390/s20010109.
32. A fog computing industrial cyber-physical system for embedded low-latency machine learning Industry 4.0 applications / P. O'Donovan, C. Gallagher, K. Bruton, D. T. J. O'Sullivan // Manufacturing Letters. – 2018. – Vol. 15, part B. – P. 139–142. – DOI: 10.1016/j.mfglet.2018.01.005.
33. Artificial intelligence for cloud-assisted smart factory / J. Wan, J. Yang, Z. Wang, Q. Hua // IEEE Access. – 2018. – Vol. 6. – P. 55419–55430. – DOI: 10.1109/ACCESS.2018.2871724.

34. Lee H. Framework and development of fault detection classification using IoT device and cloud environment // *Journal of Manufacturing Systems*. – 2017. – Vol. 43 (2). – P. 257–270. – DOI: 10.1016/j.jmsy.2017.02.007.
35. Predictive maintenance in the Industry 4.0: a systematic literature review / T. Zonta, C. A. da Costa, R. da Rosa Righi, M. J. de Lima, E. S. da Trindade, G. P. Li // *Computers & Industrial Engineering*. – 2020. – Vol. 150. – 106889. – DOI: 10.1016/j.cie.2020.106889.
36. Li L., Ota K., Dong M. Deep learning for smart industry: efficient manufacture inspection system with fog computing // *IEEE Transactions on Industrial Informatics*. – 2018. – Vol. 14 (10). – P. 4665–4673. – DOI: 10.1109/TII.2018.2842821.
37. Combining fog computing with sensor mote machine learning for industrial IoT / M. Lavasani, S. Forsström, U. Jennehag, T. Zhang // *Sensors*. – 2018. – Vol. 18 (5). – P. 1532. – DOI: 10.3390/s18051532.
38. Sodhro A. H., Pirbhulal S., de Albuquerque V. H. C. Artificial intelligence-driven mechanism for edge computing-based industrial applications // *IEEE Transactions on Industrial Informatics*. – 2019. – Vol. 15 (7). – P. 4235–4243. – DOI: 10.1109/TII.2019.2902878.
39. A fog computing-based framework for process monitoring and prognosis in cyber-manufacturing / D. Wu, S. Liu, L. Zhang, J. Terpenney, R. X. Gao, T. Kurfess, J. A. Guzzo // *Journal of Manufacturing Systems*. – 2017. – Vol. 43 (1). – P. 25–34. – DOI: 10.1016/j.jmsy.2017.02.011.
40. Raptis T. P., Passarella A., Conti M. Data management in industry 4.0: state of the art and open challenges // *IEEE Access*. – 2019. – Vol. 7. – P. 97052–97093. – DOI: 10.1109/ACCESS.2019.2929296.
41. A review of multisensor data fusion solutions in smart manufacturing: systems and trends / A. Tsanousa, E. Bektsis, C. Kyriakopoulos, A. G. González, U. Leturiondo, I. Gialampoukidis, A. Karakostas, S. Vrochidis, I. Kompatsiaris // *Sensors*. – 2022. – Vol. 22 (5). – P. 1734. – DOI: 10.3390/s22051734.
42. Advances in fiber Bragg grating (FBG) sensing: a review of conventional and new approaches and novel sensing materials in harsh and emerging industrial sensing / S. P. Kok, Y. I. Go, X. Wang, M. L. D. Wong // *IEEE Sensors Journal*. – 2024. – Vol. 24 (19). – P. 29485–29505. – DOI: 10.1109/JSEN.2024.3434351.
43. arXiv:2411.02086v1 [cs.NI]
44. A survey of traditional and deep learning-based feature descriptors for high dimensional data in computer vision / T. Georgiou, Y. Liu, W. Chen, M. Lew // *International Journal of Multimedia Information Retrieval*. – 2020. – Vol. 9 (3). – P. 135–170. – DOI: 10.1007/s13735-019-00183-w.
45. Speech recognition to build context: a survey / S. Raju, V. Jagtap, P. Kulkarni, M. Ravikanth, M. Rafeeq // *2020 International Conference on Computer Science, Engineering and Applications (ICCSEA)*, Gunupur, India, 13–14 March, 2020. – IEEE, 2020. – P. 1–7. – DOI: 10.1109/ICCSEA49143.2020.9132848.
46. Chowdhary K. R. Natural language processing // *Fundamentals of Artificial Intelligence*. – New Delhi : Springer, 2020. – P. 603–649. – DOI: 10.1007/978-81-322-3972-7_19.
47. Ye Z., Yu J. Multi-level features fusion network-based feature learning for machinery fault diagnosis // *Applied Soft Computing*. – 2022. – Vol. 122. – P. 108900. – DOI: 10.1016/j.asoc.2022.108900.
48. Hou H., Ding S., Xu X. A deep clustering by multi-level feature fusion // *International Journal of Machine Learning and Cybernetics*. – 2022. – Vol. 13 (10). – P. 2813–2823. – DOI: 10.1007/s13042-022-01557-z.
49. Taye M. M. Theoretical understanding of convolutional neural network: concepts, architectures, applications, future directions // *Computation*. – 2023. – Vol. 11 (3). – P. 52. – DOI: 10.3390/computation11030052.

50. End-to-end learning from spectrum data: a deep learning approach for wireless signal identification in spectrum monitoring applications / M. Kulin, T. Kazaz, I. Moerman, E. De Poorter // IEEE Access. – 2018. – Vol. 6. – P. 18484–18501. – DOI: 10.1109/ACCESS.2018.2818794.
51. Li Y., Gu, X, Wei Y. A deep learning-based method for bearing fault diagnosis with few-shot learning // Sensors. – 2024. – Vol. 24 (23). – P. 7516. – DOI: 10.3390/s24237516.
52. One-dimensional convolutional neural network model driven intelligent operation phases identification of hydraulic press using energy data / Y. Liu, Y. Shu, Z. Xu, S. Han, C. Zhang, M. Chen // Engineering Applications of Artificial Intelligence. – 2025. – Vol. 155. – P. 111079. – DOI: 10.1016/j.engappai.2025.111079.
53. Portnoff M. Time-frequency representation of digital signals and systems based on short-time Fourier analysis // IEEE Transactions on Acoustics, Speech, and Signal Processing. – 1980. – Vol. 28 (1). – P. 55–69. – DOI: 10.1109/TASSP.1980.1163359.
54. Alsberg B. K., Woodward A. M., Kell D. B. An introduction to wavelet transforms for chemometricians: a time-frequency approach // Chemometrics and Intelligent Laboratory Systems. – 1997. – Vol. 37 (2). – P. 215–239.
55. Hydraulic system fault diagnosis decoupling method based on 2D time-series modeling and self-attention fusion / H. Wang, J. Zhou, H. Chen, B. Xu, Z. Shen // Scientific Reports. – 2024. – Vol. 14 (1). – P. 15620. – DOI: 10.1038/s41598-024-66541-9.
56. Near-infrared spectroscopy coupled with Gramian angular field two-dimensional convolutional neural network for white tea adulteration detection / P. Zhang, J. Cheng, Q. Chen, Z. Zheng, C. Wei, T. Zou, W. Sun, Y. Huang // Journal of the Science of Food and Agriculture. – 2025. – Vol. 105. – P. 6269–6279. – DOI: 10.1002/jsfa.14353.
57. Multimodal 1D-to-2D signal transformation and pulse disease recognition / L. Fan, B. Dang, Z. Wang, R. Zhang // AIPR '23: Proceedings of the 2023 6th International Conference on Artificial Intelligence and Pattern Recognition, Xiamen, China, September 22–24, 2023. – 2024. – P. 324–330. – DOI: 10.1145/3641584.3641632.
58. Ferromagnetic resonance over-voltage identification method based on Gram angle field / Q. Li, Y. Zou, G. H. Long, W. Wu // Energy Reports. – 2022. – Vol. 8 (6). – P. 546–558. – DOI: 10.1016/j.egyr.2022.03.156.
59. Long Y., Zhou W., Luo Y. A fault diagnosis method based on one-dimensional data enhancement and convolutional neural network // Measurement. – 2021. – Vol. 180. – P. 109532. – DOI: 10.1016/j.measurement.2021.109532.
60. Zhao H., Sun S., Jin B. Sequential fault diagnosis based on LSTM neural network // IEEE Access. – 2018. – Vol. 6. – P. 12929–12939. – DOI: 10.1109/ACCESS.2018.2794765.
61. Mienye I. D., Swart T. G., Obaido G. Recurrent neural networks: a comprehensive review of architectures, variants, and applications // Information. – 2024. – Vol. 15 (9). – P. 517. – DOI: 10.3390/info15090517.
62. A smart-anomaly-detection system for industrial machines based on feature autoencoder and deep learning / I. Ahmed, M. Ahmad, A. Chehri, G. Jeon // Micromachines. – 2023. – Vol. 14 (1). – P. 154. – DOI: 10.3390/mi14010154.
63. Highly accurate machine fault diagnosis using deep transfer learning / S. Shao, S. McAleer, R. Yan, P. Baldi // IEEE Transactions on Industrial Informatics. – 2018. – Vol. 15 (4). – P. 2446–2455. – DOI: 10.1109/TII.2018.2864759.
64. arXiv:1608.08614 [cs.CV]
65. Deep learning algorithms for bearing fault diagnostics – a comprehensive review / S. Zhang, S. Zhang, B. Wang, T. G. Habetler // IEEE Access. – 2020. – Vol. 8. – P. 29857–29881. – DOI: 10.1109/ACCESS.2020.2972859.
66. Han T., Li Y. F., Qian M. A hybrid generalization network for intelligent fault diagnosis of rotating machinery under unseen working conditions // IEEE Transactions on Instrumentation and Measurement. – 2021. – Vol. 70, art. No 3520011. – P. 1–11. – DOI: 10.1109/TIM.2021.3088489.

67. Intelligent maintenance systems and predictive manufacturing / J. Lee, J. Ni, J. Singh, B. Jiang, M. Azamfar, J. Feng // *Journal of Manufacturing Science and Engineering*. – 2020. – Vol. 142 (11). – 110805. – DOI: 10.1115/1.4047856.
68. Automated IT system failure prediction: a deep learning approach / K. Zhang, J. Xu, M. R. Min, G. Jiang, K. Pelechrinis, H. Zhang // *2016 IEEE International Conference on Big Data (Big Data)*, Washington, DC, USA, 2016. – IEEE, 2016. – P. 1291–1300. – DOI: 10.1109/BigData.2016.7840733.
69. Cvetković V. M., Renner R., Jakovljević V. R. Industrial disasters and hazards: From causes to consequences – a holistic approach to resilience // *International Journal of Disaster Risk Management*. – 2024. – Vol. 6 (2). – P. 149–168. – DOI: 10.18485/ijdrm.2024.6.2.10.
70. Park J., Kang D. Artificial intelligence and smart technologies in safety management: a comprehensive analysis across multiple industries // *Applied Sciences*. – 2024. – Vol. 14 (24). – 11934. – DOI: 10.3390/app142411934.
71. The research on intelligent safety risk assessment and early warning mechanisms for power systems based on big data and artificial intelligence technology / L. Luo, Y. Song, Y. Liu, X. Jiang // *Advances in Resources Research*. – 2025. – Vol. 5 (2). – P. 666–688. – DOI: 10.50908/arr.5.2_666.
72. GPU Computing / J. D. Owens, M. Houston, D. Luebke, S. Green, J. E. Stone, J. C. Phillips // *Proceedings of the IEEE*. – IEEE, 2008. – Vol. 96 (5). – P. 879–899. – DOI: 10.1109/JPROC.2008.917757.
73. arXiv:2412.06044v1 [cs.DC]
74. Distributed artificial intelligence empowered by end-edge-cloud computing: a survey / S. Duan, D. Wang, J. Ren, F. Lyu, Y. Zhang, H. Wu // *IEEE Communications Surveys & Tutorials*. – 2022. – Vol. 25 (1). – P. 591–624. – DOI: 10.1109/COMST.2022.3218527.
75. A review of IoT sensing applications and challenges using RFID and wireless sensor networks / H. Landaluce, L. Arjona, A. Perallos, F. Falcone, I. Angulo, F. Muralter // *Sensors*. – 2020. – Vol. 20 (9). – 2495. – DOI: 10.3390/s20092495.
76. Sehrawat D., Gill N. S. Smart sensors: analysis of different types of IoT sensors // *2019 3rd International Conference on Trends in Electronics and Informatics (ICOEI)*, Tirunelveli, India, 2019. – IEEE, 2019. – P. 523–528. – DOI: 10.1109/ICOEI.2019.8862778.
77. Alahmad T., Neményi M., Nyéki A. Applying IoT sensors and big data to improve precision crop production: a review // *Agronomy*. – 2023. – Vol. 13 (10). – P. 2603. – DOI: 10.3390/agronomy13102603.
78. arXiv:2111.06061v3 [cs.LG]
79. Fault tree analysis improvements: a bibliometric analysis and literature review / M. Yazdi, J. Mohammadpour, H. Li, H.-Z. Huang, E. Zarei, R. G. Pirbalouti, S. Adumene // *Quality and Reliability Engineering International*. – 2023. – Vol. 39 (5). – P. 1639–1659. – DOI: 10.1002/qre.3271.