KATTA HAJMDAGI MA'LUMOTLARNI TAHLIL QILISHDA IZOHLANADIGAN SUN'IY INTELLEKT MODELLARINING SAMARADORLIGINI OSHIRISH USULLARI

Matkarimov Otabek Oybekovich
Toshkent shahridagi Belarus–O'zbekiston qo'shma tarmoqlararo amaliy texnik kvalifikatsiyalar instituti
E-mail: matkarimov.otabek95@gmail.com
https://doi.org/10.5281/zenodo.21906471

Annotatsiya. Mazkur tezisda katta hajmdagi ma'lumotlarni tahlil qilish jarayonida izohlanadigan sun'iy intellekt (Explainable Artificial Intelligence – XAI) modellarining samaradorligini oshirish usullari tadqiq etiladi. Katta ma'lumotlar muhitida sun'iy intellekt modellarining yuqori aniqlik bilan natija berishi bilan bir qatorda, ushbu natijalarning shakllanish sabablarini tushuntira olishi ham muhim ahamiyat kasb etadi. Tadqiqotda XAI modellarining aniqligi, izohlarning tushunarliligi, modelning barqarorligi va hisoblash samaradorligini ta'minlash masalalari tahlil qilinadi.
Kalit so'zlar: katta ma'lumotlar, sun'iy intellekt, izohlanadigan sun'iy intellekt, XAI, mashinali o'qitish, ma'lumotlarni tahlil qilish, model interpretatsiyasi, SHAP, LIME, model samaradorligi.

Аннотация. В тезисе исследуются методы повышения эффективности объяснимых моделей искусственного интеллекта (Explainable Artificial Intelligence – XAI) при анализе больших объемов данных. В условиях Big Data наряду с высокой точностью результатов искусственного интеллекта особое значение приобретает способность моделей объяснять причины и механизмы формирования полученных решений. В работе рассматриваются вопросы повышения точности XAI-моделей, понятности и информативности объяснений, устойчивости моделей и вычислительной эффективности.
Ключевые слова: большие данные, искусственный интеллект, объяснимый искусственный интеллект, XAI, машинное обучение, анализ данных, интерпретация моделей, SHAP, LIME, эффективность моделей.

Abstract. This thesis examines methods for improving the efficiency of explainable artificial intelligence (XAI) models in the analysis of large-scale datasets. In Big Data environments, along with the high predictive accuracy of artificial intelligence models, their ability to explain the reasons and mechanisms underlying their decisions is of particular importance. The study analyzes approaches to improving the accuracy, interpretability, stability, and computational efficiency of XAI models.
Keywords: big data, artificial intelligence, explainable artificial intelligence, XAI, machine learning, data analysis, model interpretation, SHAP, LIME, model efficiency.

Kirish. Bugungi kunda raqamli texnologiyalarning jadal rivojlanishi natijasida turli sohalarda katta hajmdagi ma'lumotlarni yig'ish, saqlash, qayta ishlash va tahlil qilish imkoniyatlari sezilarli darajada kengaymoqda. Big Data texnologiyalarining rivojlanishi bilan bir qatorda, ushbu ma'lumotlardan samarali foydalanish, ulardagi yashirin qonuniyatlarni aniqlash va asoslangan qarorlar qabul qilish masalasi dolzarb ahamiyat kasb etmoqda. Mazkur jarayonlarda sun'iy intellekt va mashinali o'qitish algoritmlaridan keng

foydalanilayotgan bo‘lsa-da, murakkab modellarning qaror qabul qilish mexanizmlarini inson uchun tushunarli shaklda izohlash muammosi saqlanib qolmoqda.

An’anaviy sun’iy intellekt modellarining ayrimlari yuqori aniqlikdagi natijalarni taqdim eta oladi, biroq ularning qanday qilib muayyan xulosaga kelgani foydalanuvchi uchun doimo tushunarli bo‘lavermaydi. Ayniqsa, katta hajmdagi ma’lumotlarni qayta ishlashda neyron tarmoqlar, ansambl algoritmlari va boshqa murakkab modellar qo‘llanilganda, “qora quti” muammosi yanada yaqqol namoyon bo‘ladi. Shu sababli sun’iy intellekt tomonidan qabul qilingan qarorlarning sabablarini tushuntirish, model natijalarining ishonchliligini baholash va foydalanuvchiga tushunarli izohlar taqdim etish zamonaviy axborot texnologiyalarining muhim yo‘nalishlaridan biriga aylandi.

Adabiyotlar tahlili. So‘nggi yillarda sun’iy intellekt va mashinali o‘qitish texnologiyalarining rivojlanishi katta hajmdagi ma’lumotlarni qayta ishlash va ulardan samarali foydalanish imkoniyatlarini kengaytirmoqda. Guidotti va hammualliflar tomonidan olib borilgan tadqiqotda “qora quti” modellarini tushuntirishga qaratilgan mavjud yondashuvlar tizimlashtirilgan. [1]. Doshi-Velez va Kim interpretatsiya qilinadigan mashinali o‘qitishni alohida ilmiy yo‘nalish sifatida rivojlantirish zarurligini asoslagan. [2]. Ribeiro, Singh va Guestrin tomonidan ishlab chiqilgan LIME (Local Interpretable Model-agnostic Explanations) usuli murakkab mashinali o‘qitish modellarining individual bashoratlarini izohlashga qaratilgan. LIME modelning ma’lum bir prognoz atrofidagi lokal xatti-harakatini sodda va tushunarli model orqali ifodalash imkonini beradi [3]. Lundberg va Lee tomonidan taklif etilgan SHAP (SHapley Additive exPlanations) yondashuvi sun’iy intellekt modelining alohida prognoziga har bir belgi yoki omilning hissasini aniqlash imkonini beradi [4]. Arrieta va hammualliflar tomonidan olib borilgan keng qamrovli tadqiqotda izohlanadigan sun’iy intellektning asosiy tushunchalari, tasniflari, imkoniyatlari va muammolari tizimli ravishda tahlil qilingan. [5]. Vilone va Longo XAI bo‘yicha tizimli sharh tadqiqotida mavjud izohlash usullarini nazariy yondashuvlar, amaliy metodlar va ularni baholash mezonlari asosida guruhlagan. [6]. Molnar tomonidan ishlab chiqilgan *Interpretable Machine Learning* tadqiqotida mashinali o‘qitish modellarini izohlashning turli usullari, jumladan, LIME, SHAP, feature importance, permutation importance, Partial Dependence Plot va boshqa yondashuvlar tizimli ravishda yoritilgan. [7].

Materiallar va usullar. Tadqiqotda katta hajmdagi ma’lumotlarni tahlil qilishda izohlanadigan sun’iy intellekt (XAI) modellarining samaradorligini oshirish usullari o‘rganildi. Tadqiqot materiali sifatida mashinali o‘qitish modellarida qayta ishlanadigan katta hajmdagi ma’lumotlar, model natijalari va ularni izohlash ko‘rsatkichlari olindi.

1-jadval. Tadqiqotda qo‘llanilgan usullar va ularning vazifalari

Usul	Qo‘llanilish maqsadi
Qiyosiy tahlil	XAI modellarining samaradorligini solishtirish
Feature selection	Muhim belgilarni aniqlash va ma’lumot hajmini kamaytirish
LIME	Alohida model qarorlarini lokal izohlash
SHAP	Belgilarning model natijasiga ta’sirini aniqlash
Samaradorlik bahosi	Aniqlik, tezlik va izohlanuvchanlikni baholash

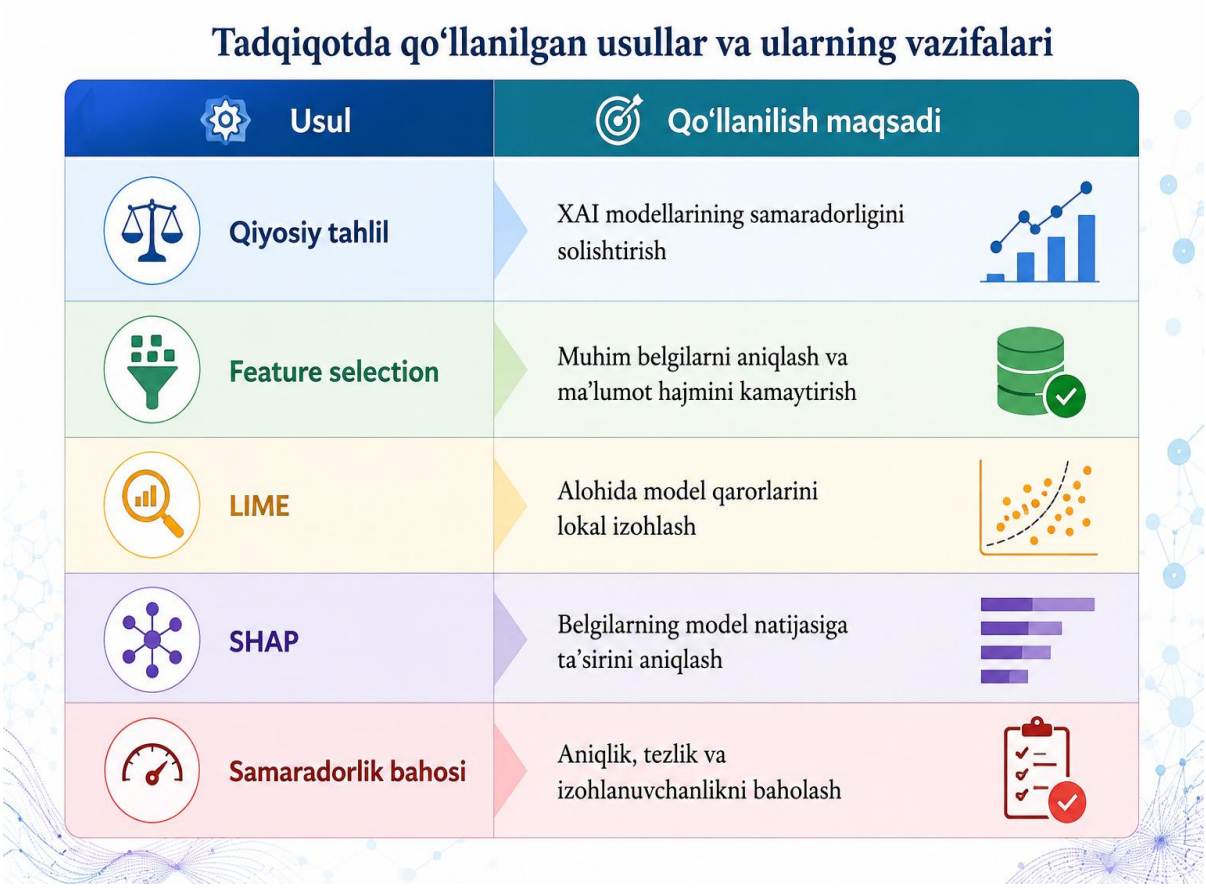

1-rasm. Tadqiqotda qo’llanilgan usullar va ularning vazifalari

Tadqiqotda model samaradorligi bashorat aniqligi, hisoblash tezligi, izohlarning tushunarliligi va barqarorligi mezonlari asosida baholandi. Ushbu usullarni kompleks qo‘llash katta hajmdagi ma’lumotlarni tahlil qilishda XAI modellarining samaradorligini oshirish imkonini beradi.

Tadqiqot muhokamasi. Tadqiqot natijalari katta hajmdagi ma’lumotlarni tahlil qilishda izohlanadigan sun’iy intellekt (XAI) modellarining samaradorligi nafaqat modelning bashorat aniqligiga, balki uning natijalarini tushuntirish imkoniyatiga ham bog‘liqligini ko‘rsatdi. An’anaviy mashinali o‘qitish modellarida yuqori aniqlikka erishish ko‘pincha modelning murakkabligini oshiradi, bu esa qarorlarni izohlashni qiyinlashtiradi. Shu sababli aniqlik va izohlanish o‘rtasidagi optimal muvozanatni ta’minlash muhim hisoblanadi.

Xulosa. Tadqiqot natijasida katta hajmdagi ma’lumotlarni tahlil qilishda izohlanadigan sun’iy intellekt (XAI) modellarining samaradorligini oshirishning asosiy yo‘nalishlari aniqlandi. Tahlillar shuni ko‘rsatdiki, sun’iy intellekt modelining samaradorligini faqat bashorat aniqligi bilan emas, balki uning qarorlarini tushuntirish imkoniyati, hisoblash tezligi, barqarorligi va foydalanuvchi uchun tushunarliligi bilan ham baholash zarur.

Katta hajmdagi ma’lumotlarni oldindan qayta ishlash, muhim belgilarni tanlash va model parametrlarini optimallashtirish hisoblash xarajatlarini kamaytirib, tahlil jarayonining tezkorligini oshiradi. LIME va SHAP kabi interpretatsiya usullaridan foydalanish esa model qarorlariga ta’sir qiluvchi omillarni aniqlash va natijalarni tushunarli shaklda taqdim etish imkonini beradi.

Foydalanilgan adabiyotlar ro'yxati

1. Guidotti R., Monreale A., Ruggieri S., Turini F., Giannotti F., Pedreschi D. A Survey of Methods for Explaining Black Box Models // ACM Computing Surveys. – 2018. – Vol. 51, No. 5. – Article 93. (KDD)
2. Doshi-Velez F., Kim B. Towards A Rigorous Science of Interpretable Machine Learning. – arXiv:1702.08608, 2017. (Google Research)
3. Ribeiro M.T., Singh S., Guestrin C. "Why Should I Trust You?": Explaining the Predictions of Any Classifier // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. – 2016. – P. 1135–1144. (DOI)
4. Lundberg S.M., Lee S.-I. A Unified Approach to Interpreting Model Predictions // Advances in Neural Information Processing Systems 30. – 2017. – P. 4765–4774. (NeurIPS Proceedings)
5. Arrieta A.B., Díaz-Rodríguez N., Del Ser J., et al. Explainable Artificial Intelligence (XAI): Concepts, Taxonomies, Opportunities and Challenges toward Responsible AI // Information Fusion. – 2020. – Vol. 58. – P. 82–115. (arXiv)
6. Vilone G., Longo L. Explainable Artificial Intelligence: A Systematic Review. – arXiv:2006.00093, 2020. (arXiv)
7. Molnar C. Interpretable Machine Learning: A Guide for Making Black Box Models Explainable. – 3rd ed. – 2025. (GitHub)