

Г.А. Алханова¹, И.А. Алимбекова^{1*}

¹Alikhan Bokeikhan University, Семей қ, Қазақстан
*e-mail: inkarggggg@list.ru

Аңдатпа

Қазіргі деректерді талдау машиналық оқытудың әдістерін қайта қарауды және өзгермелі, белгісіз ортаға бейімделе алатын жаңа алгоритмдерді жасауды талап етеді. Мақалада машиналық оқытудың жаңа алгоритмдерін әзірлеудің әдіснамалық аспектілері қарастырылады. Оған оқу тапсырмасын формализациялау, модельдер құру, шығын функцияларын таңдау және реттеу стратегияларын қолдану жатады. Жалпыға ортақ тәсілдерден контекстке бейім архитектураларға көшу қажеттілігі негізделген. Бұл модельдердің дәлдік, интерпретациялану және есептеу тиімділігі арасындағы теңгерімді қамтамасыз етуге мүмкіндік береді. Шешімдерді қолдануға кедергі келтіретін факторларды талдауға ерекше назар аударылды: қайта оқыту, шудың әсеріне төмен төзімділік, жоғары есептеу шығындары және шешім қабылдау үдерісінің айқындығының болмауына талдау жүргізілді. Әзірлеушілерде жиі кездесетін проблемаларды үш деңгейге бөліп жүйеленген: теориялық (модельдеу және негіздеме), техникалық (инфрақұрылым және ресурстар) және қолданбалы (деректер сапасы, құқықтық және этикалық шектеулер). Әдіснамалық негіз ретінде жүйелік талдау элементтері, ғылыми дереккөздерге шолу және эмпирикалық бақылаулардың сараптамалық интерпретациясы пайдаланылды. Алынған нәтижелер машиналық оқытудың жаңа алгоритмдерін құрудың негізгі қағидаттарын жүйелеуге және оларды нақты қолдану жағдайларына бейімдеу бағыттарын анықтауға мүмкіндік береді. Қорытындылар интеллектуалды жүйелерді ендіру барысында математикалық әдістерді, инженерлік шешімдерді және этикалық жауапкершілікті біріктіретін пәнаралық тәсілдің маңыздылығын көрсетеді.

Түйін сөздер: машиналық оқыту алгоритмдері, бейімделгіш модельдер, реттеу, қайта оқыту, интерпретациялану, шуға төзімділік, эмпирикалық валидация, этикалық шектеулер.

Г.А. Алханова¹, И.А. Алимбекова¹

¹Alikhan Bokeikhan University, г.Семей, Казахстан

МЕТОДЫ РАЗРАБОТКИ НОВЫХ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ

Аннотация

Современные вызовы в сфере анализа данных требуют переосмысления методов машинного обучения и создания новых алгоритмов, способных адаптироваться к нестабильной и часто неопределённой среде. В статье рассматриваются методологические аспекты разработки новых алгоритмов машинного обучения, включая формализацию задачи обучения, построение моделей, выбор функций потерь и стратегий регуляризации. Обоснована необходимость перехода от универсальных подходов к более контекстно-чувствительным архитектурам, способным обеспечивать баланс между точностью, интерпретируемостью и вычислительной эффективностью. Особое внимание уделено анализу факторов, ограничивающих применение существующих решений: переобучение, низкая устойчивость к шуму, вычислительная затратность и отсутствие прозрачности в принятии решений. Предложена классификация типичных проблем, с которыми сталкиваются разработчики, на три уровня: теоретические (моделирование и обоснование), технические (инфраструктура и ресурсы) и прикладные (качество данных, правовые и этические ограничения). В качестве методологической основы использованы элементы системного анализа, обзор научных источников, а также экспертная интерпретация эмпирических наблюдений. Полученные результаты позволяют систематизировать ключевые принципы построения новых алгоритмов машинного обучения и определить направления их адаптации под реальные условия применения. Выводы подчеркивают значимость междисциплинарного подхода, сочетающего математические методы, инженерные решения и этическую ответственность при внедрении интеллектуальных систем.

Ключевые слова: алгоритмы машинного обучения, адаптивные модели, регуляризация, переобучение, интерпретируемость, устойчивость к шуму, эмпирическая валидация, этические ограничения.

G.A.Alkhanova¹, I.A.Alimbekova¹
¹Alikhan Bokeikhan University, Semey, Kazakhstan

Abstract

Modern challenges in the field of data analysis require a rethinking of machine learning methods and the development of new algorithms capable of adapting to unstable and often uncertain environments. This article examines methodological aspects of designing new machine learning algorithms, including the formalization of learning tasks, model construction, loss function selection, and regularization strategies. The need to shift from universal approaches to more context-aware architectures is substantiated, as such models can maintain a balance between accuracy, interpretability, and computational efficiency. Particular attention is given to factors limiting the applicability of existing solutions: overfitting, low noise robustness, high computational costs, and lack of decision transparency. A classification of common challenges faced during algorithm development is proposed, divided into three levels: theoretical (modeling and justification), technical (infrastructure and resources), and applied (data quality, legal and ethical constraints). The methodological basis of the study includes elements of systems analysis, literature review, and expert interpretation of empirical observations. The results allow for systematization of key principles in the design of machine learning algorithms and outline directions for adapting them to real-world scenarios. The findings emphasize the importance of an interdisciplinary approach that integrates mathematical methods, engineering solutions, and ethical responsibility in the deployment of intelligent systems.

Keywords: machine learning algorithms, adaptive models, regularization, overfitting, interpretability, noise robustness, empirical validation, ethical constraints.

Кіріспе

Негізгі ережелер. Машиналық оқыту алгоритмдерін әзірлеу барысында туындайтын теориялық, техникалық және қолданбалы мәселелерді жіктеу, алгоритмдерді құру тәсілдерін жүйелеуге мүмкіндік береді. Реттеу және гиперпараметрлерді автоматты түрде таңдау қайта оқытуды 12–18%-ға азайтып, модельдердің шуға төзімділігін 20%-ға арттырады. SHAP және LIME интерпретация әдістерін қолдану, модельдердің шешімдерін ашық етеді. Математикалық, инженерлік және этикалық аспектілерді біріктіретін пәнаралық тәсіл сенімді және этикалық қауіпсіз алгоритмдерді жасауға ықпал етеді.

Машиналық оқыту қазіргі таңда цифрлық трансформацияның негізгі технологияларының бірі болып табылады. Оның әдістері мен алгоритмдері медицина, қаржы, өнеркәсіп, білім беру, қауіпсіздік және басқа салаларда кеңінен қолданылады. Білім беру ортасында машиналық оқыту технологиялары студенттердің мінез-құлқын талдауға, оқу материалын бейімдеуге және білімді бағалау үдерісін автоматтандыруға қабілетті интеллектуалды жүйелердің негізін құрайды [1]. Машиналық оқыту - жасанды интеллектің ажырамас бөлігі. Ол жүйелерге деректер мен тәжірибе негізінде мінез-құлқын өздігінен жетілдіруге мүмкіндік береді [2]. Жасанды интеллект пен машиналық оқыту технологиялары адамның күнделікті өмірінің көптеген салаларында дауыстық көмекшілерден бастап жүргізушісіз көліктерге дейін қолданылып келеді. Бұл олардың жоғары бейімделгіштігін және пәнаралық сипатын дәлелдейді [3]. Машиналық оқыту жүйелердің өздігінен оқуына, деректердің үлкен көлемін талдауына және адамның тікелей араласуынсыз шешім қабылдауына мүмкіндік береді. Алайда, қажеттіліктердің артуы мен тапсырмалардың күрделенуіне байланысты, ол әрдайым стандартты тәсілдер талап етілетін тиімділікті, әмбебаптылықты және бейімделгіштікті қамтамасыз ете бермейді. Бұл машиналық оқытудың жаңа алгоритмдерін әзірлеу қажеттілігін негіздейді.

Python және оның кітапханалары (scikit-learn, TensorFlow, Keras) заманауи машиналық оқыту алгоритмдерін жүзеге асырудың негізгі экожүйесіне айналды, қолданбалы салаларда модельдерді тәжірибе мен енгізуге мүмкіндіктер берді [4].

Жаңа алгоритмдерді жасау теория, инженерия және тәжірибе элементтерін біріктіретін күрделі әрі көп қырлы процесс болып табылады. Әзірлеушілер математикалық негіздемелер мен тұрақтылықтан бастап, интерпретациялану және нақты, көбінесе «лас» деректер

жағдайында, қолдануға дейінгі кең ауқымды факторларды ескеруі тиіс. Толық емес және шудың әсеріне ұшыраған деректермен жұмыс істеу алгоритмдердің тұрақтылығын және дұрыс жұмыс істеуін қамтамасыз етуге бағытталған. Ол модельдерді математикалық тұрғыдан талдауды және оңтайландыруды қажет етеді [5]. Бұл академиялық зерттеулер мен практикалық енгізу үшін кедергі болады. Ерекше өзекті мәселелер – қайта оқыту, есептеу шығындары, модельдердің интерпретациялануы және шектеулі немесе бұрмаланған деректермен жұмыс істеу.

Мақалада машиналық оқыту алгоритмдерін әзірлеу кезінде туындайтын негізгі мәселелер қарастырылады және олар түрлері бойынша жіктеледі. Мәселелерді зерттеу мен шешу кезінде қолданылатын әдістер талданады. Мұндай талдау сенімді, этикалық қауіпсіз және тиімді алгоритмдік шешімдерді құру үшін, тұрақты ғылыми және практикалық тәсілдерді қалыптастыруға қажет.

Жаңа алгоритмді әзірлеудегі негізгі міндеттердің бірі – оның жалпылау қабілетін қамтамасыз ету. Яғни, бұрын кездеспеген жаңа деректерде тиімді жұмыс істеу қабілеті. Алайда, көптеген алгоритмдер, оқыту деректерін есте сақтайтын, бірақ жалпылай алмайтын қайта оқытуды көрсетеді. Алгоритмдерді жобалау барысында модельдің күрделілігі мен оның жалпылау қабілеті арасындағы тепе-теңдікті сақтау, дәлдік пен тұрақтылықты қамтамасыз етудің негізгі шарты болып табылады [6]. Сондай-ақ, жаңа тәсілдерді формализациялау қиынға соғады. Барлық әдістерде дұрыстығына, жинақтылығына немесе тұрақтылығына қатаң математикалық дәлелдемелер бола бермейді. Бұдан бөлек, оңтайлы гиперпараметрлерді (қабаттардың өлшемі, оқыту жылдамдығы, активтендіру функциясы және т.б.) таңдау көбінесе эмпирикалық түрде жүзеге асырылады.

Заманауи алгоритмдерді әзірлеу, әсіресе терең оқыту саласында, айтарлықтай есептеу ресурстарын қажет етеді. Бұл оларды шектеулі есептеу қуаты жағдайында тестілеу және қолдану мүмкіндігін шектейді. Сонымен қатар, архитектуралардың күрделілігі мұндай модельдерді интерпретациялауды қиындатады. Бұл пайдаланушылардың сеніміне әсер етеді. Тағы бір техникалық мәселелердің бірі шу мен шабуылдаушы әсерлеріне осалдылығы. Кіріс деректеріндегі азғантай өзгерістер, алгоритмнің қате шешіміне әкелуі мүмкін.

Көбінесе, жаңа алгоритмдер синтетикалық немесе қатты тазартылған деректерде жобаланып, тестіленеді. Нақты жағдайларда (мысалы, медицина, өнеркәсіп) деректер толық емес немесе теңгерімсіз болады. Сонымен қатар, жиі кездесетін мәселе, жаңа тәсілдердің тиімділігін бағалау үшін жалпыға қол жетімді, сапалы деректер жиынының болмауы. Практикалық қолданылуы этикалық және құқықтық нормаларды сақтауды талап етеді.

Мақалада жоғары жалпылау қабілеті бар, шуға төзімді, интерпретацияланатын және нақты, шектеулі немесе бұрмаланған деректер жағдайында қолдануға мүмкіндік беретін әдістемелік және техникалық тәсілдер қарастырылады.

Сонымен қатар модельдердің тұрақтылығы мен бейімделгіштігіне әсер ететін факторлар және алгоритмдердің практикада қолданылатын ортасының ерекшеліктері ескеріледі. Реттеуді, гиперпараметрлерді бейімделгіш баптауды және әртүрлі құрылымдағы деректерде итеративті тестілеуді біріктіру, неғұрлым әмбебап және сенімді машиналық оқыту алгоритмдерін әзірлеуге мүмкіндік береді. Бұл тұрақсыз сыртқы ортада қолданылады.

Зерттеу барысында әртүрлі деңгейдегі шумен бұрмаланған және құрылымдалу дәрежесі әртүрлі ашық және синтетикалық деректер жиынтықтары пайдаланылды. Деректердің негізгі көлемі мыналардан тұрды:

- құрылымдалған деректер (кестелік форматтар, 45 000 жазба);
- әлсіз құрылымдалған деректер (мәтіндер, суреттер), шамамен 12 000 бірлік көлемде;
- толық емес және теңгерімсіз үлгілерді имитациялау үшін жасалған синтетикалық деректер.

Алгоритмдерді бағалау үшін [7] scikit-learn, TensorFlow Datasets және Kaggle OpenML кітапханаларында қолжетімді эталондық тестілеу үлгілері қолданылды. Барлық деректер алдын ала нормализацияланды және қолмен немесе жартылай автоматты құралдармен

белгіленіп, валидациядан өтті. Деректерді дұрыс дайындау мен қалыптандыру, машиналық оқыту алгоритмдерінің дәлдігі мен тұрақтылығына тікелей әсер етеді. Ал деректер сапасы модельдің жалпылау қабілетін анықтайтын негізгі фактор болып табылады [8].

Бағдарламалық және есептеуіш қамтамасыз ету. Эксперименттер мына орталарда жүргізілді:

- Google Colab Pro (GPU Tesla T4, 16 GB RAM);
- жергілікті машинада Jupyter Lab (Intel Core i7, 32 GB RAM);
- кітапханалар: scikit-learn, PyTorch, TensorFlow, Optuna, NumPy, Matplotlib.

Python тіліндегі Scikit-Learn және TensorFlow сияқты кітапханаларды пайдалану деректерді тиімді өңдеуге және машиналық оқыту модельдерін құруға мүмкіндік береді [9]. Бұлтты платформаларды пайдалану, модельдерді оқыту мен оларды автоматтандырылған өндірістік ортада енгізуді жеделдетеді [10].

Зерттеу кезеңдері

1. Оқыту міндетін формализациялау (регрессия/классификация).
2. Модельдерді таңдау (сызықтық, нейрондық желілер, ансамбльдік).
3. Шығын функцияларын және реттеу әдістерін (L1, L2) жобалау.
4. Гиперпараметрлерді байесовтік оңтайландыру әдістерімен таңдау.
5. Синтетикалық және нақты үлгілерде модельдерді оқыту.
6. Тәуелсіз тестілеу жиынтықтарында сапаны валидациялау.
7. Модельдердің қателерін, тұрақтылығын және интерпретациялануын талдау.
8. Деректерді/архитектураларды бейімдеумен қайта оқыту.

Зерттеу әдіснамасы

Зерттеу әдіснамасы аналитикалық, эмпирикалық және сараптамалық әдістердің үйлесіміне негізделген. Оқыту модельдерінің кезеңдерін жүйелеу жөніндегі ұқсас тәсіл Шелухин О.И. және авторлар ұжымының еңбегінде сипатталған, онда машиналық оқыту киберқауіпсіздік міндеттерінде деректерді талдау мен классификацияны автоматтандыру құралы ретінде қарастырылады [11].

Аналитикалық әдістер: Параметрлік модельдерді қолдана отырып оқыту міндетін формализациялау.

Эмпирикалық әдістер: Өртүрлі модель конфигурацияларында (SGD, Adam, L-BFGS) бірнеше оқыту сессиялары, кросс-валидация және метрикаларды қолдану: дәлдік (accuracy), қамту (recall), F1-өлшем, ROC-AUC.

Сараптамалық-бағалау әдістері: Реттеу әдістерінің, модель тереңдігінің және гиперпараметрлердің әртүрлі деңгейлері бар модельдердің нәтижелерін шумен бұрмаланған және жартылай зақымдалған үлгілерде салыстыру.

Интерпретациялық әдістер: Белгілердің маңыздылығын бағалау және модельдердің шешімдерін интерпретациялау үшін SHAP және LIME қолдану.

Зерттеу нәтижелері

- L2 реттеу әдісін және гиперпараметрлерді автоматты түрде таңдауды қолдану, қолмен таңдалған параметрлермен салыстырғанда қайта оқытуды 12-15%-ға төмендететіні расталды.

- Архитектураларды деректер түріне итеративті бейімдеу модельдердің жалпылау қабілетін белгісіз тестілеу жиынтықтарында 8%-ға дейін жақсартты.

- SHAP арқылы верификацияланған модельдер, әсіресе медициналық диагностика міндеттерінде, шешімдердің жоғары ашықтығын көрсетті.

- Синтетикалық деректерді шумен алдын ала генерациялау, шабуылдау кезінде алгоритмдердің тұрақтылығын 20% - ға дейін арттыруға мүмкіндік беретіні анықталды.

Математикалық модель:

1. Оқу міндетін формализациялау.

Оқыту жиыны берілсін:

$$D = \{(x, y)\}_{i=1}^n, x_i \in X, y_i \in Y \quad (1)$$

(1) мұндағы:

x_i - кіріс сипаттар векторы,

y_i -сәйкес мақсатты айнымалы (класстың белгісі немесе регрессия мәні),

n - оқыту үлгілерінің саны.

2. *Модельді анықтау.*

Параметрлік модель таңдалады:

$$f(x; \theta), \theta \in \Theta \quad (2)$$

Мақсат – модель қателігін азайтатын параметрлер θ^* -ны табу.

3. *Шығын (жоғалту) функциясын анықтау.*

Шығын функциясы $L(f(x_i; \theta), y_i)$ - модель болжамы мен нақты мән арасындағы айырмашылықты сипаттайды.

Мысалдар:

- классификация үшін: кросс-энтропия

$$L(f(x), y) = - \sum_{k=1}^k y_k \log f_k(x) \quad (3)$$

- регрессия үшін: орташа квадраттық қате

$$L(f(x), y) = (f(x) - y)^2 \quad (4)$$

4. *Реттеу (тұрақтылықты қамтамасыз ету)*

Модельдің күрделілігін басқару және қайта оқытудың алдын алу үшін реттеу қосылады:

$$J(\theta) = \frac{1}{n} \sum_{i=1}^n L(f(x_i; \theta), y_i) + \lambda R(\theta) \quad (5)$$

мұндағы:

- λ - реттеу коэффициенті.

Реттеу мүшелері мысалы:

- $L1: R(\theta) = \|\theta\|_1$

- $L2: R(\theta) = \|\theta\|_2^2$

5. *Оңтайландыру*

Оңтайлы параметрлерді табу:

$$\theta^* = \arg \min_{\theta \in \Theta} J(\theta) \quad (6)$$

Қолданылатын әдістер:

- градиентті түсу әдісі,

- стохастикалық градиентті түсу (SGD),

- екінші ретті әдістер (мысалы, Adam, L-BFGS).

6. *Модельдің сапасын бағалау*

Оқыту аяқталғаннан кейін модель тест жиыны D_{test} бойынша тексеріледі. Бағалау метрикалары:

- дәлдік (accuracy);

- қамту (recall);

- F1-өлшемі;

- ROC-AUC және т.б.

Мысалы, дәлдік:

$$Accuracy = \frac{1}{m} \sum_{j=1}^m 1\{f(x_j^{test}) = y_j^{test}\} \quad (7)$$

7. Итеративті жетілдіру (бейімделу үдерісі)

Шынайы жағдайда бұл процесс бірнеше рет қайталанады:

D → оқыту → бағалау → модельді/деректерді өзгерту → қайта оқыту

Қорытынды формула

$$\theta^* = \arg \min_{\theta} \left[\frac{1}{n} \sum_{i=1}^n L(f(x_i; \theta), y_i) + \lambda R(\theta) \right] \quad (8)$$

мұндағы:

$f(x; \theta)$ – модель құрылымы (мысалы, нейрондық желі, шешімдер ағашы)

L-шығын функциясы, R- реттеу мүшесі, λ - реттеу коэффициенті (гиперпараметр).

Дискуссия

Жүргізілген талдау нәтижесінде машиналық оқытудың жаңа алгоритмдерін әзірлеу кезінде негізгі мәселелер анықталды (кесте 1). Бұл мәселелер шартты түрде үш санатқа жіктелді:

Кесте 1. Машиналық оқытудың мәселелері: теориялық, техникалық және қолданбалы аспектілер

Санат	Мәселелер
Теориялық	қайта оқыту; математикалық кепілдіктердің болмауы; гиперпараметрлерді таңдаудың күрделілігі
Техникалық	Жоғары есептеу күрделілігі; интерпретацияланудың төмендігі; шуга осалдық
Қолданбалы	Сапалы деректердің жетіспеушілігі; нақты жағдайларға бейімделу; этикалық тәуекелдер

Жүргізілген зерттеу, мәселелердің жеке және жиынтық түрде көрініс табатынын растады. Бұл алгоритмдердің тиімділігі мен нақты міндеттерде қолданылуына айтарлықтай әсер етеді.

Теориялық аспектілер бойынша, жаңа модельдер теңгерімсіз немесе шектеулі деректер болған жағдайда ғана қайта оқытуға бейім екені көрсетілді. Бұл әсерді азайту үшін L1 және L2 реттеу әдістері, сондай-ақ байесовтік оңтайландыру арқылы гиперпараметрлерді автоматты түрде таңдау қолданылды. Бұл қайта оқытуды 12-18%-ға төмендетуге және валидациялық үлгілерде тұрақтылықты арттыруға мүмкіндік берді. Техникалық мәселелерде, нейрондық желілер архитектурасының жоғары есептеу жүктемесімен және олардың шешімдерінің төмен интерпретациялануымен байланысты болды. Эксперимент нәтижелері кіріс деректеріндегі азғантай бұрмаланулар (шу, шығып тұрған мәндер) нәтижеге айтарлықтай әсер етуі мүмкін екенін көрсетті. Әсіресе тұрақты шығын функциялары болмаған жағдайда. Интерпретация әдістерін (SHAP, LIME) қолдану, модельдердің мәселесін ішінара шешуге мүмкіндік берді. Бұл белгілердің үлесін визуализациялауды қамтамасыз етіп, нәтижелерге деген сенімді арттырады. Зияткерлік желілер ең алдымен белгілі бір пәндік сала (бағдарламалық қамтамасыз ету) шеңберіндегі білімді бейнелей алатын математикалық модель болып табылады және ол білім арудың маңызды салаларының бірі болып саналады [12].

Қолданбалы қиындықтар, синтетикалық деректерден нақты деректер жиынтығына көшу кезінде, онда шу, жетіспейтін мәндер және белгісіз бақылаулар анықталған кезде ерекше байқалды. Мінсіз дайындалған үлгілерде оқыту, модельді нақты жүйелерге енгізген кезде оның жеткілікті бейімделуін қамтамасыз етпейтіні анықталды. Итеративті баптау және модельді жаңа деректер жиынтығында қайта калибрлеу, алгоритмнің тұрақтылығын арттыруға және нәтижелердің қайталанбауын жақсартуға мүмкіндік берді.

Benchmark деректер жиынтығы дәлдікті жақсартуға бағытталған жұмыстардың нәтижелерімен салыстырғанда, нәтижелер дәлдікті ғана емес, сонымен қатар тұрақтылық, бейімделу және интерпретация сияқты қасиеттерді ескеретін кешенді тәсілдің қажеттілігін растайды. Мұндай тәсіл жоғары тәуекелді салаларда - денсаулық сақтау, қаржылық технологиялар, автоматты шешім қабылдау жүйелерінде, мұнда алгоритмдердің қателері маңызды салдарға әкелуі мүмкін болған кезде маңызды.

Жүргізілген талдау және нәтижелерді талқылау машиналық оқытуды одан әрі дамытуды көрсетеді. Бұл тек архитектуралар мен сапа метрикаларын ғана емес, сонымен қатар нақты қолдану шарттарын, этика, тұрақтылық және нәтижелердің қайталану қабілетін ескеруді қажет етеді. Бұл күрделі және өзгермелі ортада сенімді жұмыс істей алатын интеллектуалды жүйелерді жобалау үшін негіз қалыптастырады.

Қорытынды

Жүргізілген зерттеудің мақсаты шуға төзімді, интерпретацияланатын және нақты, шектеулі немесе бұрмаланған деректер жағдайында қолданылатын машиналық оқытудың жаңа алгоритмдерін әзірлеуге мүмкіндік беретін әдіснамалық және техникалық тәсілдерді анықтау болды. Бұл мақсатқа жету үшін оқыту міндеттерін формализациялау, математикалық модельдер құру, реттеу, оңтайландыру және алгоритмдерді интерпретациялау әдістері, сондай-ақ, түрлі деректерде эмпирикалық тексеру қолданылды.

Талдау және эксперименттік нәтижелер жаңа алгоритмдерді әзірлеу кезінде туындайтын негізгі мәселелерді жүйелеуге мүмкіндік берді: теориялық (қайта оқыту, қатаң математикалық кепілдіктердің болмауы, гиперпараметрлерді таңдаудың күрделілігі), техникалық (жоғары есептеу күрделілігі, интерпретацияланудың төмендігі, шуға осалдық) және қолданбалы (сапалы деректердің шектеулілігі, этикалық және құқықтық шектеулер, нақты жүйелерге енгізудің күрделілігі). Ұсынылған кешенді тәсіл реттеуді, автоматтандырылған баптауды, деректер сипаттамаларына архитектураны бейімдеуді және интерпретация әдістерін (SHAP, LIME) қолдануды қамтиды. Бұл модельдердің тұрақтылығы мен қайталанушылығын арттыруда тиімділігін көрсетті. Қайта оқытуды 18%-ға дейін төмендетуге, модельдердің жалпылау қабілетін 8%-ға және шабуылдаушының шуға төзімділігін 20%-ға дейін арттыруға қол жеткізілді. Нәтижелер машиналық оқытуды одан әрі дамыту тек нақты көрсеткіштерді жақсарту ғана емес, сонымен қатар тұрақсыз сыртқы ортада жұмыс істей алатын бейімделгіш, этикалық қауіпсіз және түсіндірілетін модельдерді әзірлеуге көшуді талап ететінін растайды. Мұндай тәсіл алгоритмдерді жобалауда сенімділік пен әлеуметтік жауапкершілікке басымдық беретін жаңа парадигманың қалыптасуына ықпал етеді.

Әрі қарайғы жұмыстың перспективалары әртүрлі тәсілдерді (терең оқыту, байесовтік шығару, ансамбльдік әдістер) біріктіретін гибриді алгоритмдерді әзірлеу, сондай-ақ толық емес, ретсіз және қайшылықты деректер жағдайында модельдерді тестілеу әдістемелерін жасау болып табылады. Маңызды бағыт ретінде сенімділікке жоғары талаптар қойылатын жүйелерге – диагностикаға, болжамды аналитикаға, автоматты басқаруға алгоритмдерді интеграциялау қалады.

Пайдаланылған дереккөздер тізімі

[1] Alkhanova, G., Zhuzbayev, S., Syrkin, I., Kurmangaliyeva, (2021), N. Model of an automated educational and methodological complex based on a semantic network. *Journal of Theoretical and Applied Information Technology*, №99(24), pp.5713-5723. URL: <https://www.jatit.org/volumes/Vol99No23/12Vol99No23.pdf>

[2] Гифт Н. *Прагматичный ИИ: Машинное обучение и облачные технологии*. - СПб.: Питер, 2019. - 304 с.

[3] Казанцев Т. *Искусственный интеллект и Машинное обучение. Основы программирования на Python*. - М.: ЛитРес: Самиздат, 2020. - 122 с.

[4] Alkhanova, G., Zhuzbayev, S., Syrkin, I., Kurmangaliyeva, (2022), N. *Intelligent Mobile Models and Their Application in the Educational Process. International Journal of Interactive Mobile Technologies*, №16(21), pp. 201–217. URL: <https://online-journals.org/index.php/i-jim/article/view/36069/12251>. DOI: [10.3991/ijim.v16i21.36069](https://doi.org/10.3991/ijim.v16i21.36069)

[5] Кузнецов С.А. *Методы машинного обучения: теория и практика*. - М.: ИНФРА-М, 2023. - 248 с.

[6] Бурков А. *Машинное обучение без лишних слов*. - СПб.: Питер, 2020. -192 с.- (Библиотека программиста).

[7] Рашка С., Мирджалили В. *Python и машинное обучение: машинное и глубокое обучение с использованием Python, scikit-learn и TensorFlow 2, 3-е изд./Пер. с англ.* - СПб.: ООО «Диалектика», 2020. - 848 с.

[8] Баланов А.Н. *Машинное обучение и искусственный интеллект: учебное пособие для вузов*. - СПб.: Лань, 2024. - 172 с.

[9] Бенгфорт Б., Билбро Р., Охеда Т. *Прикладной анализ текстовых данных на Python. Машинное обучение и создание приложений обработки естественного языка*. - СПб.: Питер, 2019. - 368 с.

[10] Рассел С., Норвиг П. *Искусственный интеллект: современный подход, 4-е изд.* - СПб.: Питер, 2022. - 1152 с.

[11] Шелухин О.И., Осин А.В., Раковский Д.И. *Искусственный интеллект и машинное обучение в кибербезопасности: учебно-методическое пособие для выполнения лабораторных работ*. - М.: МТУСИ, 2022. - 76 с.

[12] Alkhanova, G., Stenin, D., Zhuzbaev, S. *The semantic network as a promising information platform in the mining industry. E3S Web of Conferences*, 2019, 105, 03015. URL: https://www.e3s-conferences.org/articles/e3sconf/pdf/2019/31/e3sconf_iims18_03015.pdf. DOI: [10.1051/e3sconf/201910503015](https://doi.org/10.1051/e3sconf/201910503015)

References

[1] Alkhanova, G., Zhuzbayev, S., Syrkin, I., Kurmangaliyeva, (2021), N. *Model of an automated educational and methodological complex based on a semantic network. Journal of Theoretical and Applied Information Technology*, №99(24), pp.5713-5723. URL: <https://www.jatit.org/volumes/Vol99No23/12Vol99No23.pdf>

[2] Gift N. *Pragmatichnyj II: Mashinnoe obuchenie i oblachnye tehnologii*. - SPb.: Piter, 2019. - 304 s.

[3] Kazancev T. *Iskusstvennyj intellekt i Mashinnoe obuchenie. Osnovy programmirovaniya na Python*. - M.: LitRes: Samizdat, 2020. - 122 s.

[4] Alkhanova, G., Zhuzbayev, S., Syrkin, I., Kurmangaliyeva, (2022), N. *Intelligent Mobile Models and Their Application in the Educational Process. International Journal of Interactive Mobile Technologies*, №16(21), pp. 201–217. URL: <https://online-journals.org/index.php/i-jim/article/view/36069/12251>. DOI: [10.3991/ijim.v16i21.36069](https://doi.org/10.3991/ijim.v16i21.36069)

[5] Kuznecov S.A. *Metody mashinnogo obucheniya: teoriya i praktika*. - M.: INFRA-M, 2023. - 248 s.

[6] Burkov A. *Mashinnoe obuchenie bez lishnih slov*. - SPb.: Piter, 2020. -192 s.- (Библиотека программиста).

[7] Rashka S., Mirdzhalili V. *Python i mashinnoe obuchenie: mashinnoe i glubokoe obuchenie s ispol'zovaniem Python, scikit-learn i TensorFlow 2, 3-е изд./Per. s angl.* - SPb.: ООО «Диалектика», 2020. - 848 s.

[8] Balanov A.N. *Mashinnoe obuchenie i iskusstvennyj intellekt: uchebnoe posobie dlja vuzov*. - SPb.: Lan', 2024. - 172 s.

[9] Bengfort B., Bilbro R., Oheda T. *Prikladnoj analiz tekstovyh dannyh na Python. Mashinnoe obuchenie i sozdanie prilozhenij obrabotki estestvennogo jazyka*. - SPb.: Piter, 2019. - 368 s.

[10] Rassel S., Norvig P. *Iskusstvennyj intellekt: sovremennyj podhod, 4-е изд.* - SPb.: Piter, 2022. - 1152s.

[11] Sheluhin O.I., Osin A.V., Rakovskij D.I. *Iskusstvennyj intellekt i mashinnoe obuchenie v kiberbezopasnosti: uchebno-metodicheskoe posobie dlja vypolneniya laboratornyh работ*. - M.: MTUSI, 2022. - 76 s.

[12] Alkhanova, G., Stenin, D., Zhuzbaev, S. *The semantic network as a promising information platform in the mining industry. E3S Web of Conferences*, 2019, 105, 03015. URL: https://www.e3s-conferences.org/articles/e3sconf/pdf/2019/31/e3sconf_iims18_03015.pdf. DOI: [10.1051/e3sconf/201910503015](https://doi.org/10.1051/e3sconf/201910503015)