

UDK 004.62:004.89:37.018.43

## TA'LIM PLATFORMALARI LOG-MA'LUMOTLARI ASOSIDA TALABALARNING O'ZLASHTIRISH XAVFINI ERTA ANIQLASH UCHUN TUSHUNTIRILADIGAN MASHINAVIY O'QITISH MODELINI ISHLAB CHIQISH

*Husan Arziqulov Normurod o'g'li*

*Navoiy davlat universiteti dotsenti*

[arziqulovhusannormurodovich@gmail.com](mailto:arziqulovhusannormurodovich@gmail.com)

<https://orcid.org/0009-0005-0970-3766>

**Annotatsiya:** Mazkur maqolada ta'lim platformalarida shakllanadigan log-ma'lumotlar asosida talabalarning o'zlashtirish xavfini erta aniqlashga xizmat qiluvchi tushuntiriladigan mashinaviy o'qitish modeli taklif etiladi. Tadqiqotning muammoli maydoni raqamli ta'lim muhitida to'planayotgan katta hajmdagi xatti-harakat ma'lumotlarini pedagogik qaror qabul qilishga mos, izohlanadigan va amaliy jihatdan qo'llanadigan ko'rinishga keltirish zaruratidan kelib chiqadi. Taklif etilayotgan yechimda log-ma'lumotlar sessiya, hafta va kurs kesimida agregatsiyalanadi; ulardan faollik intensivligi, davomiylilik, topshiriq bajarish ritmi, kechikish, barqarorlik va o'zaro ta'sir xilma-xilligi kabi belgilarning hosil qilinishi nazarda tutiladi. Bashoratlash qatlami uchun logistic regression, random forest va XGBoost kabi modellar benchmark va asosiy model sifatida qaraladi, interpretatsiya uchun esa SHAP asosidagi global hamda lokal izohlar qo'llanadi. Tahlil natijasida samarali erta ogohlantirish tizimi uchun faqat aniqlik emas, balki recall, kalibrovka, vaqt bo'yicha barqarorlik va noto'g'ri bashoratlarni alohida izohlash talab etilishi asoslandi. Shuningdek, modeldan foydalanishda minimal, ammo mazmunli feature to'plami, time-sliced validatsiya va misprediction tahlili ustuvor dizayn talablari sifatida ajratildi.

**Kalit so'zlar:** learning analytics, log-ma'lumotlar, o'zlashtirish xavfi, erta ogohlantirish tizimi, mashinaviy o'qitish, XAI, SHAP, student success prediction.

**Аннотация:** В данной статье предлагается объяснимая модель машинного обучения, предназначенная для раннего выявления риска академической неуспеваемости студентов на основе лог-данных, формирующихся на образовательных платформах. Проблемное поле исследования обусловлено необходимостью преобразования большого объёма поведенческих данных, накапливаемых в цифровой образовательной среде, в форму, пригодную для принятия педагогических решений, объяснимую и практически применимую. В предлагаемом решении лог-данные агрегируются на уровне сессии, недели и курса; предусматривается формирование таких признаков, как интенсивность активности, продолжительность, ритм выполнения заданий, задержка, устойчивость и разнообразие взаимодействий. Для прогностического слоя модели *logistic regression*, *random forest* и *XGBoost* рассматриваются как *benchmark*- и основные модели, тогда как для интерпретации применяются глобальные и локальные объяснения на основе SHAP. В результате анализа обосновано, что эффективная система раннего предупреждения требует не только *accuracy*, но и *recall*, калибровки, временной устойчивости, а также отдельного объяснения ошибочных прогнозов. Кроме того, в качестве приоритетных проектных требований при использовании модели выделены минимальный, но содержательно значимый набор признаков, *time-sliced* валидация и анализ *mispredictions*.

**Ключевые слова:** *learning analytics*, лог-данные, риск академической неуспеваемости, система раннего предупреждения, машинное обучение, ХАИ, SHAP, прогнозирование академической успешности студентов.

**Abstract:** This article proposes an explainable machine learning model for the early identification of students' academic risk based on log data generated on educational platforms. The problem field of the study arises from the need to transform the large volume of behavioral data accumulated in the digital learning environment into a form that is suitable for pedagogical decision-making, explainable, and practically applicable. In the proposed solution, log data are aggregated at the session, week, and course levels; the derivation of features such as activity intensity, duration,

assignment completion rhythm, delay, stability, and interaction diversity is envisaged. For the prediction layer, models such as logistic regression, random forest, and XGBoost are considered as benchmark and core models, whereas SHAP-based global and local explanations are applied for interpretation. The analysis substantiated that an effective early warning system requires not only accuracy, but also recall, calibration, temporal stability, and separate explanation of mispredictions. In addition, a minimal yet informative feature set, time-sliced validation, and misprediction analysis were identified as priority design requirements in the use of the model.

**Key words:** learning analytics, log data, academic risk, early warning system, machine learning, XAI, SHAP, student success prediction.

**Kirish.** Raqamli ta'lim platformalari o'quv jarayonining deyarli barcha komponentlarini raqamli iz sifatida qayd etadi. Kirish chastotasi, sahifa ko'rishlari, topshiriq topshirish vaqti, forumdagi faollik, material bilan ishlash ritmi va sessiyalar davomiyligi kabi ko'rsatkichlar talabning o'quv xatti-harakatini bilvosita ifodalaydi. Kuzilek, Hlosta va Zdrahal tomonidan tavsiflangan OULAD datasetida 22 ta kurs, 32 593 talaba va 10 655 280 ta VLE klik yozuvi mavjud bo'lib, bunday tuzilmadagi log-ma'lumotlar student behavior va academic outcome o'rtasidagi bog'lanishni tahlil qilish uchun barqaror empirik baza yaratishini ko'rsatadi [1,bb. 1-2].

Talabani xavf guruhiga erta ajratish faqat monitoring vazifasi emas, balki aralashuvni vaqtida rejalashtirishning texnik asosi hisoblanadi. Alyahyan va Düştegör student success prediction bo'yicha keng adabiyotlar sharhida erta aniqlash, ma'lumotlarni tozalash, belgi tanlash va mos metrikalarni tanlash butun jarayonning sifatiga bevosita ta'sir qilishini ko'rsatib, predictive pipeline bosqichma-bosqich loyihalanishi lozimligini ta'kidlaydilar [2, bb. 1-2, 9-10].

Shu bilan birga, o'quv xavfini bashoratlash tizimlari oldida ikkita fundamental talab mavjud. Birinchisi, modelning erta bosqichda yetarlicha foydali aniqlikka ega bo'lishidir; ikkinchisi esa, model chiqargan qarorlarning izohlab berilishi, ya'ni qaysi omillar talabning xavf skoriga ko'proq ta'sir qilganini ochiq ko'rsatishidir. Saqr va López-Pernas izohlanadigan sun'iy intellekt bo'yicha tadqiqotida aggregate-level

tushuntirishlar doimo yetarli emasligini, ayniqsa noto‘g‘ri bashoratlarning individual darajadagi oqibatlarini alohida tahlil qilish zarurligini qayd etadilar [5, bb. 1-2].

Mazkur ishning maqsadi ta‘lim platformalari log-ma‘lumotlari asosida talabalarning o‘zlashtirish xavfini erta aniqlash uchun tushuntiriladigan mashinaviy o‘qitish modelining konseptual-texnik arxitekturasini ishlab chiqish, uning ma‘lumotlar oqimi, belgilar tizimi, bashoratlash va izohlash qatlamlarini ilmiy manbalar asosida asoslab berishdan iborat.

### **Mavzuga oid adabiyotlarning tahlili**

Student success prediction bo‘yicha zamonaviy tadqiqotlar predictorlarni odatda to‘rtta katta guruhga ajratadi: demografik belgilar, avvalgi akademik natijalar, psixologik ko‘rsatkichlar va e-learning activity logs. Alyahyan va Düştegör aynan universitet ichidagi ma‘lumotlar, xususan platforma bilan o‘zaro ta‘sir ko‘rsatkichlari prediction natijasini yaxshilashini, shu bilan birga belgi sonini nazoratsiz oshirish modelning talqin qilinishini qiyinlashtirishini ko‘rsatadilar [2, bb. 6-7, 16-17].

Yağcı ta‘lim ma‘lumotlarini qazib olish sohasidagi ko‘plab tadqiqotlarni umumlashtirib, loglar, baholash natijalari va o‘quv faoliyati izlari yashirin qonuniyatlarni aniqlash hamda academic achievementni bashoratlashda amaliy qiymatga ega ekanini ko‘rsatadi. Muallif tomonidan sharhlangan ishlar klassifikatsiya algoritmlarining keng doirasi qo‘llanayotganini, lekin data cleaning, feature transformation va evaluation mezonlari natijaga kuchli ta‘sir ko‘rsatishini tasdiqlaydi [3, bb. 1-2, 16-17].

Erta ogohlantirish tizimlariga bag‘ishlangan alohida tadqiqotlar predictionning aynan vaqt omiliga sezgirligini ochib beradi. Akçapınar, Altun va Aşkar 76 nafar talaba qatnashgan blended kurs ma‘lumotlari asosida qurilgan modelda muvaffaqiyatsiz talabalarni 3 hafta ichidayoq 74% darajada aniqlash mumkinligini ko‘rsatgan; bu esa early-stage behavioral signals pedagogik aralashuv uchun yetarli bo‘lishi mumkinligini bildiradi [4, b. 1]. Mazkur ishning muhim jihati shundaki, unda data transformation, feature selection va turli klassifikatorlar qiyosiy sinovdan o‘tkazilib, time-based prediction mustaqil masala sifatida qo‘yilgan.

Mamlakatimiz olimlari tomonidan ham mashinaviy o‘qitish asosidagi qaror qabul qilish tizimlarini qurishda ma’lumotlarni dastlabki qayta ishlash, multikollinearlik va haddan tashqari moslashishni bartaraf etish, shuningdek, ansambl algoritmlarni qo‘llash muhim metodik bosqichlar sifatida ko‘rsatiladi. Yarmatovning dissertatsiyasida ma’lumotlarni mashinaviy o‘qitishga tayyorlash algoritmi, tartibga solish usullari va bir nechta samarali modellarni birlashtiruvchi Voting Regressiya ansambli ishlab chiqilgani qayd etilgan [6, bb. 6-8, 19]. Mazkur xulosa ta’lim platformalari log-ma’lumotlari bilan ishlashda ham preprocessing va ensemble benchmarkingni alohida bosqich sifatida ajratish zarurligini ko‘rsatadi.

So‘nggi bosqichda asosiy e’tibor modelni tushuntirishga qaratilmoqda. Saqr va López-Pernas prediction modelini izohlashning o‘zi yetarli emasligi, misprediction holatlari alohida tahlil qilinmasa, tavsiya chiqarish xavfli bo‘lib qolishini ko‘rsatadilar [5, bb. 1-3]. Demak, zamonaviy yondashuv uchun interpretability faqat feature importance jadvali emas, balki global, lokal va xato bashoratlarni izohlash imkonini beruvchi ko‘p qatlamli mexanizm bo‘lishi kerak.

### 1-jadval. Asosiy manbalar bo‘yicha texnik xulosalar

Manba adabiyotlar tartib raqmi bilan berilgan	Ma’lumot turi	Asosiy metodik urg‘u	Model uchun foydali xulosa
[1] Kuzilek va b.	Ochiq log dataset	Katta hajmli VLE klik va demografik yozuvlar	Benchmark va data schema uchun baza
[2] Alyahyan, Düştegör	Tizimli sharh	Predictive pipeline va evaluation	Data cleaning, feature selection va metrika tanlash majburiy
[3] Yağcı	Sharh va qiyosiy tahlil	EDM algoritmlari va omillar	Belgi transformatsiyasi natijaga sezgir
[4] Akçapınar va b.	Erta warning amaliyoti	Time-based prediction	3-haftalik signal ham foydali bo‘lishi mumkin
[5] Saqr, López-Pernas	XAI tadqiqoti	Misprediction va instance-level explainability	Global va lokal izohlar birga qo‘llanishi lozim

[6] Yarmatov	PhD dissertatsiyasi	Preprocessing, tartibga solish va ansambl algoritmlar	Preprocessing va ensemble benchmarking alohida bosqich bo‘lishi kerak
--------------	---------------------	---	---

### Tadqiqot metodologiyasi

Mazkur maqola konseptual-loyihaviy tadqiqot sifatida ishlab chiqildi. Unda qiyosiy tahlil, design-oriented modeling hamda feature engineering yondashuvlari o‘zaro uyg‘un holda qo‘llanildi. Metodologik asos sifatida ta’lim platformalarida saqlanadigan raw log yozuvlarini risk prediction vazifasiga mos, semantik jihatdan boyitilgan va izohlanadigan belgilar tizimiga transformatsiya qilish g‘oyasi qabul qilindi.

Taklif etilayotgan modelda ma’lumotlarni tayyorlash uch bosqichli agregatsiya asosida amalga oshiriladi: sessiya darajasi, hafta darajasi va kurs darajasi. Sessiya darajasida login va exit oralig‘i, ko‘rilgan obyektlar soni, sessiya davomiyligi hamda uzilish holatlari qayd etiladi. Hafta darajasida kumulyativ faollik, topshiriqlarni topshirish vaqti, forumdagi javoblar soni, o‘quv material bilan ishlash izchilligi va kechikish koeffitsienti kabi ko‘rsatkichlar shakllantiriladi. Kurs darajasida esa talabanning umumiy engagement profili, faoliyat barqarorligi va baholash natijalari bilan bog‘liq hosila belgilar hosil qilinadi. Mazkur yondashuv Alyahyan va Düştegör tomonidan ajratib ko‘rsatilgan data preparation hamda feature derivation bosqichlari bilan metodologik jihatdan uyg‘unlashadi [2, bb. 9–11].

Maqsadli o‘zgaruvchi sifatida ikkilik risk yorligi yoki uzluksiz risk skori qo‘llanishi mumkin. Ikkilik holda talabanning oraliq nazorat, yakuniy baho yoki platformadagi uzoq davom etgan passivlik asosida risk guruhiga mansubligi belgilanadi. Uzluksiz holda esa model  $P(y=1|x)$  ko‘rinishidagi ehtimollikni qaytaradi va ushbu qiymat oldindan tanlangan  $\tau$  threshold bilan taqqoslanadi. Threshold tanlashda recall ustuvor bo‘lishi maqsadga muvofiq, chunki erta warning tizimlarida xavfli talabani o‘tkazib yuborish noto‘g‘ri ogohlantirish berishdan ko‘ra jiddiyroq oqibatga ega.

Bashoratlovchi qatlam uchun uch darajali model oilasi tavsiya etiladi: logistic regression - tushunarli va barqaror benchmark sifatida; random forest - nolinear bog‘lanishlarni ushlovchi kuchli ansambl sifatida; XGBoost - yuqori aniqlik va feature interactionlarni ushlash salohiyati tufayli asosiy model sifatida. Biroq model tanlashda faqat accuracy emas, balki recall, F1, ROC-AUC, calibration va vaqt bo‘yicha stability ham baholanishi kerak. Bunday yondashuv best-practice evaluation mezonlariga mos keladi [2, bb. 16-17].

Tushuntirish qatlami sifatida SHAP yondashuvi tanlandi. U model chiqargan umumiy feature importance tuzilmasini ham, konkret talabaga tegishli lokal ta’sirlarni ham ko‘rsatishga imkon beradi. Shu bilan birga, Saqr va López-Pernas qayd etganidek, explainability noto‘g‘ri bashoratlarni ham alohida tahlil qilishi kerak; aks holda tizimdan chiqarilgan tavsiyalarni amaliyotga joriy etish ishonchliligi pasayadi.

<b>Loglar</b>	→	<b>Oldindan qayta ishlash</b>	→	<b>Belgi hosil qilish</b>	→	<b>ML modeli</b>	→	<b>SHAP izohi</b>
LMS, baholash, kalendar		tozalash, haftalik agregatsiya		ritm, kechikish, faollik		LR / RF /XGB		global, lokal, xato tahlili

1-rasm. Tushuntiriladigan mashinaviy o‘qitish modeli arxitekturasi

## 2-jadval. Taklif etilayotgan modelning asosiy komponentlari

<b>Komponent</b>	<b>Mazmuni</b>	<b>Amaliy vazifasi</b>
Data ingestion	LMS loglari, assessment yozuvlari, calendar voqealari	Risk signalini erta yig‘ish
Preprocessing	Noise removal, missing handling, weekly aggregation	Barqaror kirish ma’lumotini tayyorlash
Feature engineering	Faollik, ritm, kechikish, davomiylik, diversifikatsiya	Semantik predictorlar yaratish
Prediction layer	LR, RF, XGB	Risk skorini hisoblash
Explainability layer	SHAP global/local izohlar, misprediction tahlili	Qarorni izohlash va tekshirish

Intervention output	Risk darajasi, ogohlantirish va tavsiya	Tyutor yoki o‘qituvchi qarorini qo‘llab- quvvatlash
---------------------	--	---

### Tahlil va natijalar

Adabiyotlar tahlili va modelni loyihalash jarayoni bir nechta muhim texnik natijalarni ko‘rsatdi. Birinchi natija shundan iboratki, erta warning tizimi uchun eng kerakli signal faqat umumiy faollik hajmi emas, balki vaqt bo‘yicha taqsimlangan xatti-harakatning ritmidir. Akçapınar va hammualliflar haftalar kesimida qurilgan modellar muvaffaqiyatsiz talabalarni semestr boshida ham ajrata olishini ko‘rsatgan bo‘lsa [4, b. 1], Yarmatovning ishlari intellektual qaror qabul qilish tizimlarida ma’lumotlarni puxta tayyorlash va bir nechta samarali algoritmlarni ansambl ko‘rinishida sinash bashorat ishonchliligini oshirishini ko‘rsatadi [6, bb. 18-19]. Shundan kelib chiqib, taklif etilayotgan modelda static total counts emas, balki week-over-week trend, activity regularity va deadline deviation asosiy belgilar sifatida tanlandi.

Ikkinchi natija - modelning murakkabligi avtomatik ravishda uning amaliy qiymatini oshirmaydi. Alyahyan va Düştegör feature reduction va model selectionning izohlanuvchanlik bilan birga ko‘rib chiqilishi kerakligini qayd etsa [2, bb. 9-10], Yağcı tomonidan umumlashtirilgan ishlar ham preprocessing hamda belgi tanlash natijaga sezilarli ta’sir qilishini ko‘rsatadi [3, bb. 16-17]. Shu sababli, mazkur modelda logistic regression bazaviy benchmark sifatida saqlanadi: u kam sonli, mazmunli belgilar orqali qaror qabul qilsa, tizim operatori uchun interpretability oshadi va murakkab ansambl modellarining foydasi real ko‘rsatkichlar bilan qiyoslanadi.

Uchinchi natija - tushuntirish qatlami modelning tashqi qo‘shimchasi emas, balki uning ajralmas elementi sifatida ko‘rilishi kerak. Saqr va López-Pernas prediction va misprediction farqini ochmasdan berilgan explainability noto‘liq qolishini ko‘rsatadilar [5, bb. 1-3]. Demak, model faqat “talaba xavf ostida” degan yorliqni emas, balki “qaysi xatti-harakat kombinatsiyasi riskni oshirdi” va “qaysi omillar xavfni pasaytirdi” degan ikki tomonlama izohni qaytarishi kerak. Bu yondashuv amaliy muhitda noto‘g‘ri aralashuvlarni kamaytiradi.

To‘rtinchi natija - data schema masalasi fundamental ahamiyatga ega. OULAD kabi datasetlar kurs, assessment va VLE interaction yozuvlarini bir butun ekotizim

sifatida berishi sababli [1, bb. 1-2], modelni real platformaga joriy etishda ham ma'lumotlar shu mantiqda bog'lanishi kerak: talaba-kurs-hafta formatidagi observation unit predictionning eng maqbul birligi sifatida namoyon bo'ladi. Bunda sessiyaviy granularlikni saqlash, lekin yakuniy modellashtirishni haftalik kesimda olib borish vaqt sezgir prediction va hisoblash samaradorligi o'rtasida muvozanat beradi.

Beshinchi natija - evaluation faqat bir martalik train/test ajratish bilan cheklanmasligi kerak. Erta ogohlantirish tizimlari operatsion tizim sifatida ishlaydi; shuning uchun ular semester drift, cohort drift va instruction driftga sezgir bo'ladi. Adabiyotlarda data preparation, course-level validation va staged prediction bir necha bor urg'u bilan qayd etilgan [2, bb. 16-17; 4, bb. 15-16]. Shu bois taklif etilayotgan model uchun time-sliced validation, rolling-window test va calibration monitoring majburiy diagnostika vositalari sifatida belgilandi.

Mazkur tahlil asosida ishlab chiqilgan model quyidagi amaliy natijani ta'minlashi kutiladi: platformadan kelayotgan log-ma'lumotlardan real vaqtga yaqin rejimda risk signalini ajratish, xavf darajasini skor ko'rinishida qaytarish, o'qituvchi panelida esa global tendensiyalar bilan birga individual izohlarni ham ko'rsatish. Bunday arxitektura bashoratlovchi analitika, explainable AI va early intervention logikasini yagona texnik konturga birlashtiradi.

### **Xulosa va takliflar**

Tadqiqot natijasida ta'lim platformalari log-ma'lumotlari asosida talabalarning o'zlashtirish xavfini erta aniqlash uchun tushuntiriladigan mashinaviy o'qitish modelining konseptual-texnik tuzilmasi ishlab chiqildi. Tahlil shuni ko'rsatdiki, samarali risk prediction uchun loglarning o'zi emas, balki ular asosida hosil qilinadigan vaqtga sezgir, semantik jihatdan mazmunli belgilarning sifati hal qiluvchi omil hisoblanadi. Shuningdek, erta warning tizimi uchun interpretability modeldan keyin qo'shiladigan ikkilamchi modul emas, balki predictionning ishonchliligini ta'minlaydigan asosiy qatlamdir.

Quyidagi tavsiyalar shakllantirildi: birinchidan, kuzatuv birligi sifatida talaba-kurs-hafta ko'rinishidagi formatdan foydalanish maqsadga muvofiq deb topildi; ikkinchidan, feature engineering jarayonida umumiy faollik hajmiga emas, balki

faoliyatning ritmi, muntazamligi, kechikish darajasi hamda uzilish holatlarini ifodalovchi ko'rsatkichlarga ustuvor ahamiyat berish tavsiya etildi; uchinchidan, logistic regression modelini bazaviy benchmark sifatida, XGBoost modelini esa yuqori samaradorlikka ega asosiy model sifatida parallel tarzda baholash zarurligi asoslandi; to'rtinchidan, SHAP asosidagi global va lokal izohlar bilan cheklanib qolmasdan, misprediction holatlarini ham muntazam monitoring qilish lozimligi ko'rsatildi; beshinchidan, modelni sinash jarayonida time-sliced validation yondashuvi va calibration nazoratini joriy etish muhim shart sifatida belgilandi.

Kelgusidagi amaliy tadqiqotlar ushbu modelni real universitet ma'lumotlari asosida empirik sinovdan o'tkazish, threshold qiymatlarini optimallashtirish, uni tavsiya generatori bilan integratsiyalash hamda turli fan va kurs turlarida model barqarorligini baholashga yo'naltirilishi lozim.

### **Foydalanilgan adabiyotlar ro'yxati**

1. Kuzilek, J., Hlosta, M., & Zdrahal, Z. Open University Learning Analytics dataset. *Scientific Data*, 4, Article 170171, bb. 1-8, 2017. <https://doi.org/10.1038/sdata.2017.171>.
2. Alyahyan, E., & Düşteğör, D. Predicting academic success in higher education: literature review and best practices. *International Journal of Educational Technology in Higher Education*, 17(1), bb. 1-21, 2020. <https://doi.org/10.1186/s41239-020-0177-7>.
3. Yağcı, M. Educational data mining: prediction of students' academic performance using machine learning algorithms. *Smart Learning Environments*, 9(11), bb. 1-19, 2022. <https://doi.org/10.1186/s40561-022-00192-z>.
4. Akçapınar, G., Altun, A., & Aşkar, P. Using learning analytics to develop early-warning system for at-risk students. *International Journal of Educational Technology in Higher Education*, 16(40), bb. 1-20, 2019. <https://doi.org/10.1186/s41239-019-0172-z>.

5. Saqr, M., & López-Pernas, S. Why explainable AI may not be enough: predictions and mispredictions in decision making in education. *Smart Learning Environments*, 11(52), bb. 1-14, 2024. <https://doi.org/10.1186/s40561-024-00343-4>.

6. Yarmatov, Sh. Sh. O‘. Ko‘chmas mulkni baholash qarorlarini qabul qilishga ko‘maklashishning intellektual algoritmlari. Texnika fanlari bo‘yicha falsafa doktori (PhD) dissertatsiyasi avtoreferati. Samarqand: Sharof Rashidov nomidagi Samarqand davlat universiteti, bb. 1-45, 2024.

