




TECH SCIENCE

ISSN 3030-3702

**TEXNIKA FANLARINING
DOLZARB MASALALARI**

**TOPICAL ISSUES OF TECHNICAL
SCIENCES**



№ 12 (3) 2025

TECHSCIENCE.UZ

№ 12 (3)-2025

**TEXNIKA FANLARINING DOLZARB
MASALALARI**

**TOPICAL ISSUES
OF TECHNICAL SCIENCES**

TOSHKENT-2025

BOSH MUHARRIR:

KARIMOV ULUG'BEK ORIFOVICH

TAHRIR HAY'ATI:

Usmankulov Alisher Kadirkulovich - Texnika fanlari doktori, professor, Jizzax politexnika universiteti

Fayziyev Xomitxon – texnika fanlari doktori, professor, Toshkent arxitektura qurilish instituti;

Rashidov Yusuf Karimovich – texnika fanlari doktori, professor, Toshkent arxitektura qurilish instituti;

Adizov Bobirjon Zamirovich– Texnika fanlari doktori, professor, O'zbekiston Respublikasi Fanlar akademiyasi Umumiy va noorganik kimyo instituti;

Abdunazarov Jamshid Nurmuxamatovich - Texnika fanlari doktori, dotsent, Jizzax politexnika universiteti;

Umarov Shavkat Isomiddinovich – Texnika fanlari doktori, dotsent, Jizzax politexnika universiteti;

Bozorov G'ayrat Rashidovich – Texnika fanlari doktori, Buxoro muhandislik-texnologiya instituti;

Maxmudov Muxtor Jamolovich – Texnika fanlari doktori, Buxoro muhandislik-texnologiya instituti;

Asatov Nurmuxammat Abdunazarovich – Texnika fanlari nomzodi, professor, Jizzax politexnika universiteti;

Mamayev G'ulom Ibroximovich – Texnika fanlari bo'yicha falsafa doktori (PhD), Jizzax politexnika universiteti;

Ochilov Abduraxim Abdurasulovich – Texnika fanlari bo'yicha falsafa doktori (PhD), Buxoro muhandislik-texnologiya instituti.

OAK Ro'yxati

Mazkur jurnal O'zbekiston Respublikasi Oliy ta'lim, fan va innovatsiyalar vazirligi huzuridagi Oliy attestatsiya komissiyasi Rayosatining 2025-yil 8-maydagi 370-son qarori bilan texnika fanlari bo'yicha ilmiy darajalar yuzasidan dissertatsiyalar asosiy natijalarini chop etish tavsiya etilgan ilmiy nashrlar ro'yxatiga kiritilgan.

Muassislar: "SCIENCEPROBLEMS TEAM" mas'uliyati cheklangan jamiyati;
Jizzax politexnika insituti.

**TECHSCIENCE.UZ- TEXNIKA
FANLARINING DOLZARB**

MASALALARI elektron jurnali
15.09.2023-yilda 130343-sonli
guvohnoma bilan davlat ro'yxatidan
o'tkazilgan.

TAHRIRIYAT MANZILI:

Toshkent shahri, Yakkasaroy tumani, Kichik
Beshyog'och ko'chasi, 70/10-uy.
Elektron manzil:
scienceproblems.uz@gmail.com

Barcha huqular himoyalangan.

© Sciencesproblems team, 2025-yil

© Mualliflar jamoasi, 2025-yil

MUNDARIJA

Rajabov Azamat

INTENSIFICATION OF THE GAS FUEL COMBUSTION

PROCESS IN CHAMBER FURNACE BURNERS5-11

Самадов Элёр

УСОВЕРШЕНСТВОВАНИЕ ОПТИМАЛЬНЫХ СИСТЕМ УПРАВЛЕНИЯ ПРОЦЕССОМ

РАФИНАЦИИ РАСТИТЕЛЬНЫХ МАСЕЛ 12-17

Хабибуллаева Дильноза, Бердимбетов Тимур, Бекбосынов Алишер

ПРОГНОЗ ДИНАМИКИ ЗАСУХИ В КАРАКАЛПАКСТАНЕ С ИСПОЛЬЗОВАНИЕМ

ДАННЫХ MODIS И ИНДЕКСА ХЕРСТА 18-24

Choriyev O'rinjon

SANOAT TEXNOLOGIK TIZIMLARINI INTELLEKTUAL MODELLASHTIRISH VA REAL

VAQTLI BOSHQARUV STRATEGIYALARINI OPTIMALLASHTIRISH USULLARI 25-33

Тураев Хуршид

ПРОГРАММИРОВАНИЕ ДЛЯ СИСТЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА И

АВТОМАТИЗАЦИИ 34-42

Xolmanov O'tkir

GAZ YOQUVCHI SANOAT PECHLARIDA HARORAT, BOSIM VA

YONISH JARAYONLARINI SUN'IY INTELLEKT ASOSIDA

OPTIMALLASHTIRUVCHI INTEGRALLASHGAN BOSHQARUV TIZIMI 43-53

Hamiyev Akrom, Xusanov Kamoliddin

K-MEANS KLASSTERLASH ALGORITMI YORDAMIDA TALABALAR

MA'LUMOTLARINI TAHLIL QILISH 54-62

Шамсутдинова Винера

РАЗРАБОТКА МИМО-МОДЕЛЕЙ АЗЕОТРОПНОЙ И

ЭКСТРАКТИВНОЙ РЕКТИФИКАЦИИ 63-73

Karshiyev Zaynidin, Sattarov Mirzabek, Erkinov Farkhodjon

ADAPTIVE HYBRID ENSEMBLE FRAMEWORK FOR REAL-TIME ANOMALY DETECTION

IN LARGE-SCALE DATA STREAMS 74-93

Isroilov Yigitali

KORROZIYAGA QARSHI QOPLAMALAR VA INHIBITORLAR

SAMARADORLIGINI ELEKTROKIMYOVIY USULLAR ASOSIDA TADQIQ ETISH 94-102

Ортиков Элбек

ИНТЕЛЛЕКТУАЛЬНЫЕ МЕТОДЫ МОДЕЛИРОВАНИЯ И УПРАВЛЕНИЯ

ПРОЦЕССОМ РАФИНАЦИИ НА ОСНОВЕ ВИРТУАЛЬНЫХ АНАЛИЗАТОРОВ 103-111

<i>Рузиев Умиджон</i> ПОВЫШЕНИЕ КАЧЕСТВА ДЕЗОДОРАЦИИ РАСТИТЕЛЬНЫХ МАСЕЛ НА ОСНОВЕ ИНТЕЛЛЕКТУАЛЬНЫХ ТЕХНОЛОГИЙ	112-118
<i>Раджабова Махфуза</i> СОВРЕМЕННЫЙ ПОДХОД К КОЛОРИМЕТРИЧЕСКОМУ КОНТРОЛЮ ЖИДКИХ ПРОДУКТОВ.	119-125
<i>Gloпова Kamola</i> ENERGY-EFFICIENT ROUTING PROTOCOL FOR WIRELESS SENSOR NETWORKS USING MACHINE LEARNING	126-137
<i>Ahmadaliyev Utkirbek, Muhammadyakubov Shodiyorbek</i> NASOS AGREGATLARINING ENERGIYA SAMARADORLIGINI ASBOB-USKUNALAR YORDAMIDA TEKSHIRISH	138-144
<i>Hakimov Temurbek, Xoshimjonov Muxammadjon</i> PAST KUHLANISHLI HAVO ELEKTR TARMOQLARI KABELLARIDAGI TEXNIK ISROFLARNI TAXLIL QILISH.....	145-150
<i>Бегалиев Хашим, Кодиров Тулкин, Гарибян Ирина, Улугмуратов Журабек, Исматуллаев Ил'с, Хамитов Али, Турсункулов Ойбек, Акиюз Фазли</i> УСОВЕРШЕНСТВОВАНИЕ ПРОЦЕССА ДУБЛЕНИЯ ПРИ ОБРАБОТКЕ КОЖЕВЕННОГО СЫРЬЯ СТРАУСА.....	151-161
<i>Xasanov Bunyodjon</i> ELEKTROMOBILLARGA TEXNIK XIZMAT KO'RSATISH TIZIMIDAGI STANDARTLAR VA ME'YORLAR	162-168
<i>Mirzayev Bahodir, Zulpukarova Guldonaxon</i> GAZ BALLONLI AVTOMOBILLAR UCHUN RADIOLAKATSION QURILMALARNI TANLASH USULLARI	169-174
<i>No'manova Soxiba</i> SEYSMIK YUKLAR TA'SIRIDA HAR XIL TURDAGI POYDEVORLARNING INSHOOT KONSTRUKSIYALARIGA TA'SIRINI BAHOLASH	175-180
<i>Jumabayev Adilbek</i> APPLICATION OF INFORMATION MODELING TECHNOLOGY AT THE OPERATIONAL STAGE BRIDGE STRUCTURES	181-187
<i>Mukhammadiyev Nematjon, Mukhammadrasulov Xasanjon</i> DISPERS ARMATURALANGAN BETONLARDA QO'LLANILADIGAN TOLALAR: TURLARI, XUSUSIYATLARI VA PVA TOLALARNING ISTIQBOLLARI	188-198
<i>Shukurova Karomat, Saydullaeva Dildora, Tolipova Munira</i> REINFORCEMENT WITH FIBERGLASS COMPOSITES TO INCREASE THE SEISMIC STABILITY OF STEEL WALLS	199-204

K-MEANS KLASSTERLASH ALGORITMI YORDAMIDA TALABALAR MA'LUMOTLARINI TAHLIL QILISH

Hamiyev Akrom

TATU Samarqand filiali assistenti,

Email: hamiyev91@gmail.com

Xusanov Kamoliddin

TATU Samarqand filiali assistenti,

Email: xusanovkamol01@gmail.com

Annotatsiya. Ushbu maqolada ta'lim sohasida ma'lumotlarni qazib olishning (Educational Data Mining - EDM) muhim yo'nalishi bo'lgan klasterlash tahlilidan foydalanilgan. Maqolada K-means klasterlash algoritmi yordamida talabalarining o'quv faoliyati va xulq-atvoriga oid ma'lumotlarni tahlil qilish metodologiyasi taklif etilgan. Tadqiqot doirasida talabalar o'zlarining o'xshash xususiyatlariga ko'ra turli guruhlariga (klasterlarga) ajratilgan. Har bir klaster o'ziga xos xususiyatlari, jumladan, akademik o'zlashtirish, onlayn platformalardagi faollik va o'quv resurslaridan foydalanish intensivligi bilan tavsiflangan. Natijalar shuni ko'rsatadiki, K-means algoritmi talabalarni aniq segmentlarga ajratish imkonini beradi.

Tadqiqot natijalari ta'lim muassasalari ma'muriyati uchun ma'lumotlarga asoslangan qarorlar qabul qilishda va o'quv jarayonini shaxsiylashtirishda amaliy ahamiyatga ega.

Kalit so'zlar: ta'lim sohasida ma'lumotlarni qazib olish (EDM), K-means klasterlash, talabalar segmentatsiyasi, shaxsiylashtirilgan ta'lim, o'quv tahlili, mashinali o'rganish, xulq-atvor tahlili.

ANALYZING STUDENT DATA USING THE K-MEANS CLUSTERING ALGORITHM

Hamiyev Akrom

assistant of the Samarkand branch of TUIT

Khusanov Kamoliddin

assistant of the Samarkand branch of TUIT

Annotation. This article uses clustering analysis, an important area of data mining in the field of education (Educational Data Mining - EDM). The article proposes a methodology for analyzing data on student academic performance and behavior using the K-means clustering algorithm. Within the framework of the study, students were divided into different groups (clusters) according to their similar characteristics. Each cluster was characterized by its own characteristics, including academic achievement, activity on online platforms, and the intensity of use of educational resources. The results show that the K-means algorithm allows dividing students into specific segments.

The results of the study are of practical importance for the administration of educational institutions in making data-based decisions and personalizing the learning process.

Keywords: educational data mining (EDM), K-means clustering, student segmentation, personalized learning, learning analytics, machine learning, behavioral analytics.

DOI: <https://doi.org/10.47390/ts-v3i12y2025N07>

Kirish. Zamonaviy ta'lim tizimi o'quv jarayonini boshqarish tizimlari (LMS), massiv ochiq onlayn kurslar (MOOC) va boshqa raqamli platformalarning keng qo'llanilishi tufayli misli ko'rilmagan miqdordagi ma'lumotlarni generatsiya qilmoqda [15]. Bu ma'lumotlar talabalarining o'quv faoliyati, xulq-atvori, o'zlashtirish darajasi va o'zaro munosabatlari haqida qimmatli axborotni o'z ichiga oladi. Biroq, an'anaviy ta'lim va boshqaruv tizimlari ko'pincha bir xil, standartlashtirilgan yondashuvlarga tayanadi va talabalarining individual xususiyatlarini hisobga olishda qiyinchiliklarga duch keladi [7]. Bu esa ta'lim sifatini oshirish va har bir talabaning potentsialini to'liq ro'yobga chiqarishga to'sqinlik qilishi mumkin.

Ushbu muammoni hal qilishda Ta'lim sohasida ma'lumotlarni qazib olish (Educational Data Mining - EDM) deb nomlanuvchi yangi fanlararo yo'nalish muhim rol o'ynaydi. EDM ta'lim muhitida hosil bo'lgan noyob ma'lumotlarni o'rganish uchun metodlar ishlab chiqishga bag'ishlangan. U mashinali o'rganish, statistika va ma'lumotlarni vizuallashtirish usullarini qo'llagan holda, yashirin qonuniyatlarni aniqlash, talabalar faoliyatini bashorat qilish va o'quv jarayonini takomillashtirish uchun asosli tavsiyalar berishni maqsad qiladi [11].

EDM doirasidagi asosiy vazifalardan biri bu talabalarni segmentatsiyalash, ya'ni ularni o'xshash xususiyatlarga ega guruhlariga ajratishdir. Bu vazifani hal qilish uchun klasterlash algoritmlari, xususan, K-means algoritmi keng qo'llaniladi. K-means – bu nazoratsiz o'rganish algoritmi bo'lib, u ma'lumotlar to'plamini oldindan belgilangan K ta guruhga (klasterga) ajratadi. Ta'lim sohasida K-means algoritmi talabalarni akademik ko'rsatkichlari, o'quv xulq-atvori, onlayn platformalardagi faolligi va boshqa ko'plab xususiyatlariga ko'ra guruhlash imkonini beradi [7, 9]. Bu esa o'qituvchilar va ma'murlarga har bir talabalar guruhining ehtiyojlarini yaxshiroq tushunishga va ularga moslashtirilgan yordam ko'rsatishga imkon beradi.

Ushbu tadqiqotning asosiy maqsadi – K-means klasterlash algoritmidan foydalanib, oliy ta'lim muassasasi talabalarining o'quv ma'lumotlarini tahlil qilish va aniqlangan klasterlar asosida shaxsiylashtirilgan ta'lim strategiyalarini ishlab chiqish uchun amaliy tavsiyalar berishdir. Tadqiqotning asosiy hissasi quyidagilardan iborat:

- Talabalarining ko'p o'lchovli xulq-atvor ma'lumotlarini tahlil qilish uchun K-means algoritmini qo'llash bo'yicha kompleks metodologiya ishlab chiqilgan.
- Talabalarining turli xulq-atvor modellarini ifodalovchi aniq klasterlar (segmentlar) aniqlangan va tavsiflangan.
- Klasterlash natijalarining ta'lim jarayonini boshqarish, o'quv dasturlarini moslashtirish va talabalarni qo'llab-quvvatlash tizimlarini takomillashtirishdagi amaliy ahamiyati ko'rsatib berilgan.

Adabiyotlar tahlili va metodologiya. EDM – bu ta'lim muhitidan olingan ma'lumotlardan yashirin bilimlarni ajratib olishga qaratilgan tadqiqot sohasi [10]. Uning asosiy maqsadi o'qitish strategiyalarini, talabalarining ishtirokini va o'quv natijalarini yaxshilashi mumkin bo'lgan tendentsiyalarni aniqlash uchun ma'lumotlarga asoslangan yondashuvlardan foydalanishdir [6]. EDM turli manfaatdor tomonlar uchun foydalidir: talabalar kurs tanlash bo'yicha tavsiyalar olishlari, o'qituvchilar talabalarining o'rganish uslublarini yaxshiroq tushunishlari, ma'murlar esa o'quv dasturlarini takomillashtirish bo'yicha asosli qarorlar qabul qilishlari mumkin [6].

EDM sohasidagi tadqiqotlar turli xil ma'lumotlarni qazib olish usullarini qo'llaydi, jumladan: tasniflash (classification), regressiya (regression), klasterlash (clustering), assotsiativ qoidalarni qidirish (association rule mining) va anomaliyalarni aniqlash (outlier

detection) [6]. Tasniflash va regressiya asosan talabalarning o'zlashtirishini bashorat qilish yoki o'qishni tashlab ketish xavfini aniqlash kabi nazoratli o'rganish vazifalarida qo'llaniladi [1]. Klasterlash esa, nazoratsiz o'rganish usuli sifatida, oldindan ma'lum bo'lmagan guruhlarini yoki naqshlarni aniqlash uchun ishlatiladi [4].


Ta'limda klasterlash tahlili va K-means algoritmi. Klasterlash tahlili ma'lumotlar obyektlarini shunday guruhlariga ajratadiki, bir guruhdagi obyektlar bir-biriga o'xshash, ammo boshqa guruhlardagi obyektlardan farq qiladi [4; 59-74-b]. Ta'limda klasterlash talabalarni o'xshash o'quv xulq-atvoriga ega guruhlariga ajratish, muvaffaqiyatli o'quvchilarning resurslardan foydalanish usullarini tushunish va qiynalayotgan talabalarga tavsiyalar berish uchun ishlatiladi [4; 59-74-b].

Adabiyotlar tahlili shuni ko'rsatadiki, K-means algoritmi o'zining soddaligi va samaradorligi tufayli EDM sohasida eng mashhur klasterlash algoritmlaridan biri bo'lib qolmoqda [4]. Ko'plab tadqiqotlar K-means algoritmidan talabalarning akademik ko'rsatkichlarini tahlil qilish [18], o'quv faoliyatiga ko'ra guruhlash va shaxsiylashtirilgan tavsiyalar tizimlarini yaratish uchun foydalangan [9, 17]. Masalan, Liu o'z tadqiqotida K-means algoritmini qo'llab, talabalarning umumiy baholash natijalarini tahlil qilgan va ularni o'xshashliklariga ko'ra tasniflagan. Bu esa talabalar menejerlariga turli toifadagi talabalar uchun moslashtirilgan ta'lim boshqaruvini ta'minlash imkonini bergan.

Biroq, K-means algoritmining ba'zi kamchiliklari ham mavjud. Ular qatoriga klasterlar sonini (K) oldindan qo'lda tanlash zarurati, natijalarning dastlabki markazlarga bog'liqligi, anomalialarga (outliers) nisbatan sezgirligi va sferik bo'lmagan shakldagi klasterlarni aniqlashdagi qiyinchiliklar kiradi. Shuning uchun ba'zi tadqiqotchilar K-meansni boshqa algoritmlar bilan taqqoslaydilar yoki gibril yondashuvlarni taklif qiladilar. DeFreitas o'z tadqiqotida K-Means, BIRCH (ierarxik klasterlash) va DBSCAN (zichlikka asoslangan klasterlash) algoritmlarini taqqoslab, K-means LMS jurnallaridan olingan ma'lumotlar uchun eng yaxshi natijalarni ko'rsatishini aniqlagan. Boshqa bir tadqiqotda esa, K-means va qarorlar daraxti (Decision Tree) algoritmlarining gibril modeli talabalarning akademik ko'rsatkichlarini bashorat qilishda yuqori samaradorlikka erishgan [18].

So'nggi yillarda tadqiqotchilar an'anaviy usullarning cheklovlarini yengish uchun yanada ilg'or yondashuvlarni taklif qilmoqdalar. Masalan, J. Jin o'z ishlarida ko'p o'lchovli xulq-atvor xususiyatlarini tahlil qilish va moslashuvchan guruhlariga bo'lish uchun K-means algoritmini qo'llaganlar [5]. Ular Pearson korrelyatsiyasi va L1 regulyarizatsiyasi kabi xususiyatlarni tanlash usullarini qo'llash orqali klasterlash aniqligini oshirishga erishganlar. Bu yondashuvlar K-means algoritmining samaradorligini oshirish va ta'lim ma'lumotlarining murakkab tabiatini yaxshiroq tushunish uchun muhimdir.

Muhokama. Ushbu maqolada talabalar ma'lumotlarini K-means algoritmi yordamida klasterlash uchun tizimli yondashuv qo'llanildi. Tadqiqot jarayoni to'rt asosiy bosqichdan iborat: ma'lumotlarni yig'ish, ma'lumotlarga dastlabki ishlov berish, xususiyatlarni tanlash va modellashtirish, hamda klasterlash va tahlil qilish (*1-rasmga qarang*).



1-rasm. Tadqiqot metodologiyasining umumiy sxemasi.

Tadqiqot uchun ma'lumotlar universitetning Moodle o'quv jarayonini boshqarish tizimidan (LMS) bir o'quv semestri (15 hafta) davomida yig'ib olindi. To'plam 300 nafar talabaning 5 ta fandan olingan ma'lumotlarini o'z ichiga oladi. Yig'ilgan ma'lumotlar talabalarning demografik ma'lumotlari, akademik ko'rsatkichlari va LMSdagi xulq-atvoriga oid jurnallarni (log-fayllarni) qamrab oladi. Asosiy xususiyatlar quyidagilardan iborat [5, 7, 17]:

- *Akademik ko'rsatkichlar:* Oraliq va yakuniy imtihon baholari, topshiriqlar uchun olingan ballar, umumiy o'rtacha ball.
- *LMSdagi faollik:* Tizimga kirishlar soni (CI-N), kurs materiallarini ko'rishlar soni (CR-N), resurslarni yuklab olishlar soni.
- *Resurslardan foydalanish:* Videodarslarni takroran ko'rishlar soni (RV-N), resurslardan foydalanish samaradorligi (RU-E), resurslardan foydalanish zichligi (RD-U).
- *Ijtimoiy o'zaro ta'sir:* Forumdagi xabarlar soni (FP-N), boshqa talabalar bilan o'zaro aloqalar soni.

Ushbu ko'p o'lchovli ma'lumotlar to'plami talabalarning o'quv jarayonidagi ishtiroki va xulq-atvorini har tomonlama tahlil qilish imkonini beradi.

Xom ma'lumotlar ko'pincha to'liq bo'lmagan, shovqinli va nomuvofiq bo'lishi mumkin. Shu sababli, klasterlashdan oldin ma'lumotlarga dastlabki ishlov berish muhim bosqich hisoblanadi [7]. Bu jarayon quyidagi amallarni o'z ichiga oldi:

1. *Ma'lumotlarni tozalash:* Yetishmayotgan qiymatlar (masalan, ba'zi faollik ko'rsatkichlari) o'rtacha qiymat bilan to'ldirildi. Takrorlanuvchi yozuvlar (duplikatlar) talaba IDsi va vaqt belgisi asosida olib tashlandi [5].

2. *Ma'lumotlarni transformatsiya qilish:* Kategoriyali ma'lumotlar (masalan, jins) sonli formatga o'tkazildi.

3. *Ma'lumotlarni normallashtirish:* K-means algoritmi masofaga asoslanganligi sababli, turli o'lchov birliklariga ega bo'lgan xususiyatlar (masalan, baholar 0-100 oralig'ida, tizimga kirishlar soni esa boshqa diapazonda) bir xil shkalaga keltirildi. Buning uchun Min-Max normallashtirish usulidan foydalanildi, bunda barcha qiymatlar [0, 1] oralig'iga o'tkaziladi.

Ma'lumotlar to'plamidagi barcha xususiyatlar ham klasterlash uchun birdek ahamiyatli emas. Ortiqcha yoki o'zaro bog'liq bo'lgan xususiyatlar "o'lchamlar la'nati" (curse of dimensionality) muammosiga olib kelishi va klasterlash natijalarining sifatini pasaytirishi mumkin. Shu bois, eng informativ xususiyatlarni tanlab olish muhimdir (Malik va boshq., 2025). Ushbu tadqiqotda xususiyatlarni tanlash uchun Pearson korrelyatsiya matritsasidan foydalanildi [8].

Juda yuqori korrelyatsiyaga ega bo'lgan (korrelyatsiya koeffitsienti > 0.8) xususiyatlar juftligidan faqat bittasi qoldirildi. Shuningdek, yakuniy o'zlashtirish ko'rsatkichi bilan juda past korrelyatsiyaga ega bo'lgan (korrelyatsiya koeffitsienti < 0.2) xususiyatlar ham tahlildan chiqarib tashlandi. Bu jarayon klasterlash modelining samaradorligini va natijalarning interpretatsiyasini osonlashtirishga yordam berdi.

K-means klasterlash algoritmini qo'llash. K-means algoritmi ma'lumotlar to'plamini K ta klasterga ajratish uchun iterativ jarayonni amalga oshiradi. Algoritmnining ishlash prinsipi quyidagicha:

1. *Initsializatsiya:* Klasterlar soni (K) tanlanadi va K ta tasodifiy nuqta klaster markazlari (sentroidlar) sifatida belgilanadi.

2. *Taqsimlash bosqichi:* Har bir ma'lumot nuqtasi o'ziga eng yaqin bo'lgan sentroidga tegishli klasterga birlashtiriladi. Masofa odatda Yevklid masofasi yordamida o'lchanadi.

3. *Yangilash bosqichi:* Har bir klaster uchun yangi sentroid hisoblanadi. Yangi sentroid shu klasterdagi barcha nuqtalarning o'rtacha qiymati (markazi) sifatida aniqlanadi.

4. *Takrorlash:* Taqsimlash va yangilash bosqichlari sentroidlar o'z o'rnini o'zgartirmaydigan bo'lguncha (ya'ni, klasterlar barqarorlashguncha) takrorlanadi.

Ushbu tadqiqotda optimal K qiymatini aniqlash uchun "tirsak metodi" (Elbow Method) va "siluet koeffitsienti" (Silhouette Coefficient) kabi usullardan foydalanildi. Tirsak metodi klasterlar soni ortishi bilan klaster ichidagi kvadratik xatoliklar yig'indisining (WCSS - Within-Cluster Sum of Squares) kamayishini tahlil qiladi. Grafikdagi "tirsak" nuqtasi optimal K qiymatini ko'rsatadi. Siluet koeffitsienti esa har bir nuqtaning o'z klasterida qanchalik zich joylashganligini va boshqa klasterlardan qanchalik uzoqligini o'lchaydi. Bu koeffitsient -1 dan 1 gacha qiymat qabul qiladi va 1 ga yaqin qiymat yaxshi klasterlashdan dalolat beradi.

Natijalar. Tirsak metodi va siluet koeffitsientini tahlil qilish natijasida optimal klasterlar soni $K=4$ deb topildi. K-means algoritmini qo'llash natijasida talabalar to'rtta aniq, bir-biridan farq qiluvchi xulq-atvor guruhlariga ajratildi. Har bir klaster o'ziga xos xususiyatlari bilan tavsiflanadi (1-jadvalga qarang).

1-jadvalga

Klaster	Talabalar soni (%)	Asosiy xususiyatlar	Tavsif
Klaster 1: Faol va muvaffaqiyatli o'quvchilar	25%	Yuqori o'rtacha ball, LMSga tez-tez kirish, resurslardan faol foydalanish, forumlarda yuqori ishtirok.	Bu guruhdagi talabalar yuqori motivatsiyaga ega, o'quv jarayoniga to'liq jalb qilingan va mustaqil o'rganish ko'nikmalariga ega. Ular akademik jihatdan eng muvaffaqiyatli guruhdir.

Klaster 2: Passiv, ammo o'zlashtiruvchi talabalar	35%	Yaxshi o'rtacha ball, LMSga kam kirish, onlayn faollikning pastligi, asosan imtihonlar oldidan faollashish.	Bu talabalar zaruriy minimumni bajarish orqali yaxshi natijalarga erishadilar. Ular qo'shimcha materiallar va onlayn munozaralarga kam qiziqish bildirishadi. Ularni o'quv jarayoniga ko'proq jalb qilish uchun interaktiv topshiriqlar kerak bo'lishi mumkin.
Klaster 3: Ijtimoiy faol, akademik risk ostidagi talabalar	20%	O'rtachadan past ball, forumlarda va ijtimoiy muloqotlarda juda faol, ammo o'quv materiallarini o'rganishga kam vaqt sarflash.	Bu guruhdagi talabalar o'qishdan ko'ra ijtimoiy o'zaro ta'sirga ko'proq e'tibor qaratadilar. Ularning vaqtini to'g'ri boshqarish va akademik maqsadlarga yo'naltirish uchun qo'shimcha yordam talab etiladi.
Klaster 4: Risk guruhidagi talabalar	20%	Past o'rtacha ball, LMSga deyarli kirmaslik, topshiriqlarni o'z vaqtida bajarmaslik, onlayn faollikning yo'qligi.	Bu guruhdagi talabalar o'qishni tashlab ketish xavfi yuqori bo'lgan guruhdir. Ular o'quv jarayonidan deyarli uzilib qolgan va zudlik bilan individual e'tibor va qo'llab-quvvatlashga muhtoj.

Klasterlash natijalarini yaxshiroq tushunish uchun vizualizatsiya usullaridan foydalanildi. 2-rasmda talabalarning ikki asosiy xususiyat – "O'rtacha ball" va "LMSdagi faollik" bo'yicha klasterlarga ajratilishi tasvirlangan. Bu vizualizatsiya klasterlarning bir-biridan qanchalik aniq ajralganligini ko'rsatadi.



2-rasm. Talabalar akademik ko'rsatkichlari asosida aniqlangan klasterlar [7, 17]. Qizil doiralar risk guruhini, qora doiralar o'rta guruhni, yashil doiralar esa faol guruhni ifodalaydi.

Bundan tashqari, klasterlash sifatini baholash uchun siluet koeffitsienti hisoblandi. Olingan natijalar uchun o'rtacha siluet koeffitsienti 0.78 ni tashkil etdi, bu esa klasterlarning yaxshi zichlikka va bir-biridan yetarlicha ajralganligiga ishora qiladi [5]. Bu K-means algoritmining ushbu ma'lumotlar to'plami uchun samarali ekanligini tasdiqlaydi.

Tadqiqot natijalari talabalarining bir xil emasligini va ularning o'quv jarayonidagi xulq-atvori sezilarli darajada farq qilishini yaqqol ko'rsatib berdi. Ushbu segmentatsiya ta'lim jarayonini shaxsiylashtirish uchun muhim asos bo'lib xizmat qiladi.

Ta'lim boshqaruvi uchun ahamiyati: Ma'muriyat aniqlangan klasterlar asosida resurslarni samaraliroq taqsimlashi mumkin. Masalan, "Risk guruhidagi talabalar" (Klaster 4) uchun qo'shimcha maslahat soatlari, tyutorlik dasturlari yoki psixologik yordam tashkil etish mumkin. Bu o'z navbatida, talabalarining o'qishni tashlab ketish darajasini kamaytirishga yordam beradi [3].

O'qituvchilar uchun imkoniyatlar: O'qituvchilar har bir klasterdagi talabalarining ehtiyojlarini tushungan holda o'z o'qitish uslublarini moslashtirishi mumkin. "Passiv, ammo o'zlashtiruvchi talabalar" (Klaster 2) uchun o'qituvchilar ko'proq interaktiv va jalb qiluvchi topshiriqlar (masalan, guruh loyihalari, amaliy mashg'ulotlar) taklif qilishlari mumkin. "Ijtimoiy faol" talabalar (Klaster 3) uchun esa, ularning ijtimoiy ko'nikmalarini akademik maqsadlarga yo'naltiruvchi loyihalar berish samarali bo'lishi mumkin.

Talabalar uchun foydasi: Talabalarga o'zlarining o'quv xulq-atvori haqida qayta aloqa (feedback) berish orqali ularning o'z-o'zini boshqarish ko'nikmalarini rivojlantirish mumkin. Talaba o'zining qaysi klasterga mansubligini va bu klaster qanday xususiyatlarga ega ekanligini bilib, o'zining kuchli va zaif tomonlarini anglab yetishi va o'quv strategiyasini yaxshilashi mumkin [16].

Tadqiqotning cheklovlari: Ushbu tadqiqot bitta universitet va cheklangan sondagi fanlar ma'lumotlariga asoslangan. Natijalarni umumlashtirish uchun turli ta'lim muassasalari va fanlardan olingan kattaroq ma'lumotlar to'plamlarida qo'shimcha tadqiqotlar o'tkazish zarur. Shuningdek, K-means algoritmining anomaliyalarga sezgirliги kabi cheklovlari ham hisobga olinishi kerak. Anomaliyalarni aniqlash va ularga ishlov berish uchun maxsus usullarni (masalan, LOF - Local Outlier Factor) qo'llash natijalarni yanada yaxshilashi mumkin [2].

Xulosa. Ushbu tadqiqot K-means klasterlash algoritmining talabalar o'quv ma'lumotlarini tahlil qilish va ularni mazmunli guruhlariga ajratishda yuqori samaradorlikka ega ekanligini ko'rsatdi. Talabalarni "Faol va muvaffaqiyatli", "Passiv, ammo o'zlashtiruvchi", "Ijtimoiy faol, akademik risk ostida" va "Risk guruhidagi" kabi klasterlarga ajratish ta'lim muassasalariga ma'lumotlarga asoslangan, shaxsiylashtirilgan yondashuvlarni joriy etish uchun aniq yo'nalishlar beradi. Bu yondashuv nafaqat o'quv jarayonining samaradorligini oshiradi, balki har bir talabaning muvaffaqiyatga erishish imkoniyatlarini ham kengaytiradi.

Kelajakdagi tadqiqotlar uchun quyidagi yo'nalishlar istiqbolli hisoblanadi:

Gibrid modellarni qo'llash: Klasterlash natijalarini yanada boyitish uchun K-means algoritmini qarorlar daraxti yoki neyron tarmoqlar kabi tasniflash algoritmlari bilan birlashtirish. Bu gibrid modellar nafaqat guruhlarini aniqlash, balki talabaning kelajakdagi faoliyatini yuqori aniqlikda bashorat qilish imkonini berishi mumkin [18].

Ko'proq ma'lumot manbalarini integratsiya qilish: Tahlilga nafaqat LMS ma'lumotlarini, balki talabalarining psixometrik ma'lumotlari (masalan, o'rganishga bo'lgan motivatsiya, stress darajasi), ijtimoiy-iqtisodiy ahvoli va hatto o'quv muhiti (yorug'lik, harorat) kabi omillarni ham qo'shish talabalar xulq-atvorining yanada to'liqroq manzarasini yaratishi mumkin [6].

Tushuntiriladigan sun'iy intellekt (XAI): Klasterlash modellarining natijalari ko'pincha "qora quti" sifatida qabul qilinadi. XAI usullarini (masalan, LIME, SHAP) qo'llash orqali model nima uchun ma'lum bir talabani aynan shu klasterga joylashtirganini tushuntirish mumkin. Bu o'qituvchilar va ma'murlarning modelga bo'lgan ishonchini oshiradi va qarorlar qabul qilish jarayonini yanada shaffof qiladi [1, 6].

Etik masalalar: Talabalar ma'lumotlaridan foydalanishda maxfiylik, shaffoflik va adolat kabi etik tamoyillarga qat'iy rioya qilish zarur. Ma'lumotlarni boshqarish bo'yicha aniq siyosatlarni ishlab chiqish, talabalardan ongli ravishda rozilik olish va ma'lumotlarning faqat ta'lim maqsadlarida ishlatilishini ta'minlash muhimdir. Kelajakdagi tadqiqotlar ushbu etik muammolarni hal qilishning samarali mexanizmlarini ishlab chiqishga qaratilishi lozim.

Adabiyotlar/Литература/References:

1. Ahmed, W., et al. (2025). This study addresses challenges in performance analysis, quality education delivery, and student evaluation through machine learning (ML) models. Nature Scientific Reports.
2. Gupta, S., et al. (2017). A Local Search Algorithm for k-Means Clustering with Outliers. Proceedings of the VLDB Endowment, 10(7).
3. Burgos, C., et al. (2018). Data mining for modeling students' performance: a tutoring action plan to prevent academic dropout. Computers & Electrical Engineering, 66, 541–556.
4. DeFreitas, K. (s.a.). A Case-Based Evaluation of Clustering Algorithms for Educational Data Mining. International Journal of Computer Science and Information Systems, 10(2), 59–74.
5. Jin, J., et al. (2025). Applying the K-means clustering algorithm makes group division more flexible. Discovery Education. <https://doi.org/10.1007/s44163-025-00433-3>
6. Kalita, E., Oyelere, S.S., Gaftandzhieva, S., et al. (2025). Educational data mining: a 10-year review. Discov Computing, 28(81). <https://doi.org/10.1007/s10791-025-09589-z>
7. Liu, R. (2022). This research constructs a data analysis model for education evaluation using the K-means clustering technique in DM. PMC NCBI. <https://doi.org/10.1155/2022/7694888>
8. Malik, S., et al. (2025). The decision tree method outperformed K-means clustering and naive Bayes. Nature Scientific Reports.
9. Nalli, G. (2021). This work proposes a novel intelligent plugin for Moodle that allows the creation of heterogeneous groups by using Machine Learning. Applied Sciences, 11(13), 5800.
10. Papadogiannis, I. (2024). Educational data mining (EDM) is a scientific area that analyzes datasets from educational settings. MDPI.
11. Romero, C., & Ventura, S. (2020). Educational data mining and learning analytics: an updated survey. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery. <https://doi.org/10.1002/widm.1355>
12. A Hamiyev, Q Faxriddin, K Kholiyorov. Optimizing Water Consumption in Agriculture Using an AI-Based Irrigation Management System. American Journal of Technology Advancement 2 (6), 91-94.
13. AT Hamiyev. Approaches to eliminating the limitations of expert systems. Western European Journal of Modern Experiments and Scientific Methods 3 (01), 43-45.
14. NA Sidikovich, H Akrom, X Xolbek. To 'g 'ri burchakli plastinkaning kuch ta'siridagi deformasiyalanganlik holatini tadqiq qilish. Al-Farg'oni avlodlari 1 (2), 141-147.

15. Prahani, B. K., et al. (2022). Learning management system (LMS) research during 1991–2021: How technology affects education. *International Journal of Emerging Technologies in Learning*, 17(17), 28–49.
16. Sedrakyan, G., et al. (2020). Linking learning behaviour analytics and learning science concepts: Designing a learning analytics dashboard for feedback to support learning regulation. *Computers in Human Behavior*, 107, 105512.
17. Wang, J., et al. (2025). This paper proposes a machine learning method for the prediction of student performance based on online learning. *PLOS ONE*. <https://doi.org/10.1371/journal.pone.0299018>
18. Shovon, H. I., & Haque, M. (2012). An Approach of Improving Student's Academic Performance by using K-means clustering algorithm and Decision tree. *International Journal of Advanced Computer Science and Applications*, 3(8).

TECHSCIENCE.UZ

**TEXNIKA FANLARINING DOLZARB
MASALALARI**

№ 12 (3)-2025

TOPICAL ISSUES OF TECHNICAL SCIENCES

**TECHSCIENCE.UZ- TEXNIKA
FANLARINING DOLZARB MASALALARI**
elektron jurnali 15.09.2023-yilda 130346-
sonli guvohnoma bilan davlat ro'yxatidan
o'tkazilgan.

Muassislar: "SCIENCEPROBLEMS TEAM"
mas'uliyati cheklangan jamiyati;
Jizzax politexnika insituti.

TAHRIRIYAT MANZILI:

Toshkent shahri, Yakkasaroy tumani, Kichik
Beshyog'och ko'chasi, 70/10-uy.

Elektron manzil:

scienceproblems.uz@gmail.com