

Oliy Ta'lim Muassasalarida O'Quv Yuklamasini Boshqarish Va Optimallashtirish Uchun Mashinali O'Rganish Modellarini Qo'llash

Qadamov Boburjon Quvondiq o'g'li¹

Abstract: Ushbu tadqiqot O'zbekistondagi oliy ta'lim muassasalarida o'quv yuklamasini boshqarish va optimallashtirishga qaratilgan bo'lib, yuklamani teng taqsimlash va samarali tashkil etish uchun mashinali o'rganish modellarini qo'llashning usullari va afzalliklarini tahlil qiladi. Ushbu ishda regressiya, tasniflash va klasterlash modellari orqali yuklamani prognozlash va boshqarish imkoniyatlari o'rganilgan. Tadqiqot natijalari yuklama taqsimotini yaxshilash va o'qituvchilarning samaradorligini oshirish uchun muhim ko'rsatkichlarni aniqlashga yordam beradi.

Kalit so'zlar: O'qituvchi yuklamasi, oliy ta'lim, mashinali o'rganish, regressiya, tasniflash, klasterlash.

I. Introduction

O'zbekistondagi oliy ta'lim muassasalarida o'quv yuklamasini boshqarish dolzarb masalalardan biri hisoblanadi. O'qituvchilar va professorlar uchun yuklama darajasining teng taqsimlanishi nafaqat ularning samaradorligini oshiradi, balki ta'lim sifatiga ham sezilarli ta'sir ko'rsatadi. O'quv yuklamasi muammosi bilan bog'liq asosiy qiyinchiliklardan biri — talabalarga ajratilgan vaqtni maksimal darajada samarali tashkil etish, dars yuklamasi haddan tashqari yuqori yoki past bo'lmashligini ta'minlashdir.

Odatda, o'qituvchilarga yuklamalar ma'lum yillik reja asosida qo'l bilan taqsimlanadi, bu esa ortiqcha vaqt va resurs talab qiladi. Shuningdek, ba'zida adolatsizlik yoki noto'g'ri taqsimlanish natijasida ayrim o'qituvchilar yuklamasi og'irlashib ketishi, boshqalari esa past yuklama bilan qolishi mumkin. Ushbu vaziyatlarni yengillashtirish uchun so'nggi yillarda mashinali o'rganish modellari, jumladan, regressiya, tasniflash va klasterlash algoritmlaridan foydalanish usullari keng qo'llanilmoqda.

Mazkur tadqiqotda oliy ta'lim muassasalarida o'quv yuklamasini samarali boshqarish uchun mashinali o'rganish modellari orqali yuklamani bashorat qilish, adolatli taqsimlash va optimallashtirish usullari o'rganiladi. Tadqiqotning asosiy maqsadi — yuklamani teng taqsimlash va boshqarish orqali o'qituvchilar samaradorligini oshirishga qaratilgan. Shu bois, O'zbekiston sharoitiga mos keladigan mashinali o'rganish modellarini tanlash va ularni o'quv yuklamasiga tatbiq etish imkoniyatlarini aniqlash ushbu ishning ustuvor vazifalaridandir.

Tadqiqot davomida quyidagi savollarni o'rganamiz:

O'quv yuklamasini boshqarish uchun qaysi mashinali o'rganish modellaridan samarali foydalanish mumkin?

Turli modellar asosida yuklamani qanday bashorat qilish mumkin?

O'quv yuklamasini teng taqsimlash uchun modellarni qanday sozlash va baholash mumkin?

Shu kabi yondashuvlar oliy ta'lim muassasalarida o'quv yuklamasini boshqarishni yanada avtomatlashtirish va samarali tashkil qilishga xizmat qiladi.

¹ Urgench State University, Department of Computer Sciences



II. Literature Review

O'quv yuklamasini boshqarish bo'yicha ilgari olib borilgan tadqiqotlar mashinali o'rganish usullari yordamida yuklama taqsimoti va prognozlashda ijobiy natijalar berganini ko'rsatadi. Bir qancha mamlakatlarda ta'lim jarayonini optimallashtirish maqsadida regressiya, tasniflash, va klasterlash modellaridan foydalanilgan. Bu bo'limda o'quv yuklamasini boshqarish uchun ishlatilgan asosiy yondashuvlar va modellar ko'rib chiqiladi.

1. Regressiya modellari

Regressiya modellari ta'lim yuklamasini bashorat qilishda samarali usul bo'lib, u turli faktorlarni inobatga olib, kelajakdagi yuklamalarni prognozlash imkonini beradi. Oddiy chiziqli regressiya modeli dars soatlari, talabalar soni, va o'qituvchilarning tajribasi kabi omillarni hisobga olib, har bir o'qituvchi uchun yuklamani taxminlashda qo'llanilgan. Ko'p omilli regressiya esa bir nechta o'zgaruvchilarning ta'sirini tahlil qilish imkonini beradi, bu esa murakkab va katta hajmdagi ta'lim ma'lumotlari bilan ishlashda samaradorlikni oshiradi.

2. Tasniflash modellari

O'qituvchilarni yuklama darajasiga qarab tasniflash ham muhim amaliyotlardan biri hisoblanadi. Ilg'or tadqiqotlar shuni ko'rsatadiki, **K yaqin qo'shnilar (KNN)** va **logistik regressiya** modellaridan foydalanib, o'qituvchilarni yuqori, o'rtacha, va past yuklama darajalariga ajratish mumkin. KNN modeli, ayniqsa, o'qituvchilar yuklamasi hajmi va o'qituvchilar tajribasi bo'yicha tasniflashda yaxshi natija beradi, chunki u yaqin qo'shnilarni aniqlash orqali tasniflashni amalga oshiradi. Logistik regressiya esa o'qituvchilarni yuqori yoki past yuklama kategoriyalariga ajratishda samarali.

3. Klasterlash modellari

Klasterlash usullari yordamida o'qituvchilar va talabalarni guruhlariga ajratish o'quv yuklamasini boshqarishda samaradorlikni oshiradi. **K-means** va **gavdaviy klasterlash** usullari ko'p hollarda ta'lim tizimlarida ishlatiladi. K-means yordamida o'qituvchilar o'quv yuklamasi va tajribasiga qarab guruhlariga bo'linadi, bu esa yuklamani teng taqsimlash imkonini beradi. Gavdaviy klasterlash usuli esa hierarchik tuzilmani tashkil etib, ta'lim jarayonini o'qituvchilarning o'zaro bog'liq guruhlariga bo'linishini ta'minlaydi.

4. Natijalar va afzalliklar

O'tkazilgan tadqiqotlar mashinali o'rganish modellarining ta'limda yuklamani boshqarishda samaradorligini isbotladi. Avvalgi tajribalar asosida klasterlash va regressiya usullari yuklama taqsimotini yaxshilash, tasniflash modellari esa o'qituvchilarning yuklamasini me'yoriy darajada boshqarish imkoniyatini beradi. Ushbu yondashuvlar yuklama taqsimotini yanada adolatli qilib, o'qituvchilarning o'qitish jarayoniga ajratadigan vaqtlarini optimallashtirishga yordam beradi.

Ushbu adabiyot tahlili natijalariga asoslanib, O'zbekiston oliy ta'lim muassasalarida o'quv yuklamasini boshqarish uchun ushbu modellarni tatbiq etish maqsadga muvofiq ekanligi tushunildi.

III. Methodology

Ushbu tadqiqot O'zbekistondagi oliy ta'lim muassasalarida o'qituvchilar uchun o'quv yuklamasini boshqarish va optimallashtirishga qaratilgan bo'lib, turli mashinali o'rganish modellarini qo'llash orqali yuklama taqsimotini adolatli va samarali tashkil etishga yordam beradi. Bu bo'limda tadqiqot metodikasini batafsil bayon etamiz: ma'lumotlarni yig'ish va tayyorlash, mashinali o'rganish modellarini tanlash va ularni baholash jarayonlari.

1. Ma'lumotlarni yig'ish va tayyorlash

O'quv yuklamasini boshqarish uchun talab qilinadigan asosiy ma'lumotlar quyidagilardan iborat:

O'qituvchilarning tajribasi: yillik tajribasi, ilmiy darajasi va mutaxassisligi.

Dars soatlari va yuklama: haftalik va semestrlik yuklama soatlari.



Talabalar soni: har bir guruhdagi talabalar soni va ularning ta'lim yo'nalishi.

Kafedra va fakultet ma'lumotlari: o'qituvchilarning ish joylari va kafedra yuklamalari.

Ushbu ma'lumotlar O'zbekiston oliy ta'lim muassasalaridagi professor-o'qituvchilar uchun yig'ilib, tozalash va tayyorlash jarayonidan o'tkazildi. Ma'lumotlar tahlili uchun Python dasturlash tilidagi *Pandas* va *NumPy* kabi kutubxonalaridan foydalanildi. Ma'lumotlarni normallashtirish va o'zgaruvchilarning bir xil shkalada bo'lishini ta'minlash uchun **min-max skalalash** texnikasidan foydalanildi.

2. Model tanlash va o'qitish

O'quv yuklamasini boshqarish uchun tanlangan mashinali o'rganish modellarining qisqacha tavsifi quyidagicha:

a) Chiziqli regressiya

Chiziqli regressiya modeli yuklama prognozlash uchun tanlangan asosiy model hisoblanadi. Bu model yordamida dars yuklamasini bashorat qilish imkoniyati mavjud. Chiziqli regressiya yondashuvi o'qituvchilarning yuklamalarini haftalik va o'quv yilidagi o'zgaruvchilar asosida hisoblab chiqishga imkon beradi.

b) Ko'p omilli regressiya

Ko'p omilli regressiya yondashuvi yuklama prognozlashda bir nechta omillarni hisobga olish imkoniyatini beradi. Bu yondashuv yordamida o'qituvchilarning tajribasi, dars soatlari va guruhdagi talabalar soni kabi omillar birgalikda o'rganilib, natijalar aniqligi oshiriladi.

c) K yaqin qo'shnilar (KNN)

K yaqin qo'shnilar (KNN) modeli o'qituvchilarni yuqori, o'rta va past yuklama darajalariga tasniflashda qo'llaniladi. KNN modeli o'qituvchilarning yuklamasini aniqlashda yaqin qo'shnilarga asoslanib, ma'lumotlarni tasniflaydi. Bu model yordamida yuklamani teng taqsimlash va yuqori yuklamalarni aniqlash osonlashadi.

d) K-means Klasterlash

K-means klasterlash o'qituvchilarni yuklama darajasi va tajriba bo'yicha guruhlariga ajratish uchun ishlatiladi. Bu yondashuv yordamida o'qituvchilarni ma'lum bir klasterlarga bo'lish, har bir klaster uchun o'rtacha yuklama aniqlash va yuklamani teng taqsimlash imkoniyati mavjud.

3. Modelni baholash

Tadqiqotda qo'llanilgan modellarning samaradorligini baholash uchun turli metrikalardan foydalanildi:

Chiziqli va ko'p omilli regressiya uchun: **MSE (Mean Squared Error)** va **R²** ko'rsatkichlari orqali bashorat aniqligi baholandi.

KNN va K-means uchun: yuklamaning tasniflash aniqligi va klasterlash samaradorligini baholash uchun **aniqlik** va **siluet skori** kabi metrikalardan foydalanildi.

Model turi	Metrika	Natija
Chiziqli regressiya	MSE	15.3
	R ²	0.85
Ko'p omilli regressiya	MSE	12.5
	R ²	0.88
K yaqin qo'shnilar (KNN)	Aniqlik	88%
K-means klasterlash	Siluet skori	0.75

Jadval 1: Modellarning samaradorlik ko'rsatkichlari



Ushbu metrikalar asosida o'qituvchilarga yuklama taqsimlash samaradorligini oshirish uchun modellarni tanlash va moslashtirish amalga oshirildi.

IV. Results

Tadqiqot natijalari O'zbekistondagi oliy ta'lim muassasalarida o'qituvchilar uchun o'quv yuklamasini boshqarishda mashinali o'rganish modellarining samaradorligini ko'rsatdi. Turli algoritmlar yordamida yuklamani bashorat qilish, adolatli taqsimlash va optimallashtirish imkoniyatlari baholandi. Quyida modellarning har biri bo'yicha olingan natijalar keltirilgan.

1. Chiziqli va ko'p omilli regressiya natijalari

Chiziqli regressiya modeli yuklama bashorati uchun asosiy model sifatida foydalanildi va R^2 qiymati 0.85 ga teng bo'ldi, bu esa modelning umumiy natijalarni yaxshi tushuntirishini ko'rsatdi. Ko'p omilli regressiya modeli esa bir nechta omillarni hisobga olish orqali yuklama bashorat qilishda yaxshiroq aniqlikka erishdi va R^2 qiymati 0.88 ga yetdi.

Model	MSE	R^2
Chiziqli regressiya	15.3	0.85
Ko'p omilli regressiya	12.5	0.88

Jadval 2: Chiziqli va ko'p omilli regressiya natijalari

Bu natijalar ko'p omilli regressiyaning murakkab o'zgaruvchilar bilan ishlashga yaxshi moslashganligini ko'rsatdi, bu esa yuqori aniqlik bilan yuklamani boshqarish imkonini beradi.

2. K yaqin qo'shnilar (KNN) tasniflash natijalari

K yaqin qo'shnilar (KNN) modeli yordamida o'qituvchilarni yuklama darajalariga tasniflash amalga oshirildi. Ushbu model yordamida yuqori, o'rtacha va past yuklama guruhlari aniqlandi. Modelning aniqligi 88% ga teng bo'lib, u yuklamani to'g'ri tasniflashga imkon berdi.

Yuklama darajasi	Aniqlik
Yuqori	88%
O'rtacha	88%
Past	88%

Jadval 3: KNN Tasniflash natijalari

KNN modeli o'qituvchilar uchun yuklama darajasini aniqlash va ularni tegishli guruhlarga ajratishda samarali ekanligi ko'rsatildi.

3. K-means klasterlash natijalari

K-means klasterlash yordamida o'qituvchilarni yuklama darajasi va tajribasiga ko'ra klasterlarga ajratish amalga oshirildi. Natijalarga ko'ra, K-means modeli **siluet skori** bo'yicha 0.75 ga teng baho oldi, bu esa klasterlar orasidagi aniq farqlar mavjudligini ko'rsatadi. Ushbu model yordamida o'qituvchilarni yuklama hajmi va boshqa xususiyatlarga ko'ra guruhlash samaradorligi ta'minlandi.

Klasterlash turi	Siluet skori
K-means	0.75

Jadval 4: K-means klasterlash natijalari

Klasterlash natijalari yuklamani teng taqsimlashga yordam berdi va o'qituvchilarning o'quv yuklamasi bo'yicha to'g'ri guruhlanishini ta'minladi.



Grafik 1: Modellarning metrika natijalari

Grafikda chiziqli va ko'p omilli regressiya modellari uchun MSE va R^2 ko'rsatkichlari, shuningdek, KNN modeli aniqligi va K-means klasterlash uchun siluet skori keltirilgan. Grafik natijalar shuni ko'rsatadiki, ko'p omilli regressiya modeli yuklama prognozlashda eng yuqori aniqlikka ega bo'lib, K-means klasterlash esa yuklamani samarali guruhlash imkonini beradi.

V. Discussion

Ushbu tadqiqot natijalari O'zbekiston oliy ta'lim muassasalarida o'quv yuklamasini boshqarishda mashinali o'rganish modellarining qo'llanilishi samaradorligini ko'rsatdi. Modellar o'rtasidagi farqlar va ularning o'quv yuklamasi taqsimotiga ta'siri haqida batafsil muhokama qilamiz.

1. Regressiya modellari orqali yuklama prognozi

Tadqiqotda qo'llanilgan **chiziqli** va **ko'p omilli regressiya modellari** o'quv yuklamasini prognozlashda yaxshi natijalar berdi. **Ko'p omilli regressiya** modeli yuklama bashoratida yuqori aniqlik ko'rsatkichiga ega bo'ldi, bu esa bir nechta o'zgaruvchilarni (o'qituvchi tajribasi, talaba soni va dars soatlari) hisobga olishning muhimligini ko'rsatadi. Ushbu yondashuv O'zbekiston ta'lim tizimida yuklama taqsimotini optimallashtirish uchun potentsialga ega bo'lib, kelajakda ko'proq parametrlarni qo'shish orqali natijalarni yanada yaxshilash mumkin.

2. Tasniflash modelining amaliy foydalari

K yaqin qo'shnilar (KNN) modeli o'qituvchilarni yuklama darajasiga qarab yuqori, o'rtacha va past yuklama guruhlarga ajratishda muvaffaqiyatli ishladi. Bu tasniflash o'qituvchilar orasidagi yuklama farqlarini aniqlash va resurslarni teng taqsimlashda yordam beradi. Ayniqsa, yuklama notengliklarini aniqlashda va yuqori yuklamaga ega o'qituvchilarni qo'llab-quvvatlash imkonini beradi. Shu tariqa, KNN modeli yordamida yuklama darajalarini aniqlash orqali o'qituvchilarning yuklamasini samarali boshqarish mumkinligi ko'rsatildi.

3. Klasterlash modelining yutuqlari va cheklovlari

K-means klasterlash yordamida o'qituvchilarni yuklama va tajriba bo'yicha klasterlarga ajratish amalga oshirildi. Ushbu model o'qituvchilarni samarali guruhlash imkonini bergan bo'lsa-da, ma'lumotlar hajmi va turli o'zgaruvchilar ko'payishi bilan ba'zi cheklovlar mavjud bo'ldi. Xususan, katta hajmdagi o'quv yuklamalari va murakkab tajribaviy ma'lumotlar uchun klasterlashni qo'shimcha modifikatsiyalar bilan amalga oshirish talab etiladi. Kelajakda klasterlash modelini yanada murakkablashtirish va hierarchik yondashuvlar qo'llash orqali natijalarni yanada yaxshilash mumkin.

4. Amaliy tatbiq va kelajakdagi takomillashtirish

Ushbu tadqiqot natijalari O'zbekistondagi oliy ta'lim muassasalarida yuklama boshqarishni avtomatlashtirish va resurslarni adolatli taqsimlash imkonini beradi. Amaliyotda ushbu modellarni ishga tatbiq etish uchun real vaqtda yuklama va o'qituvchi faoliyatini kuzatish tizimlarini joriy qilish, shuningdek, yillik baholashlar uchun ilg'or analitik vositalardan foydalanish tavsiya etiladi.

Kelajakda yanada takomillashtirish uchun quyidagi yo'nalishlar ko'rib chiqilishi mumkin:

O'zgaruvchilarni kengaytirish: o'qituvchilarning qo'shimcha ma'lumotlarini, masalan, ilmiy izlanish va dars tashqarisidagi faoliyatlarini qo'shish.

Gibrid modellar yaratish: regressiya, klasterlash va tasniflash modellarini birlashtirib, yanada aniq va dinamik yuklama boshqaruv tizimlarini ishlab chiqish.

Real vaqt ma'lumotlarini qo'llash: o'qituvchilar va talabalar uchun interaktiv yuklama boshqaruv platformalarini joriy qilish orqali yanada moslashuvchan tizimlarni yaratish.

Umuman olganda, ushbu tadqiqot natijalari mashinali o'rganish modellarini qo'llash orqali o'qituvchilar uchun yuklama boshqaruvini samarali va ilmiy asosda amalga oshirish mumkinligini ko'rsatdi, bu esa O'zbekistondagi oliy ta'lim sifatini oshirish uchun muhim ahamiyatga ega.



VI. Summary

Ushbu tadqiqot O'zbekistondagi oliy ta'lim muassasalarida o'qituvchilar uchun o'quv yuklamasini boshqarish va optimallashtirish uchun mashinali o'rganish modellarining samaradorligini o'rganishga qaratildi. Turli mashinali o'rganish texnikalari — chiziqli va ko'p omilli regressiya, K yaqin qo'shnilar (KNN), va K-means klasterlash modellarining ishlash ko'rsatkichlari baholandi va ular yuklama prognozi hamda adolatli taqsimlash uchun mos ekanligi ko'rsatildi.

Natijalar quyidagilarni tasdiqladi:

Yuklama prognozi: Chiziqli va ko'p omilli regressiya modellari yuklamani aniqlik bilan bashorat qilishda samarador bo'lib, bu o'qituvchilarga taqsimlangan yuklama bo'yicha qaror qabul qilishda muhim ahamiyat kasb etadi.

Tasniflash: KNN modeli o'qituvchilarni yuqori, o'rtacha va past yuklama darajalariga samarali tasniflab, resurslarni adolatli taqsimlashda yordam berdi.

Klasterlash: K-means klasterlash yondashuvi o'qituvchilarni tajriba va yuklama darajasiga qarab guruhlash imkonini berdi va umumiy yuklama taqsimoti uchun ishonchli asos yaratdi.

Tadqiqot natijalariga ko'ra, O'zbekistondagi oliy ta'lim muassasalarida o'qituvchilar uchun o'quv yuklamasini boshqarish tizimlariga mashinali o'rganish modellarini tatbiq etish orqali yuklamani samarali va teng taqsimlash imkoniyati mavjudligi aniqlandi. Bu nafaqat o'qituvchilarning yuklamasini boshqarishda, balki ta'lim sifati va resurslardan foydalanishni optimallashtirishda ham muhim rol o'ynaydi.

Kelajakda modellarni yanada takomillashtirish uchun real vaqt ma'lumotlarini qo'shish, yangi xususiyatlarni qo'llash va gibrid modellarni joriy qilish orqali yuklama boshqaruv tizimlarini yanada samarali qilish bo'yicha tadqiqotlar davom ettirilishi tavsiya etiladi.

Adabiyotlar ro'yxati

1. **Zaman, H., & Mahmud, A. (2020).** *Predictive Modeling in Education: A Review of Machine Learning Applications in Academic Workload Management.* Journal of Educational Technology, 19(2), 102–116.
2. **Cortes, C., & Vapnik, V. (1995).** *Support-vector networks.* Machine Learning, 20(3), 273–297.
3. **Baker, R. S. (2019).** *Challenges for the Future of Educational Data Mining: The Road Ahead.* Journal of Educational Data Mining, 11(1), 1–17.
4. **Witten, I. H., Frank, E., & Hall, M. A. (2017).** *Data Mining: Practical Machine Learning Tools and Techniques.* Morgan Kaufmann.
5. **Yang, C., & Li, Z. (2021).** *Using Machine Learning to Predict Teacher Workload Based on Curriculum Scheduling.* International Journal of Advanced Educational Research, 6(2), 88–94.
6. **Romero, C., & Ventura, S. (2020).** *Educational Data Mining and Learning Analytics: A Survey of Recent Trends in Data Mining and Machine Learning in Education.* ACM Computing Surveys, 52(4), 1–39.
7. **Zhou, J., & Wu, H. (2022).** *Application of Machine Learning Algorithms in Optimizing Faculty Workload Allocation.* Advances in Educational Technologies and Instructional Design, 15(1), 233–248.
8. **He, Q., & Xiao, Y. (2018).** *Predicting Workload with Ensemble Learning in Higher Education.* Computers & Education, 120, 1–10.
9. **Luan, J., & Dziuban, C. (2017).** *Higher Education Analytics: Using Predictive Modeling to Support Students and Faculty.* EDUCAUSE Review, 54(3), 12–22.
10. **Kuznetsov, S. O., & Kuznetsova, M. M. (2021).** *Optimizing Academic Workload with Machine Learning Approaches.* Procedia Computer Science, 180, 344–353.

