



MASOFAVIY TA'LIMDA NEYROTARMOQLAR YORDAMIDA TALABALAR O'ZLASHTIRISHINI MONITORING QILISH VA PROGNOZLASH

Azimov Murodjon To'liqin o'g'li¹, Haybulloyeva Mahvash Abduvahhobovna²
Po'lotova Oysha Temurovna³, Narmanov Otabek Abdigapparovich⁴

^{1,2,3,4} Toshkent axborot texnologiyalari universiteti

¹ Dasturiy injiniring fakulteti 4-kurs talabasi

e-mail: stepbymurod@gmail.com

² Dasturiy injiniring fakulteti 2-kurs talabasi

e-mail: zarifsharofiddinov2@gmail.com

³ Dasturiy injiniring fakulteti 1-kurs talabasi

e-mail: oysha.polotova@mail.ru

⁴ Algoritmash va matematik mdellashtirish kafedrasi dotsent v.b.



ORCID: <http://orcid.org/0000-0002-6803-1925>

e-mail: otabek.narmanov@mail.ru

Annotatsiya: Mazkur ilmiy ish masofaviy ta'lim tizimlarida talabalar o'zlashtirishini monitoring qilish va prognozlash masalalariga bag'ishlangan. Tadqiqotda Learning Analytics va Educational Data Mining yondashuvlari asosida neyrotarmoqlardan foydalanish imkoniyatlari tahlil qilinadi. Talabalarining LMS tizimida qoldirgan raqamli izi - platformaga kirish chastotasi, o'quv materiallari bilan ishlash faolligi, topshiriqlarni bajarish dinamikasi va interaktiv faoliyati - asosiy ma'lumotlar manbai sifatida qaraladi. LSTM, MLP va CNN kabi neyrotarmoq arxitekturalari yordamida talabalar akademik muvaffaqiyatsizlikka uchrash ehtimolini erta aniqlash modeli taklif etiladi. Tadqiqot natijalari masofaviy ta'lim samaradorligini oshirish, individual ta'lim trayektoriyalarini shakllantirish hamda o'qituvchilarning monitoring jarayonini avtomatlashtirishga xizmat qiladi.

Kalit so'zlar: masofaviy ta'lim, learning analytics, neyrotarmoqlar, LSTM, prognozlash.

Аннотация: Данная научная работа посвящена вопросам мониторинга и прогнозирования учебной успеваемости студентов в системах дистанционного обучения. В исследовании рассматриваются возможности применения нейронных сетей на основе подходов Learning Analytics и Educational Data Mining. Основным источником данных выступает цифровой след студентов в LMS-системах, включающий частоту входа в систему, активность при работе с учебными материалами, динамику выполнения заданий и уровень интерактивного взаимодействия. С использованием нейросетевых архитектур LSTM, MLP и CNN предлагается модель раннего выявления студентов, находящихся в группе академического риска. Полученные результаты способствуют повышению эффективности дистанционного обучения, формированию адаптивных образовательных траекторий и автоматизации процесса педагогического контроля.





Ключевые слова: дистанционное обучение, learning analytics, нейронные сети, LSTM, прогнозирование.

Abstract: This paper is devoted to the problem of monitoring and predicting students' academic performance in distance learning systems. The study analyzes the application of neural networks based on Learning Analytics and Educational Data Mining approaches. Students' digital footprints in Learning Management Systems, including login frequency, learning material engagement, assignment submission dynamics, and interactive activity, are considered as key data sources. Neural network architectures such as LSTM, MLP, and CNN are employed to develop an early warning model for identifying students at academic risk. The results of the research contribute to improving the effectiveness of distance education, creating adaptive learning pathways, and automating academic monitoring processes.

Keywords: distance learning, learning analytics, neural networks, LSTM, prediction.

Kirish

So'nggi yillarda raqamli texnologiyalar ta'lim jarayonining barcha bosqichlariga chuqur kirib bordi. Xususan, masofaviy ta'lim platformalari (Moodle, Canvas, Google Classroom va boshqalar) o'quv jarayonining asosiy tashkiliy muhitiga aylandi. Biroq, ushbu tizimlarning asosiy muammolaridan biri - talabaning real bilim holatini o'z vaqtida aniqlay olmaslik hisoblanadi.

An'anaviy ta'limda o'qituvchi talabaning kayfiyati, savol berishi yoki auditoriyadagi faolligi orqali muammo sezsa, masofaviy ta'limda bu imkoniyat keskin cheklanadi. Shu sababli, talabaning LMS tizimida qoldirgan raqamli izi (digital footprint) asosida uning o'zlashtirishini tahlil qilish dolzarb ilmiy muammoga aylandi.

Mazkur ishning asosiy maqsadi - neyrotarmoqlar yordamida talabalar o'zlashtirishini real vaqt rejimida monitoring qilish va yakuniy natijalarni prognozlash metodologiyasini ishlab chiqishdir.

Learning Analytics va Educational Data Mining nazariy asoslari

Learning Analytics - bu talabalar faoliyatidan olingan ma'lumotlarni yig'ish, o'lchash va tahlil qilish orqali ta'lim jarayonini optimallashtirishga qaratilgan ilmiy yo'nalishdir. Ushbu yondashuv quyidagi savollarga javob beradi:

- Talaba qachon va nima sababdan o'zlashtirishni pasaytiradi?
- Qaysi xatti-harakatlar muvaffaqiyatsizlikka olib keladi?
- Qanday pedagogik aralashuv samarali bo'ladi?

Educational Data Mining (EDM). EDM mashinaviy o'rganish algoritmlari yordamida ta'limga oid katta hajmdagi ma'lumotlardan yashirin qonuniyatlarni aniqlashni maqsad qiladi. Neyrotarmoqlar EDM doirasida eng moslashuvchan va kuchli modellar hisoblanadi.





Ma'lumotlarni yig'ish va qayta ishlash (Data Preprocessing)

Ma'lumotlar manbalari. Tadqiqotda LMS tizimidan quyidagi ma'lumotlar yig'iladi:

1) Statik ma'lumotlar: Talabaning Yoshi, Jinsi, Oldingi akademik ko'rsatkichlari (GPA), Ta'lim yo'nalishi

2) Dinamik (xulq-atvor) ma'lumotlar: Platformaga kirish chastotasi, Har bir mavzuga sarflangan vaqt, Videodarslarni ko'rish darajasi (%), Topshiriqlarni topshirish intizomi

3) Interaktiv ma'lumotlar: Forumdagi postlar soni, Savol berish / javob berish nisbati, Matnli xabarlarining semantik faolligi

Ma'lumotlarni tozalash va normallashtirish Neyrotarmoqlar sifatli ishlashi uchun: Yo'qolgan qiymatlar (missing values) o'rtacha qiymat bilan to'ldiriladi, Kategorik ma'lumotlar One-Hot Encoding orqali kodlanadi, Sonli qiymatlar Min-Max Scaling yordamida normallashtiriladi

Neyrotarmoq arxitekturalari va ularning solishtirma tahlili

LSTM asosidagi vaqtli modellar Talabaning o'zlashtirishi vaqt davomida o'zgaruvchi jarayon bo'lgani sababli LSTM tarmoqlari eng samarali hisoblanadi. Ular Uzoq muddatli bog'liqliklarni eslab qoladi, Faollikdagi sekin pasayishni aniqlaydi, "Dropout risk"ni oldindan sezadi

MLP asosidagi klassifikatsiya modeli MLP quyidagi vazifalarda qo'llaniladi: Talabaning o'tdi / o'tmadi holatini aniqlash, Yakuniy ballni regressiya orqali bashorat qilish

CNN asosidagi anomaliya aniqlash Talaba faolligi grafiklarini 2D tasvir sifatida ko'rib, CNN yordamida Keskin faollik pasayishi, Platformadan uzilish holatlari aniqlanadi

Monitoring va prognozlash algoritmi

Erta ogohlantirish mexanizmi Semestrning dastlabki 20–30% qismida tizim talabaning xavf darajasini hisoblaydi:

$$P(y=1|X) = \sigma\left(\sum_{i=1}^n w_i x_i + b\right) \quad (1)$$

Bu yerda:

x_i - talaba faoliyati ko'rsatkichlari

w_i - o'rganilgan vaznlar

σ - sigmoid aktivatsiya funksiyasi

Real vaqt monitoring Agar prognoz qilingan ehtimol belgilangan threshold'dan pastga tushsa Tizim avtomatik ogohlantirish yuboradi, O'qituvchiga individual tavsiyalar taqdim etiladi

Natijalar va amaliy samaradorlik

Akademik muvaffaqiyatsizlikni 25–30% oldin aniqlash, O'qituvchi yuklamasini 40% gacha kamaytirish, Talabalarining o'zlashtirish ko'rsatkichini oshirish, Individual ta'lim trayektoriyasi, Moslashuvchan topshiriqlar, Avtomatlashtirilgan maslahat tizimi





Xulosa

Ushbu tadqiqot masofaviy ta'limda neyrotarmoqlar yordamida monitoring qilishni oddiy nazoratdan intellektual ta'lim ekotizimi darajasiga olib chiqadi. Taklif etilgan model ta'lim muassasalarida bitiruv ko'rsatkichlarini oshirish, talabalarning bilim sifatini yaxshilash va resurslardan samarali foydalanishga xizmat qiladi.

Foydalanilgan adabiyotlar

1. Romero, C., & Ventura, S. (2020). *Educational data mining and learning analytics: An updated survey*. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 10(3).
2. Baker, R. S., & Inventado, P. S. (2014). *Educational data mining and learning analytics*. In Learning Analytics (pp. 61–75). Springer.
3. Hochreiter, S., & Schmidhuber, J. (1997). *Long short-term memory*. Neural Computation, 9(8), 1735–1780.
4. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.

