

SUN'IY INTELLEKT YORDAMIDA O'QUVCHILARGA INDIVIDUAL MATEMATIK MASALALAR TAVSIYA QILISH TIZIMI: GIBRID ALGORITMNING ADAPTIV SAMARADORLIGI

Madraximova Gulrux Farxodovna
Toshkent Davlat Iqtisodiyot Universiteti
“Axborot tizimlari va texnologiyalari”
kafedrasi assistenti
gulruxmadraximova91@tsue.uz

Annotatsiya. Ushbu tadqiqotda o'quvchilarning individual o'rganish xususiyatlarini real vaqt rejimida hisobga olgan holda matematik masalalar tavsiya qilishning gibrid tizimi ishlab chiqildi va eksperimental baholandi. Tizim kontentga asoslangan filtrlash (content-based filtering) va hamkorlikli filtrlash (collaborative filtering) usullarining dinamik kombinatsiyasidan foydalanadi. Taklif etilgan adaptiv vazn mexanizmi yangi foydalanuvchilar uchun "cold start" muammosini hal qiladi va tajribali o'quvchilar uchun hamkorlikli tavsiyalarning ulushini avtomatik oshiradi. 80 nafar 9-11 sinf o'quvchilari ishtirokida o'tkazilgan 16 haftalik kvazi-eksperimental tadqiqot natijasida tizim 87.3% aniqlik (Precision@10), 82.1% to'liqlik (Recall@10) va 84.6% F1-score ko'rsatkichlariga erishdi. Tajriba guruhi o'quvchilari nazorat guruhiga nisbatan o'rtacha 23.3% yuqori o'sish namoyish etdi ($p < 0.001$, Cohen's $d = 1.29$). O'quvchilar subyektiv qoniqish darajasi 4.3/5 ballni tashkil etdi. Natijalar sun'iy intellekt yordamida individual ta'lim samaradorligini oshirishning imkoniyatlarini tasdiqlaydi.

Kalit so'zlar: adaptive learning, tavsiya tizimlari, individual ta'lim, matematik masalalar, mashina o'rganish, kontentga asoslangan filtrlash, hamkorlikli filtrlash, gibrid algoritmi, cold start, o'quvchi profili.

KIRISH

Tadqiqotning dolzarbligi. Zamonaviy ta'lim tizimida individual yondashuv (individualized instruction) ahamiyati tobora oshib bormoqda. Har bir o'quvchi o'zining o'rganish tezligi, kognitiv uslublari, qiziqishlari va bilim darajasiga ega. Ayniqsa, matematika kabi ierarxik tuzilmaga ega fanlarni o'rganishda o'quvchilarning turlicha bilim darajalari aniq namoyon bo'ladi. Ba'zi o'quvchilar algebraik masalalarni oson yechsa, boshqalari geometrik masalalarda kuchliroq bo'lishi mumkin [3].

Bloomning "2 sigma" muammosi [1] shuni ko'rsatadiki, individual repetitorlik o'quvchilarning o'rganish natijalarini guruhviy o'qitishga nisbatan ikki standart og'ishcha yuqori oshiradi. Biroq, an'anaviy ta'lim sharoitida o'qituvchi har bir o'quvchiga alohida e'tibor qaratish uchun cheklangan vaqtga ega. Katta sinflarda (30-40 o'quvchi) individual yondashuvni amalga oshirish amaliy jihatdan qiyinlashadi [4].

Sun'iy intellekt (AI) va mashina o'rganish (machine learning) texnologiyalarining rivojlanishi individual ta'limni masshtablash uchun yangi

imkoniyatlar yaratmoqda [5,6]. Tavsiya tizimlari (recommender systems) e-commerce, media va entertainment sohalarida keng qo'llanilishi bilan birga, so'nggi yillarda adaptive learning (moslashuvchan o'rganish) sohasiga joriy etilmoqda.

Ta'lim sohasida tavsiya tizimlari o'quvchilarning o'tmishdagi faoliyatini, bilim darajasini va qiziqishlarini tahlil qilib, ularga eng mos keluvchi o'quv materiallarini, mashqlar va matematik masalalarni tavsiya qiladi. Bu yondashuv o'quvchilarning o'rganish natijalarini oshirishga, vaqtini samarali tashkil etishiga va motivatsiyasini yuqori darajada saqlashiga yordam beradi [11].

Ammoda mavjud tavsiya tizimlari asosan ikki yondashuvga asoslanadi: kontentga asoslangan filtrlash (content-based filtering, CBF) va hamkorlikli filtrlash (collaborative filtering, CF). CBF o'quvchining oldingi faoliyatiga asoslanib, o'xshash kontentni tavsiya qiladi. CF esa o'xshash o'quvchilarning tajribasidan foydalanadi. Har ikki yondashuvning ham o'ziga xos cheklovlari mavjud: CBF yangi foydalanuvchilar uchun (cold start problem) va noyob qiziqishlarga ega o'quvchilar uchun samarasiz, CF esa siyrak ma'lumotlar (sparse data) holatida yoki yangi tizimlarda ishlata olmaydi.

Shu sababli, ushbu tadqiqotda bu ikki usulning optimal kombinatsiyasini ishlab chiqish, adaptiv vazn mexanizmi orqali ularning kuchli tomonlarini birlashtirish va zaif tomonlarini kamaytirish maqsad qilindi. Taklif etilgan tizim o'zbek ta'lim kontekstida, ayniqsa 9-11 sinf matematika kursi uchun mo'ljallangan.

Tadqiqot obyekti: 9-11 sinf o'quvchilarining matematik masalalar yechish jarayoni va ularning individual o'rganish xususiyatlari (o'rganish tezligi, bilim darajasi, qiziqishlari).

Tadqiqot predmeti: O'quvchilarga individual matematik masalalar tavsiya qilish algoritmlari, ularning samaradorligi, optimallashtirish usullari va adaptive learning nazariyasiga tatbiqi.

Tadqiqot maqsadi va vazifalari

Asosiy maqsad: Sun'iy intellekt yordamida o'quvchilarga individual matematik masalalar tavsiya qiluvchi, yuqori aniqlikka ega adaptiv gibril tizim ishlab chiqish va uning pedagogik samaradorligini eksperimental baholash.

Tadqiqot vazifalari:

1. O'quvchi profilini shakllantirish va uzluksiz yangilash usulini ishlab chiqish;
2. Kontentga asoslangan va hamkorlikli filtrlash algoritmlarini integratsiyalash va ularning optimal kombinatsiyasini aniqlash;
3. Dinamik vazn koeffitsienti ($\alpha(t)$) mexanizmini ishlab chiqish va "cold start" muammosini yechish;
4. Tizim samaradorligini eksperimental baholash (offline va online metrikalar);
5. Pedagogik amaliy qo'llanish bo'yicha tavsiyalar ishlab chiqish.

Ilmiy yangiligi:

1. Birinchi marta o'zbek ta'lim kontekstida matematik masalalar uchun maxsus adaptiv gibril tavsiya algoritmi ishlab chiqildi. Taklif etilgan dinamik vazn koeffitsienti $\alpha(t)$ yangi o'quvchilar uchun CBF ustunligini, tajribali o'quvchilar uchun

esa CF ustunligini avtomatik ta'minlaydi.

2. Murakkablik adaptatsiyasi mexanizmi ishlab chiqildi: tizim nafaqat o'quvchining umumiy bilim darajasini, balki har bir mavzudagi mahoratini alohida hisobga oladi.

3. Diversifikatsiya strategiyasi taklif etildi: tavsiyalar nafaqat eng mos masalalarni, balki o'sish uchun biroz qiyinroq va takrorlash uchun osonroq masalalarni ham qamrab oladi.

Nazariy ahamiyati: Tavsiya tizimlari nazariyasiga ta'lim sohasidagi qo'llanish bo'yicha yangi empirik ma'lumotlar qo'shildi. Gibridd algoritmnining optimal parametrlari ($\alpha_0 = 0.9$, $H_{min} = 10$) eksperimental aniqlandi.

Amaliy ahamiyati: Ishlab chiqilgan tizim maktab va o'quv markazlarida qo'llanilishi mumkin. O'qituvchilar vaqtini tejash, o'quvchilarning motivatsiyasini oshirish va individual o'rganish natijalarini yaxshilash imkonini beradi. Tizim kodlari ochiq manba sifatida taqdim etiladi.

METODLAR

Tadqiqot dizayni. Tadqiqot kvazi-eksperimental (quasi-experimental) turda o'tkazildi. Pre-test—post-test with control group dizayni qo'llandi [15]. O'quvchilar tasodifiy tanlash (simple random sampling) usuli bilan ikki guruhga bo'lindi:

1. Tajriba guruhi (n=40): Tavsiya tizimi + an'anaviy o'qitish
2. Nazorat guruhi (n=40): Faqat an'anaviy o'qitish

Tanlash mezonlari:

1. Matematika fanidan boshlang'ich bilim darajasi o'rtacha (40-70% test natijasi);
2. 16 hafta davomida doimiy qatnashish imkoniyati;
3. Boshlang'ich kompyuter savodxonligi;
4. O'qituvchi tavsiyasi asosida "o'rtacha" darajadagi o'quvchilar (eng yaxshi va eng zaiflar chiqarib tashlandi).

Matematik masalalar bazasi

Masalalar soni: 500 ta, quyidagi kategoriyalarga bo'lingan:

Kategoriya	n	Sub-mavzular	Murakkablik diapazoni
Arifmetika	80	Natural sonlar, kasrlar, foizlar	1-3
Algebra	120	Tenglamalar, tengsizliklar, ifodalar	2-4
Geometriya	100	Planimetriya, stereometriya	2-5
Trigonometriya	80	Trigonometrik tenglamalar, ayniyatlar	3-5
Matematik analiz	120	Limit, hosila, integral	3-5

$$\text{Difficulty}(p) = 0.3 \cdot \text{steps}_{\text{norm}}(p) + 0.3 \cdot \text{formulas}_{\text{norm}}(p) + 0.4 \cdot \text{expert}_{\text{norm}}(p)$$

Bu yerda:

$$\text{steps}_{\text{norm}}(p) = \frac{\text{qadamlar soni}}{10} \text{ (masalan, 5 qadam} \rightarrow 0.5)$$

$$\text{formulas}_{\text{norm}}(p) = \frac{\text{formular soni}}{5} \text{ (masalan, 3 formula} \rightarrow 0.6)$$

$$\text{expert}_{\text{norm}}(p) = \frac{\text{ekspert bahos}}{5} \text{ (masalan, 4 baho} \rightarrow 0.8)$$

O'quvchi profilini shakllantirish

Profil ikki bosqichda yaratiladi va uzluksiz yangilanadi:

Boshlang'ich baholash (Onboarding, Hafta 0). O'quvchi tizimga birinchi marta kirganda 15 ta kalibrlash masalasi beriladi: Har bir asosiy mavzudan 3 ta masala (arifmetika, algebra, geometriya, trigonometriya, analiz), Murakkablik darajalari: 2 ta oson (2), 1 ta o'rta (3).

O'lchovlar:

t_i^0 — yechish vaqti (sekund),

$c_i^0 \in \{0,1\}$ — to'g'ri yechim (1) yoki noto'g'ri (0),

$h_i^0 \in \{0,1\}$ — yordam so'ralganligi.

Boshlang'ich bilim darajasi:

$$L_0 = \frac{1}{15} \sum_{i=1}^{15} \left(0.6 \cdot c_i^0 + 0.3 \cdot \min\left(\frac{\bar{t}_i}{t_i^0}\right) + 0.1 \cdot (1 - h_i^0) \right)$$

bu yerda \bar{t}_i — masala i uchun o'rtacha vaqt.

Uzluksiz profil yangilashi. Har bir masaladan so'ng quyidagi ko'rsatkichlar yangilanadi:

Ko'rsatkich	Formulasi	Tavsif
Mavzudagi mahorat	$S_{t+1}^{(topic)} = S_t^{(topic)} + \eta \cdot (c_i - S_t^{(topic)})$	Exponential smoothing
Umumiy bilim darajasi	$L_{t+1} = L_t + \eta \cdot \Delta L$	Adaptive learning rate
O'rganish tezligi	$\eta = 0.1 \cdot \frac{5}{S_i}$	O'quvchi bahosiga bog'liq

Bilim darajasi yangilanishi:

$$\Delta L = c_i \cdot \frac{\bar{t}_i}{t_i} \cdot \frac{S_i}{5} - (1 - c_i) \cdot 0.1$$

bu yerda:

c_i — to'g'ri yechim indikatorini,

\bar{t} — o'rtacha vaqt,

t_i — sarflangan vaqt,

$S_i \in [1,5]$ — o'quvchining subyektiv bahosi (qiyinlikni baholash).

Kontentga asoslangan filtrlash (CBF). Masalalar o'xshashligi kosinus o'xshashligi (cosine similarity) bilan aniqlanadi: CBF afzalliklari: Yangi masalalar uchun samarali, o'quvchining shaxsiy xususiyatlarini hisobga oladi. CBF kamchiliklari: Cold start, diversifikatsiya yetishmovchiligi.

Hamkorlikli filtrlash (CF). Foydalanuvchilar o'xshashligi Pearson korrelyatsiyasi bilan [6]: CF afzalliklari: Noyob qiziqishlarni aniqlay oladi, serendipity

(kutilmagan yaxshi tavsiyalar). CF kamchiliklari: Siyrak ma'lumotlar (sparse matrix), yangi masala/mavzu uchun samarasiz.

Gibrid usul: Adaptiv vazn koeffitsienti. Asosiy innovatsiya — dinamik $\alpha(t)$ koeffitsienti:

$$\alpha(t) = \alpha_0 + (1 - \alpha_0) \cdot \min\left(\frac{|H_u|}{H_{min}}\right)^\beta$$

Parametrlar:

$\alpha_0 = 0.9$ — boshlang'ich CBF ulushi,

$H_{min} = 10$ — minimal tarix hajmi,

$\beta = 0.8$ — o'tish tezligi (sublinear).

Yakuniy reyting:

$$R_{hybrid}(u, p) = \alpha(t) \cdot R_{CBF}(u, p) + (1 - \alpha(t)) \cdot R_{CF}(u, p)$$

Murakkablik adaptatsiyasi:

$$R_{final}(u, p) = R_{hyb}(u, p) \cdot \exp\left(-\frac{(d_p - L_u^{(topic)})^2}{2\sigma^2}\right)$$

bu yerda:

d_p — masala murakkabligi,

$L_u^{(topic)}$ — o'quvchining ushbu mavzudagi mahorati,

$\sigma=0.8$ — moslashuvchanlik darajasi.

Tavsiya qilish jarayoni. Diversifikatsiya strategiyasi: 5 ta asosiy: Eng yuqori R_{final} ga ega, mavzuga mos, 3 ta qiyin: O'sish uchun ($d_p = L_u + 1$), 2 ta takrorlash: Avval yechilgan, lekin uzoq vaqt o'tgan (>7 kun).

Eksperimental protokol

Tadqiqot davomiyligi: 16 hafta.

Haftalik rejim:

Dushanba-Juma: Tizimdan foydalanish (tajriba guruhi),

Shanba: 30 daqiqalik nazorat testi,

Yakshanba: Ma'lumotlar tahlili va tizim yangilanishi.

Nazorat guruhi: An'anaviy usul — o'qituvchi tomonidan belgilangan mashqlar (haftasiga 10 ta masala, bir xil barcha o'quvchilar uchun).

Statistik tahlil.

Dasturiy ta'minot: Python 3.10, scipy 1.9, statsmodels 0.13.

Testlar:

Guruhlar o'rtasidagi farq: Independent samples t-test,

Pre-post farq: Paired samples t-test,

Effect size: Cohen's d (0.2=kichik, 0.5=o'rta, 0.8=katta),

Korrelyatsiya: Pearson r,

Signifikantlik: $\alpha=0.05$ (95% ishonch oralig'i).

NATIJARLAR

Tizim aniqlik ko'rsatkichlari (Offline Evaluation)

Jadval 1.

Sinflashtirish modellarining taqqoslash natijalari (n=200, test to'plami, 10-fold cross-validation)

Model	Precision@10	Recall@10	F1-score	NDCG@10	AUC-ROC	Inference
Random (baseline)	23.4 ± 3.1%	18.2 ± 2.8%	0.204	0.312	0.501	0.01
Popular (baseline)	45.2 ± 4.5%	38.6 ± 4.2%	0.416	0.528	0.642	0.02
Faqat CBF	78.6 ± 4.2%	71.3 ± 3.9%	0.747	0.823	0.856	0.08
Faqat CF	65.2 ± 5.1%	58.9 ± 4.7%	0.618	0.701	0.782	0.15
Gibrid (statik $\alpha=0.5$)	82.4 ± 3.8%	76.8 ± 3.6%	0.794	0.856	0.891	0.18
Gibrid (adaptiv $\alpha(t)$)	87.3 ± 3.4%	82.1 ± 3.6%	0.846	0.891	0.923	0.19

Eslatma: Ko'rsatkichlar mean ± SD. Eng yaxshi natijalar qalin shrift bilan.

"Cold start" muammosini tahlil

Jadval 2.

Yangi o'quvchilar uchun tavsiya aniqligi (birinchi 10 ta masala)

Tavsiya turi	1-3 masala	4-6 masala	7-10 masala	O'rtacha
Faqat CF	12.3%	18.7%	24.5%	18.5%
Faqat CBF	71.2%	74.8%	77.3%	74.4%
Gibrid (statik $\alpha=0.5$)	41.8%	46.7%	50.9%	46.5%
Gibrid (adaptiv $\alpha=0.9$)	78.4%	76.2%	73.1%	75.9%

H4 gipotezasi tasdiqlandi. Adaptiv $\alpha=0.9$ yangi o'quvchilar uchun CBF samaradorligini saqlab qoldi. CF faqat yetarli tarix to'plangach (7+ masala) samarali bo'ldi.

Vaqt bo'yicha dinamika

Jadval 4.

O'sish dinamikasi (haftalik o'rtacha natijalar, tajriba guruhi)

Hafta	Bilim darajasi (%)	Masalalar soni	To'g'ri yechish (%)	Tavsiya qabul qilish (%)	α o'rtacha
0 (Pre)	58.4	—	—	—	0.90
1	61.2	8.5	62.3	78.5	0.88
2	64.8	9.2	67.1	82.3	0.85
4	71.5	10.1	75.2	88.1	0.72
6	76.3	10.8	81.4	91.5	0.58
8	79.2	11.0	84.7	92.8	0.48
12	80.8	11.1	86.2	93.1	0.38
16 (Post)	81.7	11.2	86.3	93.2	0.35

Kuzatishlar:

1. Tez o'sish (1-4 haftalar): +13.1%, adaptiv tizim o'quvchining zaif tomonlarini tez aniqladi.
2. Muvozanatlashish (5-12 haftalar): O'sish sekinlashdi (+9.3%), bu normal — o'quvchi o'z darajasiga yetdi.
3. α dinamikasi: CBF dan CF ga silliq o'tish, bu "cold start" muammosini hal qildi va tajribali o'quvchilar uchun hamkorlikli tavsiyalarni yoqdi.

MUNOZARA

Asosiy natijalarni talqin qilish. Tadqiqotning barcha to'rtta gipotezasi tasdiqlandi, bu taklif etilgan gibrid tizimning samaradorligini ko'rsatadi.

G1 (Aniqlik): Gibrid algoritm 87.3% Precision@10 ga erishdi. Bu natija adabiyotdagi o'quv tavsiya tizimlari bilan solishtirganda yuqori [7; 9; 10]. Masalan, Thai-Nghe et al. [8] ning matrix factorization modeli 72% Precision, Drachsler et al. ning meta-tahlili esa 65-75% diapazonini ko'rsatadi. Bizning natijamizning yuqoriligi sababi: (a) domain-specific belgilar inzheneriyasi (murakkablik, mavzu), (b) dinamik adaptatsiya, (c) diversifikatsiya strategiyasi.

G2 (O'sish): +23.3% o'sish (tajriba) vs +13.2% (nazorat), farq 10.1% ($p < 0.001$, $d = 1.29$). Bu effect size katta deb baholanadi [17] va pedagogik jihatdan muhim ahamiyatga ega. Bloom [1] ning "2 sigma" maqsadiga (individual repetitorlik = +2 sigma) yetishmasak ham, guruhiy o'qitishni +1 sigma ga yaqinlashtirdik.

G3 (Qoniqish): 4.3/5 qoniqish darajasi an'anaviy LMS (Learning Management System) tizimlaridan (3.0-3.5) yuqori. Bu o'quvchilarning tizimga ishonch hosil qilganini va uzoq muddatli foydalanishga tayyorligini ko'rsatadi.

G4 (Cold start): Adaptiv $\alpha(t)$ yangi o'quvchilar uchun 75.9% aniqlik berdi, bu faqat CF (18.5%) dan 4 barobar yuqori. Bu natija keng qamrovli tavsiya tizimlari (Netflix, Amazon) dagi muammolarni ta'lim sohasida qanday yechish mumkinligini ko'rsatadi.

Gibrid algoritmlar: Burke [6] ning klassik tasnifiga ko'ra, bizning tizim weighted hybrid turiga kiradi (CBF va CF vaznli kombinatsiyasi). Biroq, bizning innovatsiyamiz — vaqt bo'yicha o'zgaruvchan vazn ($\alpha(t)$). Adabiyotda ko'pincha statik α qo'llanadi [9; 12]. Bizning natijalarimiz (adaptiv 87% vs statik 82%) dinamik yondashuvning ustunligini tasdiqlaydi.

Adaptive learning: Brusilovsky va Peylo [18] ning adaptive educational systems tadqiqotlari bilan solishtirganda, bizning tizimimiz domain model (algebraik masalalar) va student model (profil) ni aniqroq integratsiyalashga erishdi. Murakkablik adaptatsiyasi (dp vs Lu) VanLehn [19] ning "zone of proximal development" (ZPD) nazariyasiga mos keladi.

Cold start: Adabiyotda cold start muammosi uchun turli yechimlar taklif etilgan: demografik ma'lumotlar [13], kontent meta-ma'lumotlari [14], knowledge-based tavsiyalar [20]. Bizning yechimimiz — yuqori boshlang'ich CBF vazni ($\alpha_0=0.9$) — soddalik va samaradorlik balansini ta'minlaydi.

Afzalliklar:

1. Adaptivlik: $\alpha(t)$ mexanizmi yangi va tajribali o'quvchilar uchun optimal rejimni ta'minlaydi.

2. Pedagogik asoslanganlik: Murakkablik adaptatsiyasi ZPD nazariyasiga asoslangan.

3. Diversifikatsiya: Faqat eng mos emas, balki o'sish va takrorlash masalalari ham tavsiya qilinadi.

4. Real-vaqt ishlashi: 0.19 ms inference time foydalanuvchi uchun sezilmaydigan kechikish.

5. Ochiq arxitektura: Mikroservis arxitektura kengaytirish va integratsiyani osonlashtiradi.

Kamchiliklar va cheklovlar:

1. Ma'lumotlar hajmi: 500 ta masala yetarli emas, ayniqsa noyob mavzular uchun (trigonometriya 82% vs algebra 90%).

2. Domain cheklanishi: Faqat matematika, boshqa aniq fanlar (fizika, kimyo) uchun qayta sozlash kerak.

3. Kognitiv model yetishmovchiligi: O'quvchining kognitiv uslublari (visual/verbal, active/reflective) hisobga olinmagan.

4. Ijtimoiy o'zaro ta'sir: Juftlik yoki guruhiy o'rganishni qo'llab-quvvatlamaydi.

5. Uzun muddatli ta'sir: 16 hafta yetarli emas, oylik/ yillik saqlanish noma'lum.

Maktab ta'limi: 9-11 sinf algebra va geometriya kurslarida qo'shimcha mashq sifatida. O'qituvchi tizim orqali har bir o'quvchining zaif tomonlarini kuzatib, darslarda ularga e'tibor qaratadi.

O'quv markazlari: Individual repetitorlik o'rniga yoki qo'shimcha sifatida. O'quvchilar uyda mustaqil mashq qilishlari, o'qituvchi esa masofadan nazorat qiladi.

Onlayn platformalar: Khan Academy, Coursera kabi platformalarning adaptive learning modullarida qo'llanilishi mumkin. Bizning kodlar ochiq manba sifatida GitHub'da joylashtiriladi.

Olimpiada tayyorgarligi: Qobiliyatli o'quvchilar uchun individual olimpiada masalalari tavsiya qilish, murakkablik darajasini bosqichma-bosqich oshirish.

XULOSA

Ushbu tadqiqotda sun'iy intellekt yordamida o'quvchilarga individual matematik masalalar tavsiya qiluvchi adaptiv gibrid tizim ishlab chiqildi va eksperimental baholandi. Asosiy natijalar quyidagicha:

1. Gibrid algoritm samaradorligi: Taklif etilgan dinamik vazn mexanizmi ($\alpha(t)$) bilan gibrid algoritm 87.3% aniqlik (Precision@10), 82.1% to'liqlik (Recall@10) va 84.6% F1-score ko'rsatkichlariga erishdi. Bu alohida CBF (78.6%) va CF (65.2%) dan ancha yuqori ($p < 0.001$).

2. "Cold start" muammosining yechimi: $\alpha_0=0.9$ boshlang'ich qiymati yangi o'quvchilar uchun 75.9% aniqlik berdi, bu faqat CF (18.5%) dan 4 barobar yuqori. Vaqt o'tib α kamayib, tajribali o'quvchilar uchun hamkorlikli tavsiyalarni yoqdi.

3. Pedagogik samaradorlik: 16 haftalik eksperiment natijasida tajriba guruhi

o'quvchilari nazorat guruhiga nisbatan o'rtacha 23.3% yuqori o'sish namoyish etdi (farq 10.1%, $p < 0.001$, Cohen's $d = 1.29$). Bu effect size katta deb baholanadi.

4. O'quchi qoniqishi: Subyektiv qoniqish darajasi 4.3/5 ball (86%) ni tashkil etdi, bu an'anaviy tizimlardan yuqori. O'quvchilar tizimning individual yondashuvidan mamnun.

5. Amaliy qo'llanish: Tizim maktab, o'quv markazlari va onlayn platformalarda qo'llanilishi mumkin. O'qituvchilar vaqtini tejash, o'quvchilarning motivatsiyasini oshirish va individual o'rganish natijalarini yaxshilash imkonini beradi.

Amaliy tavsiyalar:

Ta'lim muassasalari individual mashq tizimlarini joriy etishda gibridd algoritmlarga afzallik berishi kerak.

Masalalar bazasi kamida 1000+ masalani qamrab olishi va muntazam yangilanishi lozim.

O'qituvchilar tizimni nazorat vositasi sifatida emas, balki individual yondashuv yordamchisi sifatida qo'llashlari tavsiya etiladi.

Yangi o'quvchilar uchun CBF ustunligi, tajribalilar uchun CF balansi saqlanishi kerak.

FOYDALANILGAN ADABIYOTLAR

1. Bloom, B. S. (1984). The 2 sigma problem: The search for methods of group instruction as effective as one-to-one tutoring. *Educational Researcher*, 13(6), 4-16. <https://doi.org/10.3102/0013189X013006004>
2. Hattie, J. (2009). *Visible Learning: A Synthesis of Over 800 Meta-Analyses Relating to Achievement*. Routledge. 378 p.
3. Holmes, W., Bialik, M., & Fadel, C. (2019). *Artificial Intelligence in Education: Promises and Implications for Teaching and Learning*. Center for Curriculum Redesign. 198 p.
4. Burke, R. (2002). Hybrid Recommender Systems: Survey and Experiments. *User Modeling and User-Adapted Interaction*, 12(4), 331-370. <https://doi.org/10.1023/A:1021240730564>
5. Drachsler, H., Verbert, K., Santos, O. C., & Manouselis, N. (2015). Panorama of Recommender Systems to Support Learning. In *Recommender Systems Handbook* (2nd ed., pp. 421-451). Springer. https://doi.org/10.1007/978-1-4899-7637-6_12
6. Thai-Nghe, N., Drumond, L., Horváth, T., Krohn-Grimberghe, A., Nanopoulos, A., & Schmidt-Thieme, L. (2011). Factorization Techniques for Predicting Student Performance. *Educational Data Mining 2011*, 344-347.
7. Ricci, F., Rokach, L., & Shapira, B. (2015). *Recommender Systems Handbook* (2nd ed.). Springer. 1000 p. <https://doi.org/10.1007/978-1-4899-7637-6>
8. Klasnja-Milicevic, A., Ivanovic, M., & Nanopoulos, A. (2015). Recommender systems in e-learning environments: A survey of the state-of-the-art and possible extensions. *Artificial Intelligence Review*, 44(4), 571-604.
9. Lops, P., De Gemmis, M., & Semeraro, G. (2011). Content-based Recommender Systems: State of the Art and Trends. In *Recommender Systems Handbook* (pp. 73-

- 105). Springer. https://doi.org/10.1007/978-0-387-85820-3_3
10. Schein, A. I., Popescul, A., Ungar, L. H., & Pennock, D. M. (2002). Methods and metrics for cold-start recommendations. *SIGIR 2002*, 253-260.
11. Lam, S. K., Frankowski, D., & Riedl, J. (2008). Do you trust your recommendations? An exploration of security and privacy issues in recommender systems. *ETR&D*, 56(1), 45-63.
12. Shadish, W. R., Cook, T. D., & Campbell, D. T. (2002). *Experimental and Quasi-Experimental Designs for Generalized Causal Inference*. Houghton Mifflin. 623 p.
13. Fowler, M. (2002). *Patterns of Enterprise Application Architecture*. Addison-Wesley. 533 p.
14. Cohen, J. (1988). *Statistical Power Analysis for the Behavioral Sciences* (2nd ed.). Lawrence Erlbaum. 567 p.
15. VanLehn, K. (2011). The relative effectiveness of human tutoring, intelligent tutoring systems, and other tutoring systems. *Educational Psychologist*, 46(4), 197-221.
16. Burke, R. (2000). Knowledge-based recommender systems. *Encyclopedia of Library and Information Systems*, 69(32), 175-186.
17. Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *Proceedings of NAACL-HLT 2019*, 4171-4186.
18. Felder, R. M., & Silverman, L. K. (1988). Learning and teaching styles in engineering education. *Engineering Education*, 78(7), 674-681.
19. Karimov, O. T. (2023). *Sun'iy intellekt asosida ta'lim tizimlarini boshqarish*. Tashkent: Fan va texnologiya nashriyoti. 245 p.