DOI: 10.65322/j.srd.05192026.106

UDK 004.8

O‘ZBEK TILI UCHUN TASVIR-TIL MODELLARINI ADAPTIV MOSLASHTIRISHNI MATEMATIK MODELLASHTIRISH

Otakishiyeva G.A., *o‘qituvchi,*
Kompyuter injiniringi kafedrasi,
Sun’iy intellekt va raqamli texnologiyalar fakulteti,
E-mail: gulshanoyotakishiyeva@gmail.com,
Andijon davlat universiteti

Annotatsiya: *Maqolada o‘zbek tilidagi tasvir va matn o‘rtasidagi semantik moslikni aniqlash masalasi adaptiv parametrik optimallashtirish shaklida qo‘yiladi. Tasvir-matn juftligi ishonchliligi, namuna murakkabligi va lotin-kirill yozuvlari muvofiqligini birlashtiruvchi matematik model taklif etiladi. Kontrastiv maqsad funksiyasi yozuvlararo cheklov hamda regulyarizatsiya hadi bilan to‘ldiriladi. Model parametrlarini hisoblash uchun stoxastik gradientga asoslangan sonli usullar va past rangli parametrizatsiya ko‘rib chiqiladi. Yordamchi silliq funksiyaga nisbatan pasayish shartlari bayon qilinadi, adaptiv vaznlarni barqaror hisoblash usuli beriladi. Ikki juftlikli nazorat misolida kontrastiv gradient markaziy chekli ayirmalar bilan tekshirildi; maksimal absolyut tafovut $3{,}35\cdot10^{-11}$ dan kichik bo‘ldi. Natija hisoblash formulasiga tegishli bo‘lib, real korpusdagi aniqlikni ifodalamaydi. Mustaqil baholash protokoli va matematik modelning dasturiy majmuaga integratsiya tamoyillari ishlab chiqiladi.*

Abstract: *This article formulates semantic alignment between images and Uzbek text as an adaptive parametric optimization problem. The proposed mathematical model combines pair reliability, sample difficulty, and consistency between Latin and Cyrillic script variants. A contrastive objective is augmented with a script-consistency term and parameter regularization. Stochastic gradient methods and low-rank parameterization are considered as numerical tools for solving the resulting problem. Descent conditions are stated for an auxiliary smooth objective, and a stable procedure for computing adaptive weights is described. In a two-pair numerical check, the analytical contrastive gradient was compared with central finite differences, yielding a maximum absolute discrepancy below 3.35×10^{-11}. This result validates the calculation at the test point and does not measure performance on a real corpus. An independent evaluation protocol and principles for integrating the model into a software framework are specified.*

Аннотация: *В статье задача семантического согласования изображений и узбекских текстов сформулирована как задача адаптивной параметрической оптимизации. Предлагаемая математическая модель учитывает достоверность пар, сложность примеров и согласованность латинского и кириллического написания. Контрастивная целевая функция дополнена условием согласованности письменностей и регуляризацией параметров. Для численного решения рассматриваются стохастические градиентные методы и низкоранговая параметризация. Сформулированы условия убывания вспомогательной гладкой функции и предложено устойчивое вычисление адаптивных весов. На контрольном примере из двух пар аналитический градиент сопоставлен с центральными конечными разностями; максимальное абсолютное расхождение составило менее $3{,}35\cdot10^{-11}$. Этот результат проверяет формулу в выбранной точке и не характеризует точность на реальном корпусе. Определены протокол независимой оценки и принципы интеграции модели в программный комплекс.*

Kalit so‘zlar: *matematik modellashtirish, tasvir-til modeli, adaptiv optimallashtirish, sonli usullar, kontrastiv mezon, past rangli parametrizatsiya, yozuvlararo moslik.*

Keywords: *mathematical modeling, vision-language model, adaptive optimization, numerical methods, contrastive objective, low-rank parameterization, script consistency.*

DOI: 10.65322/j.srd.05192026.106

Ключевые слова: *математическое моделирование, визуально-языковая модель, адаптивная оптимизация, численные методы, контрастивный критерий, низкоранговая параметризация, согласованность письменностей.*

Kirish. Tasvir-til modeli tasvir va matnni umumiy vektor fazosida ifodalab, ularning semantik yaqinligini hisoblaydi. CLIP yondashuvida bu moslik kontrastiv maqsad funksiyasi yordamida shakllantiriladi [1]. O‘zbekcha matnlarda lotin va kirill yozuvlari, apostrof variantlari hamda so‘z shakllarining xilma-xilligi bitta mazmunning turlicha ifodalanishiga olib keladi. Shu sababli tasvir va matn mosligini yozuv xususiyatlari bilan birgalikda matematik modellashtirish maqsadga muvofiq.

Tadqiqot obyekti tasvir va o‘zbekcha tavsiflardan tashkil topgan multimodal ma’lumotlar to‘plamidir. Tadqiqot predmeti esa bu ma’lumotlarda semantik moslikni ifodalovchi maqsad funksiyasi, uning parametrlarini hisoblash algoritmi va sonli barqarorlik shartlaridan iborat. Yondashuvning asosiy g‘oyasi har bir juftlikning optimallashtirishga ta’sirini uning ishonchliligi va joriy murakkabligi orqali boshqarishdir.

Mavjud yondashuvlar va tadqiqot vazifasi

CLIP tasvir va matn o‘rtasidagi moslikni umumiy vektor fazosida ifodalash uchun kontrastiv mezonni qo‘llaydi [1]. LoRA katta parametr matritsalariga past rangli qo‘shimchalar kiritish orqali moslashtirish masalasining o‘lchamini kamaytiradi [2]. AdamW adaptiv gradient qadamini vaznlar so‘nishidan ajratadi [3]. Ushbu ishlarda keltirilgan umumiy tamoyillar bu maqolada o‘zbekcha tavsiflarning yozuv variantlari va juftliklar ishonchliligi bilan bog‘lanadi.

Tadqiqot metodologiyasi. Ko‘p tilli matn ifodalarini qurish bo‘yicha XLM-R tadqiqoti tillararo umumiy reprezentatsiya imkoniyatlarini ko‘rsatadi [4,5]. Biroq ko‘p tilli matn enkoderining mavjudligi tasvir va o‘zbekcha tavsiflar mosligini avtomatik hal qilmaydi. Shuning uchun bu yerda til komponentini tanlashdan tashqari, multimodal moslik va yozuvlararo muvofiqlikni birgalikda boshqaruvchi mezon taklif etiladi. Maqolada ushbu cheklovlar bitta adaptiv hisoblash sxemasida ifodalanadi.

O‘zbekcha matnlarni ifodalash shartlari

Matnni tokenlarga ajratishda tayanch enkoderga mos tokenizator saqlanadi. SentencePiece kabi usullar so‘z ichidagi birliklar bilan ishlash imkonini beradi [6]. O‘zbekcha qo‘shimchalar sabab bir so‘zning ko‘p tokenlarga bo‘linishi ketma-ketlik uzunligini oshirishi mumkin. Shu bois tokenlar soni, kesib tashlangan tavsiflar ulushi va apostrof variantlari alohida tekshiriladi. Lug‘atni o‘zgartirish zarur bo‘lsa, yangi tokenlar va ularning vektorlarini moslashtirish alohida bosqich sifatida belgilanadi.

Masalaning matematik qo‘yilishi. $D = \{(x_i, y_i, q_i)\}$ juftliklar to‘plami berilgan bo‘lsin. Bu yerda x_i – tasvir, y_i – o‘zbekcha tavsif, $q_i \in (0, 1]$ – ekspert tekshiruvi va ma’lumot yaxlitligi asosida belgilangan ishonchlilik koeffitsiyenti. Bir tasvirga tegishli tavsiflar umumiy identifikator bilan birlashtiriladi. Masala tasvir va matnni bir xil o‘lchamli fazoga akslantiruvchi funksiyalar parametrlarini aniqlashdan iborat.

f va g mos ravishda tasvir hamda matn enkoderlari, P va Q esa proyeksiya operatorlari bo‘lsin. Nol bo‘lmagan chiqishlar birlik norma bo‘yicha normallashtiriladi. Hosil bo‘lgan u_i va v_i vektorlar uchun o‘xshashlik quyidagicha aniqlanadi:

$$u_i = Pf(x_i) / \|Pf(x_i)\|_2,\ v_i = Qg(y_i) / \|Qg(y_i)\|_2,\ s_{ij} = u_i{}^T v_j \qquad (1)$$

Mini-paket hajmi b ga teng va unda har bir tasvir uchun bittadan mos tavsif mavjud deb olinadi. $\tau > 0$ harorat parametri o‘xshashliklar taqsimotining keskinligini boshqaradi. Ikki yo‘nalishli kontrastiv yo‘qotish [1] asosida quyidagi ifoda olinadi:

$$\ell_i = -\tfrac{1}{2} \left[\ln\left(\exp(s_{ii}/\tau) / \sum_{j=1}^{b} \exp(s_{ij}/\tau) \right) + \ln\left(\exp(s_{ii}/\tau) / \sum_{j=1}^{b} \exp(s_{ji}/\tau) \right) \right] \qquad (2)$$

DOI: 10.65322/j.srd.05192026.106

Bir mini-paketda mazmunan teng tavsiflar mavjud bo‘lsa, ular noto‘g‘ri salbiy juftlik sifatidaishlatilmaydi. Bunday holatda barcha tasdiqlangan mos juftliklarni hisobga oluvchi ko‘p musbatli yo‘qotish qo‘llanadi yoki paket shu juftliklarni ajratish orqali shakllantiriladi.

Har bir tasvirga tegishli matnlar obyekt, belgi va fazoviy munosabatlarni yetarlicha aniq ifodalashi talab etiladi. Masalan, “qizil piyola stol ustida” va “qizil piyola stol ostida” tavsiflari bir xil obyektlarni tilga olsa ham, turli vaziyatlarni bildiradi. Shu sababli faqat so‘zlarning ustma-ust kelishiga asoslangan moslik yetarli emas; tasvirda tekshiriladigan munosabatlar ham manfiy juftliklarni tanlashda hisobga olinadi.

Adaptiv maqsad funksiyasi. Har bir k-iteratsiyada namuna vazni $a_i = q_i \exp(-d_i/\sigma_k)$ tarzida belgilanadi. Bunda $d_i \geq 0$ – oldingi iteratsiyalardagi yo‘qotishning cheklangan sirg‘aluvchi o‘rtachasi, $\sigma_k > 0$ – bosqichma-bosqich oshiriladigan murakkablik parametri. Dastlab ishonchli va sodda namunalar katta vazn oladi; σ_k ortganda murakkab namunalarning hissasi oshadi. Vaznlar gradient hisoblanayotganda o‘zgarmas deb olinadi.

$$J_k(\theta) = [\sum_{i=1}^{b} a_i \ell_i / \sum_{i=1}^{b} a_i] + \lambda L_y\ ozuv(\theta) + \mu\|\theta - \theta_0\|_2^2 \qquad (3)$$

bu yerda θ – o‘zgaruvchi parametrlar vektori, θ_0 – uning boshlang‘ich qiymati, λ va μ – manfiy bo‘lmagan koeffitsiyentlar. Lyozuv bir mazmundagi tekshirilgan lotin va kirill tavsiflarining normallashtirilgan vektorlari orasidagi kvadratik masofalarning o‘rtachasidir. Ushbu had yozuv variantlari mosligini, oxirgi had esa parametrlarning boshlang‘ich holatdan chetlanishini nazorat qiladi. λ, μ va σ_k jadvali alohida validatsiya to‘plamida tanlanadi.

Yozuvlararo hadni aniqlash uchun E ekvivalent tavsiflar juftliklari to‘plami kiritiladi. Har bir $(y^a, y^b) \in E$ juftlik bir mazmunning lotin va kirill shaklini bildiradi. Avtomatik transliteratsiya natijasi faqat semantik tengligi tekshirilgach E ga qo‘shiladi. Mazmuni o‘zgargan yoki noaniq juftliklar uchun bu cheklov qo‘llanmaydi.

$$L_y\ ozuv(\theta) = (1 / |E|) \sum_{(a,\beta)\in E} \|v^a - v^b\|_2^2 \qquad (4)$$

bu ifodada $|E| > 0$. Birlik normali vektorlar uchun $0 \leq$ Lyozuv ≤ 4 bo‘ladi: masofa kvadrati bir xil yo‘nalishda nolga, qarama-qarshi yo‘nalishda esa to‘rtga teng. λ haddan tashqari katta tanlansa, tasvirga moslikdan ko‘ra yozuvlar tengligi ustunlashishi mumkin. Shuning uchun bu koeffitsiyent qidiruv sifati bilan birgalikda tekshiriladi.

Adaptiv vaznlarning sonli barqarorligi uchun avval $h_i = \ln(q_i) - d_i/\sigma_k$ hisoblanadi. Normallashtirilgan vaznlar $h_{max} = \max_i h_i$ qiymatini ayirish orqali olinadi:

$$\alpha_i = \frac{exp(h_i - h_{max})}{\sum_{j=1\ldots b} exp(h_j - h_{max})},\ \sum_{i=1\ldots b}\alpha_i = 1 \qquad (5)$$

Mazkur almashtirish (3) dagi vaznli o‘rtachani o‘zgartirmaydi, ammo eksponentalarning umumiy miqyos tufayli nolga yaqinlashishini kamaytiradi. Masalan, teng ishonchlilikdagi ikki namuna uchun $d_1 = 0{,}2$, $d_2 = 1{,}0$ va $\sigma_k = 0{,}5$ olinsa, vaznlar taxminan 0,832 va 0,168 bo‘ladi. $\sigma_k = 2$ bo‘lganda ular 0,599 va 0,401 ga yaqinlashadi. Bu shartli hisob murakkab namuna hissasining qanday ortishini ko‘rsatadi; empirik aniqlik natijasi hisoblanmaydi.

Sonli usul va hisoblash murakkabligi. Masalani yechishda stoxastik gradientga asoslangan sonli usullar qo‘llanadi. Bir iteratsiya vektorlarni hisoblash, o‘xshashliklar matritsasini tuzish, maqsad funksiyasi gradientini topish va parametrlarni yangilashdan iborat. AdamW algoritmi adaptiv qadam va vaznlar so‘nishini alohida boshqaradi [3]. U (3) dagi regulyarizatsiyaning aynan o‘zi emas; ikkala mexanizm ishlatilsa, ularning koeffitsiyentlari alohida qayd etiladi.

DOI: 10.65322/j.srd.05192026.106

Iteratsion algoritmning boshlang‘ich bosqichida θ_0, ishonchlilik koeffitsiyentlari va σ_k jadvali belgilanadi. Har bir mini-paketda avval (1) bo‘yicha vektorlar, keyin (2) bo‘yicha yo‘qotishlar hisoblanadi. Oldingi kuzatuvlardan olingan murakkablik baholari orqali vaznlar aniqlanib, (3) funksiyaning gradienti topiladi. Parametrlar yangilangandan so‘ng joriy yo‘qotishlar murakkablik bahosining keyingi qiymatini hisoblash uchun saqlanadi. Birinchi uchrashuvda namuna murakkabligi umumiy boshlang‘ich qiymat bilan beriladi.

Amaliy realizatsiyada gradient normasi belgilangan chegaradan oshsa, uning yo‘nalishini saqlagan holda uzunligi qisqartiriladi. Harorat uchun $\tau \geq \tau\min > 0$ cheklovi kiritiladi. Bu juda kichik τ sababli hosil bo‘ladigan keskin taqsimot va katta gradientlarni nazorat qilishga xizmat qiladi. Vektor normasi nolga juda yaqinlashganda esa normallashtirish $\max(\|z\|_2, \varepsilon)$ maxraji orqali bajariladi, bunda $\varepsilon > 0$. Hisoblash hajmini kamaytirish uchun LoRA usulidagi $W = W_0 + BA$ parametrizatsiyasi tanlanadi [2]. $W_0 \in R^{mxn}$ o‘zgarmas matritsa, $B \in R^{mxr}$ va $A \in R^{rxn}$ esa hisoblanadigan omillardir. $r \ll \min(m, n)$ bo‘lganda o‘zgaruvchi parametrlar soni mn o‘rniga r(m + n) bo‘ladi. Masalan, m = n = 1024 va r = 8 uchun bu son 1 048 576 dan 16 384 gacha, ya’ni 64 marta kamayadi. Bu bitta matritsa uchun algebraik hisob bo‘lib, umumiy tezlashuvni anglatmaydi.

Vektor o‘lchami d bo‘lsa, paket ichidagi o‘xshashliklar matritsasini hisoblash $O(b^2d)$ amal va $O(b^2)$ xotira talab qiladi. Kichik paketlarda gradientlarni jamlash mumkin, biroq bu usul katta paketdagi barcha salbiy juftliklarni avtomatik tiklamaydi. Maqsad funksiyasi nokonveks bo‘lgani sababli global minimumga erishish kafolatlanmaydi; to‘xtash validatsiya mezonining yaxshilanmasligi va iteratsiyalar chegarasi bilan belgilanadi.

Maqsad funksiyasi xossalari va yaqinlashish shartlari. Modelning normallashtirilgan vektorlari uchun $-1 \leq s_{ij} \leq 1$. Shu sababli b ta elementli paket va $\tau > 0$ sharoitida (2) dagi yo‘qotish $0 \leq \ell_i \leq \ln(b) + 2/\tau$ tengsizlikni qanoatlantiradi. $\lambda, \mu \geq 0$ bo‘lganda maqsad funksiyasi ham manfiy bo‘lmaydi. Biroq quyi chegaraning mavjudligi barcha iteratsiyalarda yo‘qotish kamayishini yoki global minimumga erishishni o‘z-o‘zidan ta’minlamaydi.

Sonli usulni nazariy tahlil qilish uchun vaznlar va paket tarkibi o‘zgarmas bo‘lgan yordamchi F funksiyasi qaraladi. Uning gradienti L-Lipshits uzluksiz bo‘lsin. To‘liq gradientli $\theta_{k+1} = \theta_k - \eta \nabla F(\theta_k)$ qadamida, $0 < \eta \leq 1/L$ sharti ostida, silliq optimallashtirishning pasayish bahosi quyidagicha yoziladi [4]:

$$F(\theta_{k+1}) \leq F(\theta_k) - \frac{\eta}{2} \|\nabla F(\theta_k)\|_2^2 \qquad (6)$$

Agar F quyidan chegaralangan va ushbu shartlar barcha iteratsiyalarda bajarilsa, o‘zgarmas musbat qadam uchun gradient normalari nolga intiladi. Bu statsionarlik xossasi bo‘lib, global minimum kafolati emas. Adaptiv vaznlar, stoxastik paketlar va AdamW qo‘llanganda yordamchi tahlil shartlari avtomatik bajarilmaydi. Shuning uchun (6) to‘liq adaptiv algoritm uchun tayyor yaqinlashish isboti sifatida talqin qilinmaydi.

Amaliy to‘xtash mezoni validatsiya xatosining nisbiy o‘zgarishi, gradient normasining dinamikasi va maksimal iteratsiyalar soniga asoslanadi. Murakkablik jadvali o‘zgarganda maqsad funksiyasi ham o‘zgarishi mumkin; shu bois turli bosqichlardagi xatolar bir xil validatsiya mezoni bilan solishtiriladi. Eng yaxshi validatsiya holatining parametrlari yakuniy hisoblash natijasi sifatida saqlanadi.

Hisoblash tajribasini tashkil etish. Taklif etilgan model bir xil boshlang‘ich parametrlar va hisoblash budjetida doimiy vaznli model bilan solishtiriladi. Adaptiv vaznlash va yozuvlararo had navbatma-navbat chiqarilib, ularning alohida hissasi baholanadi. Ma’lumotlar tasvir identifikatori bo‘yicha parametrlarni aniqlash, validatsiya va yakuniy sinov qismlariga ajratiladi. Bir tasvirning tarjimalari yoki nusxalari turli qismlarga tushmasligi kerak.

Muhokama. Asosiy mezonlar tasvirdan matnni va matndan tasvirni qidirishda Recall@1, Recall@5 hamda Recall@10 ko‘rsatkichlaridir. Hisoblash vaqti, maksimal xotira sarfi va kamida

DOI: 10.65322/j.srd.05192026.106

uchta boshlang‘ich tasodifiy holatdagi natijalar tarqalishi ham qayd etiladi. Lotin, kirill va uzun so‘z shakllari bo‘yicha alohida tahlil yozuvlararo barqarorlikni tekshirishga xizmat qiladi. Tajriba protokolida $\lambda = 0$ holati yozuvlararo hadning, doimiy vaznlar esa adaptiv mexanizmning bazaviy varianti bo‘ladi. Har bir taqqoslashda qolgan shartlar bir xil saqlanadi. Rang r bir necha qiymatda tekshirilib, aniqlik va xotira sarfi o‘rtasidagi bog‘lanish olinadi. Recall@K so‘rovlarning kamida bitta to‘g‘ri mosligi dastlabki K natija ichida uchragan ulushi sifatida hisoblanadi.

Baholashda faqat umumiy o‘rtacha bilan cheklanmasdan, obyekt nomlari, fazoviy munosabatlar va uzun tavsiflar bo‘yicha xatolar ajratiladi. Ishonch oralig‘i so‘rovlar bo‘yicha qayta tanlash orqali baholanishi mumkin; bir tasvirga bog‘liq tavsiflar bitta guruh sifatida qayta tanlanadi. Bu tekshiruv adaptiv vaznlash kam uchraydigan, lekin to‘g‘ri namunalar ta’sirini ortiqcha kamaytirayotgan holatlarni aniqlashga yordam beradi.

Kontrastiv gradientni sonli tekshirish. Kontrastiv qismning dasturiy realizatsiyasini tekshirish uchun ikki juftlikli nazorat misoli olindi. O‘xshashliklar matritsasining satrlari (0,8; 0,2) va (0,1; 0,7), harorat $\tau = 0{,}2$, ishonchliliklar esa teng deb belgilandi. $d = (0{,}2;\ 1{,}0)$ va $\sigma = 0{,}5$ sharoitida normallashtirilgan vaznlar (0,832018; 0,167982) bo‘ldi. Ushbu misol haqiqiy korpus o‘rnini bosmaydi va faqat hisoblash formulasini tekshiradi.

p_{ij} tasvirdan matnga yo‘nalishdagi satr softmax ehtimolligi, r_{ij} esa matndan tasvirga yo‘nalishdagi ustun softmax ehtimolligi bo‘lsin. Vaznlar o‘zgarmas tutilganda kontrastiv qism $C = \Sigma_i \alpha_i \ell_i$ ning o‘xshashlik bo‘yicha hosilasi quyidagicha aniqlanadi:

$$\frac{\partial C}{\partial s_{ij}} = \frac{1}{2\tau}\left[\alpha_i(p_{ij} - \delta_{ij}) + \alpha_j(r_{ij} - \delta_{ij})\right] \qquad (7)$$

δ_{ij} – Kroneker belgisi. float64 aniqlikda hisoblangan vaznli yo‘qotish 0,04329613575 ga teng bo‘ldi. $h = 10^{-6}$ qadamli markaziy chekli ayirmalar bilan taqqoslashda analitik gradientning eng katta absolyut tafovuti $3{,}35 \cdot 10^{-11}$ dan kichik bo‘ldi. Natija kontrastiv qismning ushbu nazorat nuqtasidagi hosilasini tasdiqlaydi; enkoderlarning to‘liq gradienti va real ma’lumotlardagi aniqligi bundan kelib chiqmaydi.

Matematik modelning dasturiy realizatsiyasi. Dasturiy majmuada ma’lumotlar qatlami tasvir identifikatori, tavsif, yozuv turi va ishonchlilikni saqlaydi. Matematik yadro normallashtirish, kontrastiv yo‘qotish, yozuvlararo had va gradientlarni hisoblaydi. Boshqaruv moduli murakkablik jadvali hamda validatsiya bo‘yicha to‘xtashni bajaradi. Hisoblash holati model parametrlari, optimizator momentlari va namuna murakkabliklari bilan birga saqlanadi; faqat model matritsalarini saqlash adaptiv jarayonni aynan davom ettirish uchun yetarli emas.

Natijalarni tekshirish modulida formulalar uchun alohida nazorat misollari, yozuv konversiyasi tekshiruvlari va takrorlanuvchi hisoblash protokoli bo‘lishi ko‘zda tutiladi. Dasturiy interfeys kirish ma’lumotlari versiyasi va model identifikatorini qayd etadi. Qidiruv indeksi yangi proyeksiya parametrlari bilan qayta hisoblanadi; eski indeksni yangi enkoder bilan aralashtirishga yo‘l qo‘yilmaydi.

Adaptiv vaznlashning cheklovi shundaki, katta yo‘qotish har doim noto‘g‘ri belgi yoki past sifatni anglatmaydi. U kam uchraydigan, murakkab, ammo to‘g‘ri namunaga ham tegishli bo‘lishi mumkin. Shu sababli q_i sifat koeffitsiyenti model xatosidan mustaqil belgilanadi, σ_k esa keyingi bosqichlarda bunday namunalarni hisoblashga qaytarishi kerak. Yozuv turi va predmet sohasi bo‘yicha guruhlar ulushi monitoring qilinadi.

Nazariy pasayish bahosi yordamchi funksiyaning silliqlik shartlariga bog‘liq. Real enkoder, adaptiv vaznlar va cheklangan hisoblash budjeti ostida bu shartlar alohida tekshirishni talab etadi. Hisoblangan nazorat misoli algebraik va dasturiy muvofiqlikni ko‘rsatadi, taklifning o‘zbekcha qidiruv sifatiga ta’siri esa mustaqil sinov korpusida baholanishi kerak. Mazkur cheklov modelning nazariy natijalari bilan amaliy samaradorlik da’volarini ajratib turadi.

DOI: 10.65322/j.srd.05192026.106

Xulosa. Matematik modellashtirish natijasida namuna ishonchliligi, murakkabligi va yozuvlararo moslikni yagona maqsad funksiyasida ifodalovchi yondashuv taklif etildi. Past rangli parametrizatsiya hisoblanadigan parametrlar sonini kamaytiradi. Modelning qidiruv aniqligiga ta'siri esa belgilangan hisoblash tajribasi orqali aniqlanishi lozim.

Foydalanilgan adabiyotlar:

1. Radford A. va boshq. Learning Transferable Visual Models From Natural Language Supervision // PMLR. 2021. Vol. 139. P. 8748–8763.

2. Hu E. J. va boshq. LoRA: Low-Rank Adaptation of Large Language Models. 2021. arXiv:2106.09685. https://arxiv.org/abs/2106.09685

3. Loshchilov I., Hutter F. Decoupled Weight Decay Regularization // ICLR. 2019. https://arxiv.org/abs/1711.05101

4. Bottou L., Curtis F. E., Nocedal J. Optimization Methods for Large-Scale Machine Learning. 2018. arXiv:1606.04838. https://arxiv.org/abs/1606.04838

5. Conneau A. va boshq. Unsupervised Cross-lingual Representation Learning at Scale // ACL. 2020. P. 8440–8451.

6. Kudo T., Richardson J. SentencePiece: A simple and language independent subword tokenizer and detokenizer for Neural Text Processing // EMNLP System Demonstrations. 2018. P. 66–71. DOI: 10.18653/v1/D18-2012. https://aclanthology.org/D18-2012/