ISNN 3030-3907

2026
JUNE
ISSUE - 6
VOLUME -5

DEVELOPMENT OF SCIENCE

scientific journal



Development of science

Ilmiy jurnal

IYUN 2026
Issue - 6, VOLUME – 5

ISSN 3030 -3907

Ilmiy jurnal OAK rayosatining 2024 yil 27 sentabrdagi 361-son qaroriga asosan 02.00.00 kimyo fanlari hamda 2025 yil 12 fevral 367- son qaroriga asosan 05.00.00 texnika fanlari bo‘yicha falsafa doktori (PhD) va fan doktori (DSc) ilmiy darajasiga talabgorlarning dissertatsiya ishlari yuzasidan dissertatsiyalari asosiy ilmiy natijalarini chop etish tavsiya etilgan milliy ilmiy nashrlar ro‘yxatiga kiritilgan.

BOSH MUHARRIR:
Temirov Alisher Hoshim o‘g‘li – texnika fanlari falsafa doktori (PhD),Dotsent.
TAHRIRIYAT KENGASH RAISI:
Fozilov Sadriddin Fayzullayevich – texnika fanlari doktori, professor
TAHRIRIYAT KENGASH A’ZOLARI

TEXNIKA FANLARI/ TECHNICAL SCIENCES/ ТЕХНИЧЕСКИЕ НАУКИ

Bozorov G‘ayrat Rashidovich
Buxoro Davlat Texnika Universiteti, professor
Abdurahmonov Olim Rustamovich
Buxoro Davlat Texnika Universiteti, professor
Adizov Bobur Zamirovich
O‘zbekiston Respublikasi Fanlar akademiyasi Umumiy va noorganik kimyo instituti, professor
Hayitov Ruslan Rustamjonovich
Buxoro Davlat Texnika Universiteti, professor
Jumayev Qayum Karimovich
Buxoro Davlat Texnika Universiteti, professor.
Berdiyev Dorob Murodovich
Islom Karimov nomidagi Toshkent Davlat Texnika Universiteti, professor
Maxmudov Rafiq Amonovich
Buxoro Davlat Texnika Universiteti, professor.
Tilloyev Lochin Ismatilloyevich
Buxoro Davlat Texnika Universiteti, dotsent.
Raxmonov Qahramon Sanakulovich
Buxoro Davlat Texnika Universiteti, dotsent.
Barakayev Nusratullo Rajabovich
Islom Karimov nomidagi Toshkent Davlat Texnika Universiteti, professor.
Jo‘rayev Xayrullo Fayziyevich
Buxoro Davlat Texnika Universiteti, professor.
Panoyev Erali Rajabboyevich
Buxoro Davlat Texnika Universiteti, dotsent.
Ataullayev Sherzod Nabiullyevich
Buxoro Davlat Texnika Universiteti, dotsent.
Murodov Malik Negmurodovich
Buxoro Davlat Texnika Universiteti, dotsent.
Axmedova Ozoda Bahronovna
Islom Karimov nomidagi Toshkent Davlat Texnika Universiteti.
Safarov Bahri Jumayevich
Buxoro Davlat Texnika Universiteti, dotsent.
Xaydarov Axtam Amonovich
Buxoro Davlat Texnika Universiteti, dotsent.
Safarov Jasur Alijon o‘g‘li
Buxoro Davlat Texnika Universiteti, dotsent.

KIMYO FANLARI/ CHEMICAL SCIENCES/ ХИМИЧЕСКИЕ НАУКИ

Axmedov Voxid Nizomovich
Buxoro Davlat Texnika Universiteti, professor
Umarov Baqo Bafoyevich
Buxoro Davlat Universiteti, professor
Kodirov Abduaxad Abduraximovich
Qarshi davlat Universiteti, professor
Qurbonov Mingniqul Jumagulovich
Qarshi davlat Universiteti, dotsent
Turemuratov Sharibay Naurizbaevich
O‘zbekiston Respublikasi Fanlar akademiyasi Qoraqalpog‘iston bo‘limi Bosh ilmiy kotibi, professor
Tursunov Kaxor Shonazarovich
Qarshi davlat Universiteti, professor
Do‘stov Hamro
Buxoro Davlat Texnika Universiteti, professor
Panoyev Nodir Shavkatovich
Buxoro Davlat Texnika Universiteti, dotsent.
Olimov Bobur Bahodir o‘g‘li
Buxoro Davlat Texnika Universiteti, dotsent.
Kasimov Sherzod Abduazimovich
Termiz Davlat Universiteti, professor.
Aliqulov Rustam Valiyevich
Termiz Davlat Universiteti, professor
Tropov Xamza Tursunovich
Samarqand Davlat Universiteti, professor

IQTISODIYOT FANLARI/ ECONOMICS/ ЭКОНОМИЧЕСКИЕ НАУКИ

Nizamov Aslitdin Badreddinovich
Buxoro Davlat Texnika Universiteti, professor.
Boboyev Akmal Choriyevich
Buxoro Davlat Texnika Universiteti, professor.
Ergashxojayeva Shaxnoza Djasurovna
Toshkent davlat iqtisodiyot universiteti, professor
Saidaxmedova Nodira Ilxomovna
Toshkent davlat iqtisodiyot universiteti, professor
Muxsinov Bekzod Toxirovich
Buxoro Davlat Texnika Universiteti, dotsent.
Shakarov Qulmat Ashirovich
Renessans ta'lim universiteti,dotsent.
Jumaeva Zulfiya Qayumovna
Buxoro Davlat Texnika Universiteti, dotsent.
Norova Salomat Yusupovna
Buxoro Davlat Texnika Universiteti, dotsent.
Avezova Shaxnoza Maxmudjonovna
Buxoro Davlat Texnika Universiteti, dotsent.
Jalilov Jamshid G‘anijonovich
Toshkent davlat iqtisodiyot universiteti, dotsent
Xasanova Gulruh Djumanazarovna
Buxoro Davlat Texnika Universiteti, dotsent.

PEDAGOGIKA FANLARI/ PEDAGOGICAL SCIENCES / ПЕДАГОГИЧЕСКИЕ НАУКИ

Siddiqova Sadoqat G‘afforovna
Buxoro Davlat Texnika Universiteti, dotsent.
Zoyirov Erkin Xalilovich
Buxoro Davlat Texnika Universiteti, DSc, professor
Gaffarov Feruz Hasanovich
Puchon Universiteti, *professor*
Ruziyev Davron Yuldashevich
Buxoro Davlat Universiteti, professor
Muradova Firuza Rashidovna
Buxoro Davlat Texnika Universiteti, professor.
Yunusova Gulandon Samiyevna
Buxoro Davlat Texnika Universiteti, professor.
To‘xtayeva Zebo Sharifovna
Buxoro Davlat Texnika Universiteti, professor.
Navro‘zova Gulchixra Nigmatovna
Buxoro Davlat Texnika Universiteti, dotsent.
Uzoqova Laylo Polvonovna
Buxoro muhandislik – texnologiya instituti, dotsent.
To‘raqulova Marjona Qiyom qizi
Buxoro Davlat Texnika Universiteti, dotsent.
Muradova Zarina Rashidovna
Buxoro Davlat Texnika Universiteti, dotsent.
Murodov Sanjar Aslonovich
Buxoro Davlat Texnika Universiteti, dotsent.
Shodiyev Jahongir Jo‘raqulovich
Buxoro Davlat Texnika Universiteti, dotsent
Gaffarov Laziz Hasanovich
Buxoro muhandislik – texnologiya instituti, dotsent.

Tahririyat a’zolarning to‘liq ro‘yxati jurnalning www.devos.uz saytida keltirilgan.

Tahririyat hay’ati a’zolarining tarkibini o‘zgartirish hamda qo‘shimcha kiritish yoki tahririyat a’zoligidan chiqarish bosh muharrir tomonidan amalga oshiriladi.

ISSN 3030-3907

Development of science ilmiy jurnali 2024 yil 15 aprel kuni №256445 sonli guvohnoma bilan Davlat ro‘yxatidan o‘tgan.

To‘plam elektron ko‘rinishda (pdf formatida) mualliflarga taqdim etiladi. To‘plamga kiritiladigan maqolalarning mazmuni, ulardagi statistik ma’lumotlar va me’yoriy hujjatlarning to‘g‘riligiga hamda har qanday fikr - mulohazalarga mualliflarning o‘zlari mas’ul hisoblanadilar. Talablarga javob bermaydigan maqolalar to‘plamga kiritilmaydi. Tashkiliy qo‘mita maqola matnini qisqartirish, qisman tuzatish kiritish, seksiyalarga joylashtirish huquqiga ega.

ISSN 3030-3907

МАШИНАЛИ ЎҚИТИШ АЛГОРИТМЛАРИНИ ОПТИМАЛЛАШТИРИШ УСУЛЛАРИ

Юнусов Ғанишер Ғафирович
Бухоро инновациялар университети, Ахборот технологиялари ва амалий фанлар кафедраси профессор в.б., т.ф.н.
Юлдашева Зарина Рахматовна
Бухоро давлат техника университети, магистр

Аннотация. Сўнгги йилларда машинали ўқитиш моделлари мураккаблашиб боргани сари, уларни самарали ўргатиш масаласи бирламчи аҳамиятга эга бўлмоқда. Ушбу мақолада йўқотиш функциясини минималлаштиришга йўналтирилган замонавий оптималлаштириш ёндашувлари қиёсий тарзда ўрганилди. Тадқиқот доирасида биринчи ва иккинчи тартибли градиент усуллари, мослашувчан қадамга эга алгоритмлар (Adam, RMSprop, AdaGrad), регуляризациянинг L1 ҳамда L2 шакллари, шунингдек гиперпараметрларни созлаш стратегиялари кўриб чиқилди. Ўзбек ва рус олимларининг ишлари асосида ҳар бир усулнинг кучли ҳамда заиф жиҳатлари аниқланди, тажрибавий жараёнда тавсия этиладиган танлов мезонлари шакллантирилди.

Калит сўзлар: машинали ўқитиш, оптималлаштириш, градиент тушиш, Adam алгоритми, регуляризация, гиперпараметрлар, нейрон тармоқлар, конвергенция.

Аннотация. В последние годы по мере усложнения моделей машинного обучения задача их эффективного обучения приобретает первостепенное значение. В данной статье в сравнительном плане изучены современные подходы к оптимизации, ориентированные на минимизацию функции потерь. В рамках исследования рассмотрены градиентные методы первого и второго порядка, алгоритмы с адаптивным шагом (Adam, RMSprop, AdaGrad), L1- и L2-формы регуляризации, а также стратегии настройки гиперпараметров. На основе работ узбекских и российских учёных выявлены сильные и слабые стороны каждого метода, сформулированы рекомендуемые критерии выбора в экспериментальном процессе.

Ключевые слова: машинное обучение, оптимизация, градиентный спуск, алгоритм Adam, регуляризация, гиперпараметры, нейронные сети, сходимость.

Abstract. In recent years, as machine learning models have grown more complex, the problem of training them efficiently has become of primary importance. This article presents a comparative study of modern optimization approaches aimed at minimizing the loss function. Within the study, first- and second-order gradient methods, algorithms with an adaptive step size (Adam, RMSprop, AdaGrad), L1 and L2 forms of regularization, as well as hyperparameter tuning strategies were

examined. Based on the work of Uzbek and Russian scientists, the strengths and weaknesses of each method were identified, and recommended selection criteria for the experimental process were formulated.

Keywords: machine learning, optimization, gradient descent, Adam algorithm, regularization, hyperparameters, neural networks, convergence.

1. КИРИШ.

Замонавий рақамли иқтисодиётда сунъий интеллектга асосланган тизимлар, жумладан, машинали ўқитиш моделлари тиббиёт, молия, саноат ва бошқарув тармоқларининг ажралмас қисмига айланди. Шу боис самарали ўргатилган моделнинг бошқа барча халқалар билан бирга ҳал қилувчи аҳамият касб этиши ҳеч кимга сир эмас. Бироқ катта ҳажмдаги маълумотларни ва миллионлаб параметрларни ўз ичига оладиган нейрон тармоқлари ҳозирги пайтда ҳисоблаш ресурсларига нисбатан жуда оч бўлиб қолмоқда.

Айни шу сабабга кўра, оптималлаштириш масаласи нафақат математик, балки амалий-инженерлик нуқтаи назаридан ҳам кенг муҳокама қилинмоқда. Рус олими В.Н. Вапникнинг статистик ўқитиш назариясида таъкидланганидек, ҳар қандай ўқитиладиган алгоритм умумлашган риск функционалини минималлаштиришга йўналтирилган бўлиши керак [1]. Ўз навбатида, ўзбекистонлик тадқиқотчи Ш.А. Назиров эътироф этганидек, ҳозирги шароитда муҳим вазифа — оптималлаштириш усулларини маҳаллий шароитлардаги маълумот қаторига мослаштириш ва ҳисоблаш мураккаблигини камайтириш ҳисобланади [2].

Демак, машинали ўқитиш моделлари самарадорлигини оширишнинг асосий йўли — оптималлаштириш усулларининг танлаб қўлланишидадир. Бу масала сўнгги пайтда халқаро илмий доираларда ҳам, маҳаллий тадқиқотларда ҳам долзарб муаммо сифатида қаралмоқда.

2. ТАДҚИҚОТ МАҚСАДИ ВА ЁНДАШУВИ.

Мазкур илмий иш доирасида қўйилган асосий мақсад — нейрон тармоқларни ва бошқа машинали ўқитиш моделларини ўргатишда қўлланиладиган оптималлаштириш алгоритмларининг қиёсий таҳлилини амалга ошириш ҳамда уларнинг ҳар бирини амалда қачон қўллаш мақсадга мувофиқлигини аниқлашдан иборат.

Қўйилган мақсадга эришиш йўлида қуйидаги вазифалар амалга оширилади:

1) градиент тушиш ва унинг турли модификацияларини математик тавсифлаш;

2) иккинчи тартибли усулларни (Ньютон, квази-Ньютон) ва уларни қўллаш чегараларини ўрганиш;

ISSN 3030-3907

3) Adam, RMSprop ва AdaGrad каби мослашувчан алгоритмларни баҳолаш;

4) регуляризация ёрдамида қайта ўргатилиш муаммосини камайтириш йўлларини кўрсатиш;

5) гиперпараметрларни созлаш стратегияларини умумлаштириш ва тавсиялар тузиш.

Тадқиқот доирасида адабиётларни таҳлил қилиш, математик моделлаштириш ва сифатий қиёслаш каби услублар уйғунликда ишлатилган. Шу билан биргаликда, ҳар бир усул учун конвергенция тезлиги, ҳисоблаш юкламаси ва амалий қўлланилиш чегаралари бўйича мулоҳазалар келтирилади.

3. МУАММОНИНГ ҚЎЙИЛИШИ ВА МЕТОДОЛОГИЯ.

Машинали ўқитишда асосий вазифа қуйидагича шаклланади: маълум маълумотлар тўплами берилганида, моделнинг параметрларини шундай танлаш керакки, йўқотиш функцияси минимал қийматни эгалласин. Бу масалани расмий равишда қуйидаги кўринишда ифодалаш мумкин:

$$L(\theta) = \frac{1}{m} \sum_{i=1}^{m} \ell\big(y_i, f(x_i;\ \theta)\big) \qquad (1)$$

Бу ерда L(θ) — кутиладиган йўқотиш функцияси, m — ўргатиш намуналари сони, ℓ — индивидуал намунавий йўқотиш, f(x; θ) — параметрли модель прогнози, y — ҳақиқий нишон қиймати. Шунга ўхшаш ифода Ю.И. Журавлевнинг намуналарни таниб олиш назариясига оид ишларида ҳам учрайди [3].

Йўқотиш функцияси одатда ноқаварик бўлади, шунинг учун унинг глобал минимумини топиш мураккаб ҳисобланади. Натижада тадқиқотчилар иккита асосий йўналиш бўйича ишлайди: биринчиси — янги оптималлаштириш алгоритмларини яратиш, иккинчиси — мавжудларининг хатти-ҳаракатини математик жиҳатдан таҳлил қилиш. К.В. Воронцов таъкидлаб ўтган йўналишда, классик градиент усулига киритилган ҳар бир янги модификация моделнинг турғунлиги ва тезлиги ўртасидаги мувозанатни ўзгартиради [4].

Шунинг учун ушбу тадқиқотда амалда кенг қўлланилаётган оптималлаштириш ёндашувлари тизимлаштирилади, уларнинг ҳар бири учун формал тавсиф, конвергенция хусусияти ва амалий тавсиялар таклиф этилади.

4. НАТИЖАЛАР ВА УЛАРНИНГ ТАҲЛИЛИ.

4.1. Классик градиент тушиш усули

Энг базавий оптималлаштириш усули — бу пакетли градиент тушиш (Batch Gradient Descent) ҳисобланади. Унинг янгилаш қоидаси қуйидагича:

ISSN 3030-3907

$$\theta_{t+1} = \theta_t - \eta \nabla L(\theta_t) \quad (2)$$

бу ерда η — ўрганиш қадами (learning rate), ∇L(θ_t) — йўқотиш функциясининг градиенти. Усулнинг афзаллиги — ҳар бир қадамда барча намуналардан фойдаланилгани сабабли йўналиш аниқ бўлади. Лекин миллионлаб намуналар билан ишлаганда ҳар қадамда барча маълумотларни қайта ҳисоблаш амалий нуқтаи назардан ўта қиммат. Айнан шу муаммо стохастик усулларнинг пайдо бўлишига сабабчи бўлди.

4.2. Стохастик градиент тушиш (SGD) ва мини-пакет вариантлари

Стохастик градиент тушиш ҳар қадамда битта намунадан, мини-пакетли (mini-batch) усул эса унча катта бўлмаган бир неча намунадан фойдаланади. Битта намуна учун янгилаш қоидаси:

$$\theta_{t+1} = \theta_t - \eta \nabla \ell(y_i, f(x_i; \theta_t)) \quad (3)$$

Я.З. Цыпкиннинг адаптив тизимлар назариясида кўрсатилишича, агар ўрганиш қадами вақт ўтиши билан мос равишда камайтириб борилса, стохастик усул деярли барча реал ҳолатларда локал минимумга яқинлашиш қобилиятига эга бўлади [5]. Ўзбек тадқиқотчилари Т.Ф. Бекмуратов ва М.М. Арипов ўз ишларида ушбу хусусиятдан фойдаланиб, миллий маълумотлар базасида матнни таснифлаш моделини самарали ўргатиш мумкинлигини кўрсатишган [6].

4.3. Импульс (momentum) ёрдамида тезлаштириш

Стандарт SGD кўпинча тор «жарликларда» секинлашиб қолади. Бу муаммони ҳал қилиш учун импульс ёрдамчи ўзгарувчиси киритилади:

$$v_t = \gamma v_{t-1} + \eta \nabla L(\theta_t), \quad \theta_{t+1} = \theta_t - v_t \quad (4)$$

γ коэффициенти одатда 0,9 атрофида танланади. Бу ёндашув эҳтиросли йўналишларни «эслаб қолади» ва тебранишли ҳаракатни сезиларли даражада камайтиради. Натижада конвергенция тезлиги ўртача 2–3 баравар ошади.

4.4. Мослашувчан оптималлаштириш алгоритмлари: Adam

Adam (Adaptive Moment Estimation) усули ҳар бир параметр учун индивидуал ўрганиш қадамини ҳисоблайди. Унинг асосий формулалари қуйидаги кўринишда:

$$m_t = \beta_1 m_{t-1} + (1-\beta_1) g_t, \quad v_t = \beta_2 v_{t-1} + (1-\beta_2) g_t^2 \quad (5)$$

Кейин ҳаракатчан ўртачалар силжишдан халос этилгач, параметрлар янгиланиш қуйидаги тарзда амалга оширилади:

$$\theta_{t+1} = \theta_t - \eta \frac{\hat{m_t}}{\sqrt{\hat{v_t}} + \varepsilon} \quad (6)$$

бу ерда $\beta_1 = 0{,}9$, $\beta_2 = 0{,}999$, $\varepsilon = 10^{-8}$ — одатий қийматлар. Adam ҳозирги пайтда чуқур ўрганишда (deep learning) энг кенг тарқалган танлов ҳисобланиб, у RMSprop ва AdaGrad алгоритмларининг устунликларини ўзида мужассамлаштиради. С.И. Николенко ва унинг ҳаммуаллифларининг

ISSN 3030-3907

чуқур ўрганишга бағишланган изланишларида кўрсатилишича, Adam алгоритми трансформер архитектураларида деярли стандарт ҳисобланади [7].

4.5. Иккинчи тартибли усуллар (Newton, BFGS)

Ньютон усули йўқотиш функциясининг иккинчи тартибли ҳосилаларидан — Гессе матрицасидан фойдаланади:

$$\theta_{t+1} = \theta_t - H^{-1}(\theta_t)\,\nabla L(\theta_t) \qquad (7)$$

Бу ёндашувнинг конвергенцияси квадратик хусусиятга эга, бироқ Гессе матрицасини инверс қилиш ҳисоблаш жиҳатидан жуда қиммат: параметрлар сони n бўлганда мураккаблик O(n³)га тенг. Шу боис амалда квази-Ньютон вариантлари — L-BFGS, BFGS қўлланилади. Совет даври математиги Л.В. Канторович ўзининг оптимал ҳисоб-китоб ишларида айнан шу сингари алгоритмларнинг асосий ғоявий тамойилларини ишлаб чиққан эди [8].

4.6. Регуляризация — қайта ўргатилишга қарши кураш

Қайта ўргатилиш (overfitting) ҳолатида модель ўргатиш маълумотларини ёд олиб қўяди, лекин янги намуналарга умумлашиш қобилияти йўқолади. Бу муаммонинг ечими сифатида йўқотиш функциясига қўшимча жарима термини киритилади. L2-регуляризациянинг (Ridge) ифодаси:

$$L_{reg}(\theta) = L(\theta) + \lambda \sum_{j=1}^{n} \theta_j^{\,2} \qquad (8)$$

L1-регуляризация (Lasso) эса параметрлар модулининг йиғиндисидан фойдаланади:

$$L_{L1}(\theta) = L(\theta) + \lambda \sum_{j=1}^{n} |\theta_j| \qquad (9)$$

Бунда λ — регуляризация коэффициенти. L2 параметрларни нолга яқинлаштирса, L1 параметрлар сонини камайтиради (sparsity) ва шу йўл билан хусусиятларни танлаш функциясини ҳам бажаради. С.А. Айвазянинг кўп ўлчовли статистик таҳлилга оид китобларида айнан ушбу ёндашувлар чуқур таҳлил қилинган [9].

4.7. Ўрганиш қадамини созлаш стратегиялари

Ўрганиш қадами η нинг тўғри танланмаслиги моделнинг кутилмаган хатти-ҳаракатига сабаб бўлади: жуда кичик қиймат конвергенцияни сусайтиради, ҳаддан зиёд катта қиймат эса дивергенцияга олиб келади. Энг кенг тарқалган стратегиялардан бири — қадамни босқичма-босқич камайтириш:

$$\eta_t = \frac{\eta_0}{1 + k \cdot t} \qquad (10)$$

бу ерда k — пасайиш коэффициенти, t — итерация рақами. Бундан ташқари, замонавий тажрибаларда косинус ўхшаш пасайиш (cosine annealing) ҳамда циклик ўрганиш қадами усуллари ҳам кенг қўлланилмоқда. А.Н.

ISSN 3030-3907

Колмогоровнинг функционал кетма-кетликлар назариясига бағишланган ишлари ушбу стратегияларнинг математик асосини шакллантириб берди [10].

4.8. Гиперпараметрларни танлаш ёндашувлари

Гиперпараметрлар — оптимизатор тури, ўрганиш қадами, пакет ҳажми, регуляризация коэффициенти ва бошқа созланувчи қийматлар. Уларни танлаш бўйича кенг қўлланиладиган ёндашувлар: тўла қидирув (grid search), тасодифий қидирув (random search), Байес оптималлаштириши, ҳамда генетик алгоритмлар. Маҳаллий тадқиқотчилар орасида Ш.А. Назиров ва Ф.М. Адилов гиперпараметрларни мослаштириш масалаларида Байесчи ёндашувнинг афзалликларини амалий мисолда тасдиқлаганлар [11].

5. МУҲОКАМА ВА ХУЛОСА.

Олиб борилган қиёсий таҳлил натижасида қуйидаги асосий хулосаларга келиш мумкин. Биринчидан, классик пакетли градиент тушиш усули назарий жиҳатдан энг аниқ йўналишни беради, лекин амалиётда катта маълумотлар билан ишлашда ўз самарасини йўқотади. Иккинчидан, стохастик ҳамда мини-пакетли усуллар тезлик ва аниқлик ўртасидаги муросани таъминлайди ҳамда деярли барча замонавий нейрон тармоқларида асос вазифасини бажармоқда. Учинчидан, мослашувчан алгоритмлар, айниқса Adam, чуқур ўрганишнинг де-факто стандарт ёндашувига айланди.

Шу билан бирга, амалиёт шуни кўрсатдики, ҳар қандай оптимизатор универсал эмас. Айрим тармоқ архитектуралари (масалан, конвербентли (CNN) ва кенг қатламли мукаммаллаштирилган тармоқлар) учун импульс билан тўлдирилган SGD ҳамон сифатли натижалар бермоқда, бошқа ҳолатларда (RNN, трансформерлар) Adam ёки унинг турлари (AdamW, NAdam) устуворлик касб этади. Иккинчи тартибли усуллар эса жуда катта моделларда фойдалилигини йўқотиб, асосан кичик хусусиятли параметрли тизимларда қўлланилади.

Регуляризация бўйича чиқарилган хулоса шундан иборатки, L1 ва L2 жариматерминлари бир-бирини инкор этмайди, балки кўп ҳолларда биргаликда — Elastic Net усули шаклида қўлланилгани муаммони янада самарали ҳал этиш имконини беради. Ўрганиш қадамини босқичма-босқич камайтириш ёки циклик ўзгартириш эса ҳаттоки оддий моделнинг ҳам аниқлигини сезиларли даражада ошириши мумкин.

Гиперпараметрларни танлашда тажрибавий қидирув усуллари (Байес оптималлаштириши, генетик алгоритмлар) тўла қидирувга нисбатан ҳисоблаш ресурсларидан тежамкорроқ фойдаланиш имконини беради. Шунинг учун келажакдаги тадқиқотларда катта эътибор айнан автоматик гиперпараметрлар созлаш (AutoML) йўналишига қаратилиши кутилмоқда.

ISSN 3030-3907

Якуний хулоса сифатида айтиш мумкинки, машинали ўқитиш алгоритмларини оптималлаштириш — фақат бир математик масалани ҳал этиш эмас, балки масала шартлари, маълумотларнинг табиати ҳамда мавжуд ҳисоблаш ресурсларидан келиб чиқиб усулларни тўғри танлаш санъатидир. Маҳаллий шароитда олиб борилаётган тадқиқотларнинг кучайтирилиши, ҳамда халқаро тажрибанинг ўзбекистонлик мутахассислар томонидан мослаштирилиши соҳанинг янада тез ривожланишига имкон беради.

АДАБИЁТЛАР РЎЙХАТИ

1. Vapnik V.N. The Nature of Statistical Learning Theory. – New York: Springer, 2000. – 314 p.
2. Назиров Ш.А. Сунъий интеллект тизимларининг архитектураси ва ишлаш тамойиллари. – Тошкент: Фан, 2019. – 248 б.
3. Журавлёв Ю.И. Избранные научные труды. – М.: Магистр, 1998. – 420 с.
4. Воронцов К.В. Математические методы обучения по прецедентам (теория обучения машин). – М.: МФТИ, 2011. – 141 с.
5. Цыпкин Я.З. Основы теории обучающихся систем. – М.: Наука, 1970. – 252 с.
6. Бекмуратов Т.Ф., Арипов М.М. Интеллектуал тизимларни лойиҳалаш асослари. – Тошкент: Университет, 2018. – 312 б.
7. Николенко С.И., Кадурин А.А., Архангельская Е.В. Глубокое обучение. – СПб.: Питер, 2018. – 480 с.
8. Канторович Л.В. Математические методы организации и планирования производства. – Л.: ЛГУ, 1939. – 68 с.
9. Айвазян С.А. Прикладная статистика и основы эконометрики. – М.: ЮНИТИ, 1998. – 1022 с.
10. Колмогоров А.Н. Избранные труды. Математика и механика. – М.: Наука, 1985. – 470 с.
11. Назиров Ш.А., Адилов Ф.М. Машинали ўқитиш моделларини оптималлаштириш муаммолари // Ўзбекистон ахборот-коммуникация технологиялари журнали. – 2021. – №3. – Б. 45–53.

ISSN 3030-3907