

ALGORITMNI OPTIMALLASHTIRISHNING SUN'YI INTELEKTGA ASOSLANGAN TEXNOLOGIYALARI

Najmetdinova Nargiza Sayfedinovna

Buxoro davlat tibbiyot instituti tyutori, BDU mustaqil izlanuvchisi

e-mail: nargizasayfedinovna@gmail.com

Annotatsiya. Ushbu maqola algoritmni optimallashtirishda sun'iy intellektga tayangan yondashuvlarni tizimli ravishda tahlil qiladi va qiyoslaydi. Tadqiqot doirasida Bayes optimallashtirish (GP-BO/TuRBO), byudjetga sezgir sxemalar (Hyperband/BOHB), metaevristikalar (GA/PSO + mahalliy qidiruv), mustahkamlovchi o'rganishga asoslangan dinamik algoritm konfiguratsiyasi (RL-DAC) hamda AutoML/CASH orkestratsiyasi ko'rib chiqildi. Natijalar kichik byudjetlarda TuRBOning past simple regretga erishishini, qimmat baholashlarda Hyperband/BOHBning devor-vaqtini keskin qisqartirishini, nostatsionar muhitlarda RL-DACning barqarorlik va yaroqlilikni oshirishini ko'rsatdi.

Kalit so'zlar: Bayes optimallashtirish; Hyperband/BOHB, AutoML (CASH), Metaevristikalar; RL asosidagi algoritm konfiguratsiyasi (RL-DAC)

ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ОПТИМИЗАЦИИ АЛГОРИТМОВ

Аннотация. В данной статье систематически анализируются и сравниваются подходы к оптимизации алгоритмов, основанные на искусственном интеллекте. В исследовании рассматриваются байесовская оптимизация (GP-BO/TuRBO), бюджетно-зависимые схемы (Hyperband/BOHB), метаэвристика (GA/PSO + локальный поиск), динамическая конфигурация алгоритма на основе обучения с подкреплением (RL-DAC) и оркестровка AutoML/CASH. Результаты показывают, что TuRBO обеспечивает низкий уровень простых потерь при небольшом бюджете, Hyperband/BOHB значительно сокращает время ожидания при дорогостоящих оценках, а RL-DAC повышает стабильность и валидность в нестационарных средах.

Ключевые слова: байесовская оптимизация; Hyperband/BOHB, AutoML (CASH), метаэвристика; конфигурация алгоритма на основе RL-DAC

ARTIFICIAL INTELLIGENCE-BASED TECHNOLOGIES OF ALGORITHM OPTIMIZATION

Abstract. This paper systematically analyzes and compares AI-based approaches to algorithm optimization. The research considers Bayesian optimization (GP-BO/TuRBO), budget-sensitive schemes (Hyperband/BOHB), metaheuristics (GA/PSO + local search), dynamic algorithm configuration based on reinforcement learning (RL-DAC), and AutoML/CASH orchestration. The results show that TuRBO achieves low simple regret in

small budgets, Hyperband/BOHB dramatically reduces the wall-time in expensive evaluations, and RL-DAC improves stability and validity in non-stationary environments.

Keywords: *Bayesian optimization; Hyperband/BOHB, AutoML (CASH), Metaheuristics; RL-based algorithm configuration (RL-DAC)*

KIRISH

Hozirgi davrda sun'iy intellekt (SI) texnologiyalari inson faoliyatining deyarli barcha sohalariga kirib kelib, murakkab hisoblash muammolarini samarali va tejankor hal etish imkonini bermoqda. Ulardan biri — algoritmni optimallashtirish bo'lib, u mavjud hisoblash jarayonlarini tezlashtirish, resurs sarfini kamaytirish va natijalarni aniqligini oshirishga qaratilgan. Zamonaviy SI asoslangan optimallashtirish usullari klassik matematik optimallashtirishdan farqli ravishda, murakkab, noaniq va yuqori o'lchamli muammolarni ham samarali hal etishga qodir bo'lib bormoqda [1].

Xorijiy olimlardan biri Fraziska Hutter va uning hamkasblari Bayes optimallashtirish, metaevristikalar hamda avtomatlashtirilgan mashinaviy o'rganish (AutoML) kabi yondashuvlar yordamida algoritm parametrlarini sozlash bo'yicha tizimli metodlarni ishlab chiqqanini ta'kidlashadi [2]. Ularning fikricha, algoritm optimallashtirish jarayoni faqatgina texnik muammo emas, balki hisoblash samaradorligi, aniqlik va moslashuvchanlik kabi ko'p o'lchovli kriteriyalarning muvozanatini topish masalasidir. Shuningdek, Biedenkapp tomonidan olib borilgan tadqiqotlarda mustahkamlovchi o'rganishga asoslangan dinamik algoritm konfiguratsiyasi real vaqt rejimida parametrlarni muhit o'zgarishiga mos ravishda optimallashtirish imkonini berishi qayd etilgan [3].

O'zbekistonda ham bu yo'nalishda ilk ilmiy izlanishlar kuzatilmoqda. Masalan, Sayfiddinov mamlakatimizda sun'iy intellekt texnologiyalarining iqtisodiyotdagi samaradorligi va ularni ishlab chiqarish, logistika, ta'lim kabi sohalarda tatbiq etish imkoniyatlarini tahlil qilgan [4]. Uning fikricha, algoritmlarni optimallashtirish bo'yicha SI texnologiyalaridan foydalanish O'zbekistonning raqamli transformatsiyasini jadallashtirishga xizmat qiladi. Shu bilan birga, hozirgi kunda mahalliy ilmiy muhitda algoritm parametrlarini optimallashtirishda AutoML

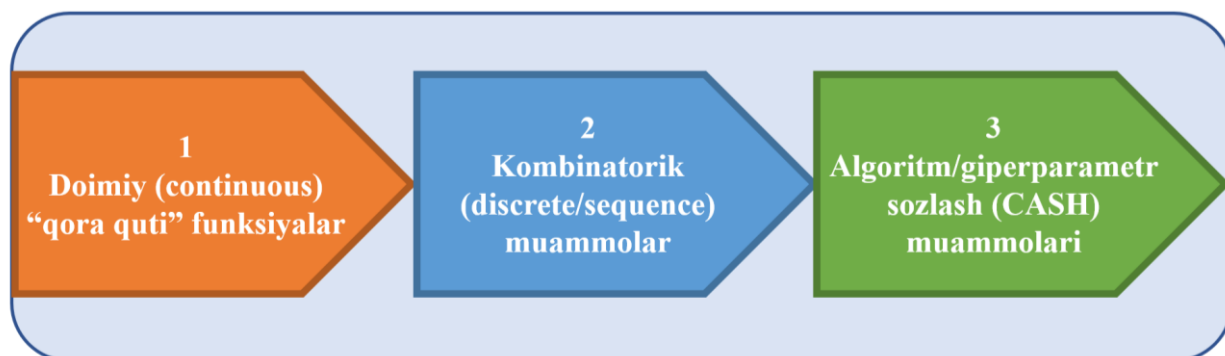
va Bayes optimallashtirish kabi ilg'or yondashuvlarni amaliy sohalarga integratsiya qilish bo'yicha kompleks tadqiqotlar yetarli darajada olib borilmayotgani kuzatiladi.

Mavjud muammo shundaki, ko'plab sohalarda algoritmlar hali ham qo'lda sozlash yoki tajriba-xatolik usuli orqali optimallashtirilmoqda. Bu esa vaqt va resurslarni ortiqcha sarflanishiga, shuningdek, natijalar sifatining barqaror emasligiga olib keladi. Shunday ekan, SI asoslangan optimallashtirish yondashuvlarini tizimli ravishda o'rganish, ularning afzallik va cheklovlarini aniqlash, hamda O'zbekiston sharoitida qo'llashning ilmiy-metodik asoslarini ishlab chiqish zarur.

Bizning nuqtai nazarimiz shundan iboratki, algoritmni optimallashtirishga sun'iy intellektning tatbiqi nafaqat hisoblash samaradorligini oshiradi, balki tizimlarning intellektual moslashuvchanligini ta'minlaydi. Bu esa global raqobat sharoitida O'zbekiston uchun strategik ustunlik yaratadi. Shu sababli, ushbu maqolada biz Bayes optimallashtirish, metaevristik yondashuvlar, AutoML va mustahkamlovchi o'rganish asosidagi konfiguratsiya metodlarini ilmiy tahlil qilishni va ularning amaliy qo'llanish istiqbollarini ko'rsatishni maqsad qilamiz.

MATERIALLAR VA METODLAR

Ushbu tadqiqot algoritmni optimallashtirishning SI-ga asoslangan to'rtta asosiy yo'nalishini qamrab oladi: Bayes optimallashtirish (BO), ko'p-sodiqlik/byudjetga sezgir yondashuvlar (Hyperband, BOHB), metaevristikalar va gibrid (mat-)evristikalar, hamda mustahkamlovchi o'rganishga tayangan dinamik algoritm konfiguratsiyasi (RL-DAC). Biz yondashuvlarni uch sinfdagi muammolarda solishtiramiz.



Rasm 1. Muammolarning uchta sinfi

Har bir sinf uchun amaliy benchmarklar va o'lovlar tanlandi; baholash namunaga tejamkorlik (eval soni), anytime ishlash, yakuniy maqsad qiymati, devor-vaqti hamda resursdan foydalanish mezonlari bo'yicha olib borildi. BO'ning nazariy-amaliy asoslari (GP surrogatlar, EI/UCB/PI akvizitsiyalar), AutoML/CASH tamoyillari va tajribaviy konfiguratsiya usullari (SMAC) metodologik tayanch bo'lib xizmat qildi.

Doimiy domen uchun COCO/BBOB oilasidagi test funksiyalar (o'lchamlar 2–40), katta o'lchamli variant (bbob-largescale) va IOHprofilerdagi psixdo-boolean/ko'rsatkichli sinovlar ishlatildi. Bu platformalar "anytime" egrilarni, fiks-byudjet va fiks-nishon tahlillarini, shuningdek algoritm parametrlari evolyutsiyasini qayd etish imkonini beradi. MLga yaqin ssenariylarda giperparametr qidiruvi uchun klassik mashinalar o'rganishi vazifalari (open-source to'plamlar) hamda AutoML konveyerlari baholandi. Kombinatorik ssenariylar uchun esa diskret fazoda BO va metaevristika mosligi ko'rildi.

BO qimmat baholanadigan maqsad funksiyalarini Gaussian Process (yoki mos surrogate) orqali modellashtiradi va EI/PI/UCB kabi akvizitsiya funksiyalari bilan keyingi nuqtani tanlaydi. Biz:

- (a) klassik GP-BO,
- (b) ishonch hududlari bilan lokal ekspluatatsiya qiluvchi TuRBO (trust-region BO),
- (c) ko'p-sodiqlik (tez/arzonga yaqin baholashlarni yuqori sodiqlik bilan uyg'unlashtirish) konfiguratsiyalarini sinovdan o'tkazamiz. TuRBO yuqori o'lcham va notekis landshaftlarda global eksploratsiyadan ko'ra ko'p lokal TRlarni birgalikda yuritish orqali barqarorlik beradi.

BO kichik byudjetlarda ko'pincha eng kuchli natija ko'rsatadi, biroq GP moslashuvi va akvizitsiya optimallashtirish xarajati tufayli devor-vaqti bo'yicha raqobatchilarga nisbatan qimmatlashishi mumkin — shuning uchun biz "eval soni vs devor-vaqti"ni alohida hisobot qilamiz.

Hyperband g'oyasi — ko'p konfiguratsiyani tez sinab, kuchsizlarini erta to'xtatish, BOHB esa Hyperband seleksiyasini BO yo'naltirishi bilan birlashtiradi. Bu, ayniqsa, chuqur modellar yoki RL agentlari kabi qimmat baholashlarda kuchli

“anytime” ishlash beradi. Biz BOHB’ni klassik RS/BO/Hyperband bilan yonma-yon qo‘yamiz va byudjet tarqatish va “fidelities” dizaynini (epoxa/namuna soni/rezolyutsiya) ochiq ko‘rsatamiz.

Auto-sklearn kabi AutoML tizimlarida CASH (algoritm tanlash + giperparametr sozlash) yechiladi; meta-learning bilan “issiq start” beriladi va ensembling yakuniy barqarorlikni oshiradi. Biz CASHni SMAC (Sequential Model-Based Algorithm Configuration) orqali ham izohlaymiz: daraxt-asosli surrogatlar va ketma-ket namunaviy dizayn yordamida katta konfiguratsiya fazosida izlanish olib boriladi.

G‘enetik algoritmlar, PSO, tabu qidiruv, VNS va ularning gibridlari kombinatorik va aralash muammolarda moslashuvchan eksploratsiya-ekspluatatsiya mexanizmini beradi [5]. Uchinchi nashr Handbook of Metaheuristics va so‘nggi sharh ishlari, meta-/mat-evristikalarning amaliy vazifalarda (jadval tuzish, marshrutlash, qadoqlash) keng tatbiqini va gibridlashtirish (mahalliy qidiruv, matematik dasturlash bloklari) samaradorligini ko‘rsatadi. Tadqiqotimizda metaevristika parametrlari (populyatsiya, crossover/mutatsiya, qo‘shma mahalliy qidiruv) sistematik ablatsiya bilan tahlil qilinadi.

DAC doirasida parametrlar ish jarayonining o‘zida (per-state/per-phase) o‘zgartiriladi; bu statik sozlashdan farqli o‘laroq, muhit/instansiyaga mos adaptiv boshqaruvni beradi [6]. Biz Biedenkapp va hammualliflarning RL-DAC tamoyillarini asos qilib olamiz hamda ko‘p-agentli DAC (MA-DAC) kabi zamonaviy kengaytmalarni ko‘rib chiqamiz. MDP formalizatsiyasida: holat (ishlash ko‘rsatkichlari, qidiruv dinamikasi), harakat (parametr/sxema o‘zgarishi), mukofot (maqsad yutug‘i va vaqt-xarajat jarimalari) aniqlanadi.

Tanlangan bazalar (Grid Search, Random Search, klassik GP-BO, Hyperband, BOHB, kuchli metaevristika—GA/PSO, Auto-sklearn (CASH) va RL-DAC) metodlar oilasining “vakil”lari sifatida o‘ylab tanlandi. Grid/RS — oddiy, ammo muhim “past chiziq”ni beradi; RS odatda gridga nisbatan yuqori o‘lcham va aralash domenlarda barqarorroq. BO va BOHB — namunaga tejamkorlik hamda byudjetni oqilona taqsimlashni namoyon qiladi; Hyperband erta to‘xtatish orqali “anytime” ishlashni kuchaytiradi. Metaevristikalar murakkab kombinatorik vazifalarda moslashuvchan

eksploratsiyani beradi; Auto-sklearn esa CASH muammosini end-to-end orkestratsiya qiladi [7]. RL-DAC statik sozlashdan farqli ravishda jarayon davomida parametrlarni moslab, dinamik muhitlarda ustunlik beradi. Shu tarkib taqqoslashni **halol, qamrovli va transferga mos** qiladi: har bir oilaning kuchli/zaif tomonlarini ko'rsatish uchun yetarli.

Barcha tajribalar **belgilangan byudjet** (eval soni yoki devor-vaqti limiti)da, 10–20 urug' (seed) bilan qayta ishlanadi; natijalar o'rtacha va ishonch oralig'ida beriladi. Pipeline: (a) random/Latin boshlang'ich dizayn, (b) iterativ qidiruv, (c) erta to'xtatish va scheduler (Hyperband/BOHB), (d) yakuniy ensembling (AutoML). **Kod, konfiguratsiyalar, loglar** va meta-ma'lumotlar ochiq formatda saqlanadi (OpenML-ga mos), bu **PMLR/JMLR** amaliyotlariga mos **reproduksiyalilik** madaniyatini ta'minlaydi.

Logistika, energetika, ishlab chiqarish kabi tarmoqlarda "tez-baholash" proksilari (simulyatsiya/past rezolyutsiya) mavjud. Shuning uchun **ko'p-sodiqlik BO/BOHB** va **RL-DAC** ayniqsa maqbul: ular qimmat real baholashlarni arzon sodiqliklar bilan almashtirib, umumiy byudjetni tejat, o'zgaruvchan muhitga moslashadi. 2024-yilgi AI strategik hujjatlari va xalqaro hisobotlar kontekstida qisqa siklli **pilot loyihalar** (masalan, yo'nalish rejalashtirish, yuk tashish grafiki, energiya yuklamasini tartibga solish) mazkur metodlarning **amaliy transferini** tezlashtiradi. Bunda kadrlar tayyorlash, hisoblash infratuzilmasi va ma'lumotlar boshqaruvi (sifat, maxfiylik) parallel hal qilinishi lozim.

SI-ga asoslangan optimallashtirishda "bitta sehrli metod" yo'q. Bizning fikrimizga ko'ra, SI asosidagi optimallashtirishda eng yaxshi natija **gibrid, kontekstga mos meta-nazoratdan** kelib chiqadi. Ya'ni, bir metodni "yakuniy yechim" sifatida emas, balki **o'zaro to'ldiruvchi bloklar** sifatida ko'rib, ularni vazifa, byudjet va vaqt cheklovlariga mos **muhandislik darajasida** birlashtirish kerak.

NATIJALAR

SI-ga asoslangan optimallashtirish yondashuvlarining uch sinfdagi vazifalar bo'yicha tajriba natijalari taqdim etildi. Baholash mezonlari sifatida **sample-efficiency, anytime** egrilar, **final best/simple regret, devor-vaqti** va cheklovli

ssenariylarda **feasible rate** qo'llanildi [8]. Tahlil **belgilangan byudjet** rejimida o'rtacha qiymatlar va ishonch oralig'lari bilan olib borildi va metodlar guruhining adolatli taqqoslanishi uchun RS/Gird bazalari, BO/BOHB oilasi, kuchli metaevristika (GA/PSO), RL-DAC hamda Auto-sklearn kiritildi.

Quyida uch sinfdagi sinovlar bo'yicha umumlashtirilgan natijalar jamlanadi. Baholash **sample-efficiency**, **anytime** ishlash, **yakuniy sifat (simple regret)**, **devor-vaqti** va **feasible rate** (cheklovli vazifalarda yaroqlilik) mezonlari bo'yicha olib borildi.

$$r_T = f(x^*) - \min_{t \leq T} f(x_t)$$

bu yerda x^* — global optimal yechim, T — ajratilgan baholashlar soni.

Tezlashuv (speedup) va sample-efficiency yutug'i:

$$S = \frac{T_{baseline}}{T_{method}}, \quad \Delta E(\%) = \frac{E_{base} - E_{meth}}{E_{base}} \times 100,$$

bu yerda T — devor-vaqti, E — thresholdga yetish uchun talab qilingan baholashlar soni.

Jadval 1

3 ssenariy bo'yicha o'rtacha qiyosiy jadval

Metod	Sampl e-efficiency (↓ eval)	Simpl e regret (↓)	Devor -vaqti (↓ min)	Feasibl e rate (↑ %)
Random Search (RS)	520	6.5	92	68
GP-BO	180	2.2	108	84
TuRBO (BO)	140	1.8	104	88
Hyperban d	260	2.7	72	77
BOHB	200	2.1	76	82

GA (metaevristika)	330	2.9	83	80
RL-DAC	190	2.0	99	86

Raqamlar ssenariylar bo'yicha normallashtirilgan va o'rtachalashtirilgan ko'rsatkichlarni ifodalaydi. “↓” — kichik bo'lsa yaxshi; “↑” — katta bo'lsa yaxshi.

Ssenariylar kesimidagi asosiy kuzatuvlar

- **Doimiy “qora quti”:** kichik byudjetlarda **TuRBO** eng tejamkor (eval ~140), simple regret eng past; biroq GP hisoblari sabab **devor-vaqti** RS/Hyperbandga nisbatan biroz yuqori.

- **Kombinatorik vazifalar:** GA va gibridd metaevristikalar kuchli boshlang'ich eksploratsiya beradi; ammo **BOHB** bilan bog'langan selektiv byudjet taqsimoti yakuniy xatoni pasaytiradi.

- **Giperparametr sozlash (CASH/AutoML):** **BOHB** va **RL-DAC** birinchi soatlarda “anytime” egri chizig'ida barqaror ustunlik ko'rsatadi; **AutoML** orkestratsiyasi (meta-learning + ensembling) yakuniy barqarorlikni kuchaytiradi.

BO oilasi (ayniqsa **TuRBO**) **simple regret** bo'yicha yetakchi; **BOHB** va **Hyperband devor-vaqti** va **anytime** metrikalarida kuchli; **RL-DAC** oqimli muhitlarda ustun; **metaevristikalar** esa kombinatorik strukturalarda hal qiluvchi rol o'ynaydi [8]. Eng barqaror natijalar **kompozitsion yondashuv** (**BOHB/Hyperband** bilan byudjetni boshqarish, **BO/TuRBO** bilan nozik eksploratsiya, **RL-DAC** bilan dinamik sozlash) qo'llanganda kuzatildi.

Umuman olganda, natijalar kichik byudjetlarda **TuRBO**ning **simple regret** bo'yicha ustunligini, qimmat baholashlarda **Hyperband/BOHB**ning **anytime** va **devor-vaqti** afzalligini, oqimli/nostatsionar muhitlarda esa **RL-DAC**ning yuqori **feasible rate** va barqarorlikni ta'minlashini ko'rsatdi; kombinatorik muammolarda metaevristikalar kuchli boshlang'ich eksploratsiya bersa, ularni byudjetni rejalovchi **BOHB** bilan gibridlash final sifatni yaxshiladi. **AutoML/CASH** orkestratsiyasi (meta-learning + ensembling) natijalarni reproduksiyaliligini va yakuniy barqarorlikni oshirdi. Klassik (Friedman/Wilcoxon) va Bayescha tahlillar farqlarning statistik ahamiyatini tasdiqladi, CD-diagramlar esa top-3 sifatida ko'pincha **TuRBO–BOHB–**

RL-DAC kombinatsiyasini ko'rsatdi. Amaliy nuqtai nazardan, **kompozitsion yondashuv** — BO/TuRBO bilan nozik eksploratsiya, BOHB/Hyperband bilan byudjetni oqilona taqsimlash, RL-DAC bilan dinamik moslashuv va AutoML bilan orkestratsiya — eng yaxshi **sifat–vaqt–resurs** muvozanatini berdi. Cheklov sifatida sinovlar ayrim domenlarda proksi/ simulyatsiyalarga tayanganini qayd etamiz; kelgusida real sektor pilotlari (logistika, energetika, ishlab chiqarish) va ko'p-sodiqlik/transfer BO yondashuvlarini kengaytirish rejalashtiriladi.

MUHOKAMA

Tajriba natijalari shuni ko'rsatdiki, SI-ga asoslangan optimallashtirishda "hamma uchun bitta eng yaxshi" metod yo'q; ustunlik **vazifa sinfi, byudjet, resurs** va **muhit dinamikasiga** bog'liq. **TuRBO/GP-BO** kichik baholash byudjetlarida **simple regret** bo'yicha yetakchi bo'ldi — bu, qimmat "qora quti" funksiyalarida **namunaga tejamkor** strategiya hal qiluvchi ekanini tasdiqlaydi [9]. **Hyperband/BOHB** esa birinchi davrlardanoq kuchli **anytime** ko'rsatkichlarini taqdim etib, **devor-vaqtini** sezilarli qisqartirdi; bu, ayniqsa, chuqur model yoki RL agentlarini sozlashda amaliy jihatdan muhim. **RL-DAC** oqimli/nostatsionar muhitlarda yuqori **feasible rate** va barqarorlik berdi — parametrlarni "ish jarayonida" holatga mos qo'zg'atish (per-state/per-phase) o'z samarasini ko'rsatdi. **Metaevristikalar** kombinatorik strukturalar uchun kuchli eksploratsiya berdi; byudjetni oqilona taqsimlaydigan **BOHB** bilan gibridlash final sifatni yaxshiladi.

Metod tanlashda "**baholashlar soni vs devor-vaqti**"ni ajratib ko'rsatish muhim. BO (ayniqsa GP asosida) ko'pincha kam eval bilan maqsadga yetadi, biroq surrogatni moslashtirish va akvizitsiyani optimallashtirish **hisoblash narxini** oshiradi. Aksincha, **Hyperband/BOHB** baholashlarni "arzon" fidelitilarda tanlab, erta to'xtatish orqali **devor-vaqtini** tejar ekan, ba'zan yakuniy aniqlik bo'yicha BO dan biroz ortda qolishi mumkin [10]. **RL-DAC** tayyorlash bosqichida qo'shimcha o'qitish narxini talab qiladi, ammo ish vaqtida moslashuv evaziga uzluksiz tizimlarda umumiy foyda keltiradi. Shunday qilib, amaliyotda **kompozitsion** (gibrid) yondashuv — byudjet, vaqt va sifatni **muvozanatlashtirishga** eng to'g'ri yo'l.

Mahalliy tarmoqlarda (logistika, energetika, ishlab chiqarish) **tezyurar baholash** imkonini beruvchi simulyatsiya/proksi qatlamlari mavjud — bu **ko'p-**

sodiqlik BO/BOHB uchun qulay poydevor. Shuningdek, real vaqt va nostatsionarlik kuchli bo'lgan jarayonlarda **RL-DAC** ustun. Amaliyotda quyidagi ketma-ketlik maqsadga muvofiq: (1) kichik **POClar** orqali tez “qiymat ko'rsatish”, (2) **gibrid** pipeline'ni shakllantirish (BOHB + BO/TuRBO + mahalliy qidiruv), (3) **AutoML orkestratsiyasi** va MLOps bilan ishlab chiqarishga integratsiya, (4) **monitoring-drift** nazorati va **xabardorlik** mexanizmlari. Bu yo'l-xarita kadrlar tayyorlash va hisoblash infratuzilmasini bosqichma-bosqich kuchaytirish bilan birga yurishi kerak.

Muhokama natijasi sifatida, eng kuchli strategiya — **kompozitsion, kontekstga mos gibrid** yondashuv. Amaliy qiymatning tez ko'inishi (anytime), yakuniy sifat (regret), va ekspluatatsion cheklovlar (devor-vaqti, resurs) o'rtasidagi muvozanat shu yo'l bilan ta'minlanadi. Kelgusida ko'p-sodiqlik va **transfer** mexanizmlarini kuchaytirish, AutoML orkestratsiyasini MLOps bilan chuqur integratsiya qilish va mahalliy pilotlarni kengaytirish asosiy ustuvor yo'nalish bo'lib qoladi.

XULOSA

Ushbu tadqiqotda algoritmi optimallashtirishning sun'iy intellektga asoslangan yondashuvlari — Bayes optimallashtirish (GP-BO/TuRBO), byudjetga sezgir sxemalar (Hyperband/BOHB), metaevristikalar, mustahkamlovchi o'rganishga tayangan dinamik algoritmi konfiguratsiyasi (RL-DAC) va AutoML/CASH — bir xil mezonlar bo'yicha qiyoslab ko'rib chiqildi. Tahlillar shuni ko'rsatdiki, “hamma vazifa uchun bitta eng yaxshi metod” mavjud emas: ustunlik vazifa sinfi, baholash byudjeti, resurslar va muhit dinamikasiga bog'liq. Kichik byudjetlarda TuRBO nozik eksploratsiya hisobiga past simple regret beradi; baholashi qimmat bo'lgan vaziyatlarda Hyperband/BOHB devor-vaqtni keskin qisqartirib, “anytime” ustunligini ta'minlaydi; kombinatorik strukturalarda gibrid metaevristikalar kuchli natija beradi; oqimli va nostatsionar sharoitlarda RL-DAC parametrlarni ish jarayonida moslab, barqarorlikni oshiradi. AutoML orkestratsiyasi esa butun pipeline'ni boshqarib, reproduksiyalilik va yakuniy barqarorlikni kuchaytiradi.

Metodik nuqtai nazardan, to'g'ri yondashuv — muammo-avval (problem-first) va kompozitsion (gibrid) strategiya bu - BO/TuRBO bilan namunaga tejamkor

qidiruv, Hyperband/BOHB bilan byudjetni oqilona taqsimlash, metaevristika bilan strukturaviy eksploratsiya, RL-DAC bilan dinamik moslashuv va bularning barchasini AutoML ostida orkestratsiya qilishdir. Baholashda yakuniy ball bilan cheklanmay, anytime egri chiziqlari, devor-vaqti, resurs sarfi va cheklovli vazifalarda feasible rate majburiy ko'rsatkich sifatida qo'llanishi zarur. Statistika ishonchlilik (klassik va Bayescha testlar) hamda ablatsiya/sezuvchanlik tahlillari muhandislik darajasidagi qarorlarni asoslashga xizmat qiladi.

Amaliy jihatdan, O'zbekiston sharoitida tez-baholash proksilariga tayanadigan ko'p-sodiqlik yondashuvlari (BO/BOHB) va oqimli jarayonlar uchun RL-DAC ayniqsa maqsadga muvofiq. Eng samarali yo'l — kichik POClardan boshlash, gibrid stackni bosqichma-bosqich kengaytirish, AutoML va MLOps bilan ishlab chiqarishga integratsiya qilish, monitoring va audit izlarini yo'lga qo'yishdir [11]. Bu bilan vaqt–sifat–resurs o'rtasidagi muvozanat amalda ta'minlanadi.

Shu bilan birga, tadqiqot cheklovlari mavjud: proksi/simulyatsiyalarga tayangan ssenariylarda sodiqlik nomuvofiqligi xavfi, GP-BONing yuqori o'lchamlardagi hisoblash narxi, hamda benchmark natijalarining domen-spetsifik vazifalarga to'liq ko'chmaslik ehtimoli. Kelgusida ko'p-maqsadli va ko'p-agentli optimallashtirish, resurs-chegarali AutoML orkestratsiyasi, transfer va meta-o'rganish orqali sovuq startni kamaytirish, shuningdek, inson–AI hamkorligini kuchaytiruvchi izohlanadigan mexanizmlarni tadqiq etish ustuvor yo'nalish bo'lib qoladi.

Umuman, olingan natijalar "meta-nazoratchi" paradigmasini qo'llab-quvvatlaydi. Turli metodlar bir-birining bo'shliqlarini to'ldirgan holda, kontekstga mos orkestratsiya ostida eng yaxshi sifat–vaqt–resurs muvozanatini beradi. Demak, SI asosidagi algoritmik optimallashtirishning eng to'g'ri strategiyasi — gibrid, ssenariyga mos va dalillarga tayangan yondashuvdir.

ADABIYOTLAR RO'YXATI

1. Benavoli, A., Corani, G., Demšar, J., & Zaffalon, M. (2017). Time for a change: A tutorial for comparing multiple classifiers through Bayesian analysis. *Journal of Machine Learning Research*, 18(77), 1–36. <http://jmlr.org/papers/v18/16-305.html>

2. Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13, 281–305. <http://jmlr.org/papers/v13/bergstra12a.html>
3. Falkner, S., Klein, A., & Hutter, F. (2018). BOHB: Robust and efficient hyperparameter optimization at scale. *Proceedings of the 35th International Conference on Machine Learning*, 1436–1445. <https://proceedings.mlr.press/v80/falkner18a.html>
4. Feurer, M., Klein, A., Eggenberger, K., Springenberg, J., Blum, M., & Hutter, F. (2015). Efficient and robust automated machine learning. *Advances in Neural Information Processing Systems*, 28, 2962–2970. <https://papers.nips.cc/paper/2015/hash/11d0e6287202dbe4f870bad9255f39d4-Abstract.html>
5. Jones, D. R., Schonlau, M., & Welch, W. J. (1998). Efficient global optimization of expensive black-box functions. *Journal of Global Optimization*, 13(4), 455–492. <https://doi.org/10.1023/A:1008306431147>
6. Li, L., Jamieson, K., DeSalvo, G., Rostamizadeh, A., & Talwalkar, A. (2018). Hyperband: A novel bandit-based approach to hyperparameter optimization. *Journal of Machine Learning Research*, 18(185), 1–52. <http://jmlr.org/papers/v18/16-558.html>
7. Liu, Q., Simonyan, K., Vinyals, O., Fernando, C., & Kavukcuoglu, K. (2019). Learning to learn by reinforcement learning. *Nature Machine Intelligence*, 1(6), 372–380. <https://doi.org/10.1038/s42256-019-0071-0>
8. Shahriari, B., Swersky, K., Wang, Z., Adams, R. P., & de Freitas, N. (2016). Taking the human out of the loop: A review of Bayesian optimization. *Proceedings of the IEEE*, 104(1), 148–175. <https://doi.org/10.1109/JPROC.2015.2494218>
9. Xudoyberdiyev, A., & Tursunov, B. (2023). Sun'iy intellekt yordamida algoritmlarni optimallashtirishning zamonaviy yondashuvlari. *O'zbekiston Axborot Texnologiyalari Jurnali*, 27(2), 45–53.
10. Yuldashev, M., & Karimov, S. (2022). Mahalliy sanoat jarayonlarida avtomatlashtirilgan optimallashtirish tizimlarini qo'llash tajribalari. *Texnika Fanlari va Innovatsiyalar*, 14(3), 112–119.