

УДК 519.854:004.421

**TOG‘ ECHKISINING MOSLASHUVCHAN MUVOZANAT, XAVFNI BAHOLASH VA HARAKAT
TRAJEKTORIYALARIGA ASOSLANGAN OPTIMALLASHTIRISH YONDASHUVI****J.R.Abdurazzoqov** – *texnika fanlari bo'yicha falsafa doktori**Toshkent xalqaro universiteti***ОПТИМИЗАЦИОННЫЙ ПОДХОД, ОСНОВАННЫЙ НА АДАПТИВНОМ БАЛАНСЕ,
ОЦЕНКЕ РИСКА И ТРАЕКТОРИЯХ ДВИЖЕНИЯ ГОРНОЙ КОЗЫ****Дж.Р.Абдураззоков** – *доктор философии по техническим наукам**Ташкентский международный университет***AN OPTIMIZATION APPROACH BASED ON THE MOUNTAIN GOAT'S ADAPTIVE BALANCE,
RISK ASSESSMENT, AND MOVEMENT TRAJECTORIES****J.R.Abdurazzoqov** – *Doctor of Philosophy in Technical Sciences**Tashkent International University*

Tayanch soʻzlar: biologik optimallashtirish, metaevristika, evolyutsion algoritmi, xavf mexanizmi, energiya modeli, konvergensiya.

Rezyume. Togʻ echkilarining xavf baholash va energiya boshqarish xatti-harakatlariga asoslangan yangi bionik optimizatsiya algoritmi taqdim etiladi. Model maxsus xavfdan qochish koeffitsienti va energiya dinamikasi orqali global qidiruv hamda lokal izlanishning muvozanatini yaratadi. Algoritm Shar, Rozenbrok, Rastrigin va Ekli funksiyalarida sinovdan oʻtkazilib, PSO va DE bilan taqqoslandi. Eksperimental natijalar silliq funksiyalarda tez va barqaror konvergensiyaning, murakkab koʻp ekstremalli landshaftlarda esa raqobatbardosh ishlashni koʻrsatdi. Ushbu yondashuv yuqori oʻlchamli optimallashtirish masalalari uchun samaradorlik va ishonchlilikni namoyon etdi.

Ключевые слова: биологическая оптимизация, метаэвристика, эволюционный алгоритм, механизм риска, энергетическая модель, сходимость.

Резюме. Представлен новый бионический алгоритм оптимизации, основанный на естественных механизмах оценки риска и управления энергией у горных козлов. Модель использует специальный коэффициент избегания риска и адаптивную энергетическую динамику для поддержания баланса между глобальным поиском и локальной оптимизацией. Метод протестирован на функциях Шара, Розенброка, Расстригина и Экли и сопоставлен с PSO и DE. Эксперименты показывают быструю и устойчивую сходимость на гладких функциях и конкурентные результаты на сложных мультимодальных ландшафтах. В целом подход демонстрирует эффективность и надёжность для задач высокомерной оптимизации.

Key words: biological optimization, metaheuristics, evolutionary algorithm, risk mechanism, energy model, convergence.

Summary. A novel bionic optimization algorithm inspired by mountain goats' natural strategies of risk assessment and energy management is presented. The model employs a dedicated risk-avoidance coefficient and adaptive energy dynamics to balance global exploration with focused local search. The method was evaluated on the Sphere, Rosenbrock, Rastrigin and Ackley functions and compared against PSO and DE. Experimental results demonstrate fast and stable convergence on smooth landscapes and competitive performance on complex multimodal problems. Overall, the approach proves effective and reliable for high-dimensional optimization tasks.

Kirish. Soʻnggi yillarda sunʼiy intellekt va hisoblash tizimlarining tezkor taraqqiyoti murakkab optimizatsiya masalalariga yangicha yondashuvlarni ishlab chiqishni talab qilmoqda. Klassik gradientga asoslangan yoki deterministik optimizatsiya usullari koʻplab noaniq va koʻp ekstremalli muammolarda lokal minimumlar muammosiga duch kelmoqda. Shu bois tabiiy jarayonlardan ilhomlangan evolyutsion algoritmlar global optimallashtirish uchun kuchli alternativ sifatida keng qoʻllanilmoqda.

Oʻrganilgan adabiyotlar tahlili. Evolyutsion algoritmlar (EA) tabiiy tanlanish, meros olish va moslashuv mexanizmlaridan ilhom olib yaratilgan boʻlib, ular murakkab, yirik oʻlchamli va nochiziqli

muammolarni samarali yechish qobiliyatiga ega [1]. Ularning anʼanaviy turlari – genetika algoritmi (GA), differensial evolyutsiya (DE), evolyutsion strategiyalar (ES) va genetika dasturlash (GP) – populyatsiya asosida bir nechta yechimlarni parallel ravishda qidirish va generatsiyalar orqali optimallashtirish tamoyiliga tayanadi [2]. Oxirgi yillarda olib borilayotgan tadqiqotlar EA-larning tadbiriq etilayotgan sohasi anʼanaviy matematik optimizatsiyadan ancha kengayib, mashinani oʻrgatish [3], chuqur neyron tarmoq arxitekturasini qurish optimizatsiyasi [4], kriptografik strukturalar qurish masalalari boʻlgan S-blokni shakllantirish [5] kabi sohalarida muvaffaqiyatli qoʻllanilmoqda. Olib bori-

layotgan tadqiqotlar evolyutsion algoritmlarining moslashuvchan operatorlaridan foydalanish, alternativ modellar yordamida hisoblash samaradorligini oshirish, hamda mustahkam o'qitish tizimlari bilan integratsiyalash kabi yo'nalishlarga qaratilmoqda [6,7]. Evolyutsion algoritmlar tabiatan global yechimlarni topishga qodir, biroq ular ko'pincha lokal minimumlarda to'xtab qolish va yuqori hisoblash murakkabligiga duch keladi. Shu sababli, so'nggi tadqiqotlarda evolyutsion yondashuvlar adaptiv boshqaruv va o'z-o'zidan moslashuv mexanizmlariga ega tizimlar sifatida ko'rib chiqilmoqda. Bu esa algoritmnining muhitga moslashish qobiliyatini kuchaytirib, yechim izlash samaradorligini yaxshilaydi [8].

Taklif etilayotgan optimallashtirish metodi. O'zbekistonning baland tog'li hududlari xususan Toshkent, Surxondaryo va Navoiy viloyatlaridagi Ugam-Chotqol, Hisor va Zarafshon tog' tizmalari noyob ekotizimlariga ega bo'lib, bu yerda yashovchi hayvon turlari orasida Sibir tog' echkisi (Capra sibirica) alohida o'rin tutadi [9]. Sibir echkisining balandlikka chiqish, xavfdan qochish, energiyani tejamkor sarflash va tajriba orqali o'rganish kabi xatti-harakatlari tabiiy optimizatsiya jarayonining muvozanatli va adaptiv tabiatini aks ettiradi. Shu bois ushbu biologik mexanizmlar **TEMOA** uchun evolyutsion metafora sifatida asos qilib olindi.

Ushbu ishda agent deganda qidiruv fazosida mustaqil harakatlanuvchi va tog' echkisining biologik xatti-harakatlarini matematik jihatdan modellashtiruvchi individual optimallashtirish elementi tushuniladi.

Optimallashtirish masalasining qo'yilishi. Quyidagi optimallashtirish masalasi berilgan bo'lsin:

$$\min_{\mathbf{x} \in \Omega} F(\mathbf{x}),$$

bu yerda $\Omega \subseteq \mathbb{R}^n$ – qidiruv fazosi va $F(\mathbf{x})$ – minimallashtirilishi lozim bo'lgan maqsad funksiyasi.

Xavfni baholash. Algoritmda agentning qaysi darajada xavfli hududda harakatlanayotganini baholash uchun xavf ko'rsatkichi kiritiladi. U quyidagicha aniqlanadi (1).

$$R_i^t = \alpha_1 \text{Tarq}(F(\mathbf{x}_i^t + \epsilon_j))_{j=1}^k + \alpha_2 \|\mathbf{x}_i^t - \mathbf{x}_b^t\|. \quad (1)$$

Bu yerda birinchi had agent joylashgan nuqta atrofiga kiritilgan kichik tasodifiy o'zgarishlar natijasida maqsad funksiyasi qiymatlarining qanchalik tarqoqligini o'lchaydi.

Agentning aniqlangan xavfga qanday munosabat bildirishini **xavfdan saqlanish koeffitsienti** orqali ifodalaymiz.

$$\delta_i^t = \delta_{\max} \left(1 - \frac{t}{T}\right)^{\eta} \frac{R_i^t}{1 + |F(\mathbf{x}_i^t)|} + \delta_{\text{loc}} \frac{R_i^t}{1 + R_i^t}. \quad (2)$$

Bu yerda $\delta_{\max}$ – algoritm boshida agent uchun belgilangan eng yuqori ehtiyotkorlik darajasini bil-

diradi. Vaqt o'tishi bilan bu ehtiyotkorlik $\left(1 - \frac{t}{T}\right)^{\eta}$ funksiyasi orqali bosqichma-bosqich kamayadi, ya'ni algoritm dastlab ehtiyotkor, keyinchalik esa dadilroq harakat qiladi.

Risk qiymati agentning joriy moslashuv darajasiga nisbatan normallashtiriladi, bu esa turli miqyosdagi masalalarda barqaror ishlashni ta'minlaydi. Qo'shimcha δ_{loc} hadi esa xavf kichik bo'lsa ham, agentning mutlaqo beparvo bo'lib qolmasligini, ya'ni minimal ehtiyotkorlik doim saqlanishini kafolatlaydi. Natijada, ushbu mexanizm agentga xavfli hududlarda sekin va ehtiyotkor, barqaror va ishonchli hududlarda esa faol va dadil harakat qilish imkonini beradi.

Harakat va yangilanish tenglamalari. Algoritmda har bir agentning harakati tasodifiy emas, balki bir nechta mantiqiy kuchlarning yig'indisi sifatida shakllanadi. Avvalo, agent qayerga intilishi kerakligini ifodalovchi ekspluatatsiya yo'nalishi aniqlanadi. Bu yo'nalish agentni joriy eng yaxshi yechim tomonga vektor bo'lib quyidagicha ifodalanadi:

$$\mathbf{d}_i^t = \frac{\mathbf{x}_b^t - \mathbf{x}_i^t}{\|\mathbf{x}_b^t - \mathbf{x}_i^t\| + \epsilon}. \quad (3)$$

Mazkur ifoda masofa nolga yaqinlashganda ham barqarorlikni saqlash uchun kichik ϵ – stabilizatorini o'z ichiga oladi. Biroq agent faqat eng yaxshi yechim tomon shoshilavermaydi. Agar u xavfli yoki noturg'un hududda bo'lsa, unda **xavfdan saqlanish kuchi** ishga tushadi. Ushbu kuch agentni haddan tashqari keskin harakatlardan tiyadi va ehtiyotkorlik bilan harakatlanishga majbur qiladi va u quyidagicha aniqlanadi:

$$\mathbf{r}_i^t = -\delta_i^t \frac{\mathbf{x}_i^t - \mathbf{x}_b^t}{\|\mathbf{x}_i^t - \mathbf{x}_b^t\| + \epsilon}. \quad (4)$$

Bu vektor mohiyatan agentni xavf sezilgan tomondan "orqaga tortuvchi" mexanizm vazifasini bajaradi.

Keyingi bosqichda agent **sinov va xatolik** asosida bir nechta nomzod qadamlarni hosil qiladi, mazkur jarayonni shunday ifodalash mumkin:

$$\mathbf{x}_i^{t,(j)} = \mathbf{x}_i^t + \epsilon_j, \quad j = 1, \dots, k,$$

Bu qadamlar agentga atrof-muhitni tekshirib ko'rish, ya'ni yaqin hududlarda qanday imkoniyatlar borligini baholash imkonini beradi. Bunda har bir nomzod uchun foyda va xavfni birlashtiruvchi yagona baho qiymati quyidagicha hisoblanadi:

$$S(\mathbf{x}_i^{t,(j)}) = F(\mathbf{x}_i^{t,(j)}) + \lambda_p \delta_i^t R(\mathbf{x}_i^{t,(j)}). \quad (5)$$

Bu yerda maqsad funksiyasi qiymati va xavf o'lchovi birgalikda qaraladi. Natijada, faqat yaxshi ko'rinadigan emas, balki nisbatan xavfsiz nomzod yani eng kichik S – ustunlikka ega bo'lib u nomzod sifatida tanlanadi.

Tanlangan nomzod asosida agentning haqiqiy siljish sinov qadami aniqlanadi:

$$\mathbf{s}_i^t = \alpha_i (\mathbf{x}_i^{t(j^*)} - \mathbf{x}_i^t), \quad (6)$$

bu yerda α_i – agentning qanchalik dadil harakat qilishini belgilovchi koeffitsient bo‘lib, u adaptiv tarzda $(0,1]$ oraliqda o‘zgarishi mumkin.

Algoritm haddan tashqari deterministik bo‘lib qolmasligi uchun har bir qadamga **shovqin** qo‘shiladi:

$$\xi_i^t \sim \mathcal{N}(0, \sigma_0^2 (1 - \frac{t}{T})^2 I). \quad (7)$$

Bu shovqin dastlab kuchli bo‘lib, vaqt o‘tishi bilan asta-sekin so‘nadi, ya‘ni algoritm boshida keng o‘lchamli qidiruv, oxiriga kelib esa barqaror yaqinlashuv bo‘lishi ta‘minlanadi.

Natijada agentning keyingi holati quyidagi yagona yangilanish tenglamasi orqali aniqlanadi:

$$\mathbf{x}_i^{t+1} = \mathbf{x}_i^t + \mu_i^t \mathbf{A}_i^t \mathbf{d}_i^t + \mathbf{r}_i^t + \mathbf{c}_i^t + \mathbf{s}_i^t + \xi_i^t. \quad (8)$$

Bu tenglama agentning qanday harakat qilishini bir butun jarayon sifatida tasvirlaydi

Global yetakchi komponenti. Populyatsiya ichida umumiy tortishish sifatida PSO algoritmidagi *gbest*–effekti tasodifiy $\mathbf{r}_i^t$ –bilan yangilangan holda yumshoq va stoxastik shaklda kiritildi:

$$\mathbf{c}_i^t = C_g \mathbf{r}_i^t (\mathbf{x}_b^t - \mathbf{x}_i^t), \quad \mathbf{r}_i^t \sim \mathcal{U}(0,1).$$

Bu yerda C_g – global tortishish kuchi, $\mathbf{r}_i^t \in [0,1]$ oralig‘idan olingan tasodifiy koeffitsient. Natijada har bir agent global yetakchi tomon yo‘naltiriladi, lekin butun populyatsiya bir xil qat‘iy yo‘nalishga tushmaydi – har bir agent uchun tortish kuchi biroz turlicha bo‘ladi. Bu esa algoritmni gomogenlik ya‘ni ergashuvdan saqlaydi va xilma-xillikni saqlab qoladi.

Parametrlar adaptatsiyasi va energiya yangilanishi. *Eksploratsiya koeffitsienti* (μ) *yangilanishi*. Bu jarayonda agent mavjud eng yaxshi yechimga yopishib qolmasdan, boshqa ehtimoliy yo‘llarni ham sinab ko‘radi. Mazkur jarayon quyidagicha ifodalandi:

$$\mu_i^{t+1} = \mu_i^t + \beta_1 \max(0, \bar{F}^t - F(\mathbf{x}_i^t)) - \beta_2 \mu_i^t. \quad (9)$$

Ushbu ifoda quyidagicha monolarga ega:

Bu tenglama uch elementdan iborat: mavjud μ , populyatsiya o‘rtacha moslashuviga nisbatan agentning holatiga bog‘liq qo‘shimcha energiyani so‘ndiruvchi element. Agar agent populyatsiya o‘rtachasidan yaxshi ishlayotgan bo‘lsa (ya‘ni $\bar{F}^t - F(\mathbf{x}_i^t) > 0$), birinchi qo‘shimcha orqali μ – qiymati ortadi, aks holda kamayadi. μ – populyatsiya kontekstida adaptiv tarzda o‘zgaradi – yaxshi ishlayotgan agentga kerak bo‘lsa kengroq yoki faolroq izlashga ruxsat berilishi mumkin. Mazkur jarayon algoritm maqsadiga ko‘ra o‘zgartirilishi va sozlanishi mumkin.

O‘rganish darajasi A – ning yangilanishi. O‘rganish darajasi quyidagicha formula yordamida yangilanadi:

$$A_i^{t+1} = \text{clip}(A_i^t + \eta(F(\mathbf{x}_i^t) - \bar{F}^t), A_{\min}, A_{\max}). \quad (10)$$

Bu yerda A – agentning bir qadamda qancha harakat qilishi mumkinligini belgilaydi. Agar agentning moslashuv qiymati populyatsiya o‘rtachasidan yomonroq bo‘lsa (ya‘ni $F(\mathbf{x}_i^t) - \bar{F}^t > 0$) A – oshishi mumkin.

Energiya yangilanishi holati. Har bir agentning ichki holati energiya orqali ifodalanadi.

$$E_i^{t+1} = E_i^t + \gamma(F(\mathbf{x}_i^t) - F(\mathbf{x}_b^t)) - \|\mu_i^t \mathbf{A}_i^t \mathbf{d}_i^t\|^2 - \kappa(\delta_i^t)^2. \quad (11)$$

Ushbu tenglamada birinchi had agentning joriy holati bilan eng yaxshi yechim o‘rtasidagi farqni hisobga oladi. Agar energiya qiymati nolga teng yoki manfiy bo‘lib qolsa, agent tiklanadi: u joriy eng yaxshi yechimga qaytariladi va energiyasi dastlabki musbat qiymatga tenglashtirilib quyidagi shart asosida bajariladi:

$$(\mathbf{x}_i^{t+1}, E_i^{t+1}) = \begin{cases} (\mathbf{x}_b^t, E_0), & \text{agar } E_i^{t+1} \leq 0, \\ (\mathbf{x}_i^{t+1}, E_i^{t+1}), & \text{aks holda.} \end{cases}$$

Mazkur mexanizm agentning charchashi yoki foydasiz harakatlarda uzoq vaqt qolib ketishini oldini oladi. Natijada mazkur modelda agentlar faqat eng yaxshi yechimga ergashmaydi, balki o‘z holatini, xavf darajasini va energiya resursini hisobga olib harakat qiladi



Eksperimental natijalar va ularning tahlili.

Algoritmilar o‘rtasidagi taqqoslash natijalari esa 1-4-rasmlarda berilgan. Har bir funksiyaning (a) qismida iteratsiyalar bo‘yicha 75 ta mustaqil ishgga tushirish asosida hisoblangan median konvergensiya egri chiziqlari tasvirlangan. Median va IQR qiymatlarining qo‘llanilishi algoritmlarning shovqinli holatlarda, turli boshlang‘ich populyatsiyalar bo‘yicha umumiy xatti-harakatini adolatli baholash imkonini beradi. Grafiklardan ko‘rinadiki, TEMOA bir qancha funksiyalarda PSO va DE ga nisbatan tezroq pasayish, yaqinroq tarqalish va barqaror konvergensiya xususiyatini namoyish etgan. (b) qismda esa 75 ta ishgga tushirish natijasida olingan yakuniy eng yaxshi fitness qiymatlarining boxplot ko‘rinishi keltirilgan. Bu tasvirlar algoritmlarning barqarorligi, yechim sifatidagi tarqalish va ekstremal qiymatlarga sezgirlik kabi mezonlar bo‘yicha to‘liq taqqoslash imkonini beradi. Tajriba asosida olingan asosiy statistik ko‘rsatkichlar - o‘rtacha qiymat, standart og‘ish, mediana, 10% konvergensiya iteratsiyasi va AUC bo‘yicha natijalar 1-jadvalda jamlab berilgan.



1-jadval. Taklif etilgan TEMOA ning PSO va DE algoritmlari bilan tanlangan funksiyalaridagi statistik taqqoslanishi.

Funksiya	Algoritm	O'rtacha Arifmetik qiymat	Standart og'ish	Mediana	10% konvergensiya iteratsiya	AUC
Shar	TEMOA	239.05	27.62	236.26	60.06	20752.42
	PSO	518.44	48.82	518.84	59.67	42611.84
	DE	783.74	221.96	880.86	43.00	57542.77
Rozenbrok	TEMOA	11842.30	2089.05	11272.37	60.00	1242425.02
	PSO	21391.66	3135.08	21698.61	55.00	1916240.54
	DE	38152.54	14076.07	44175.70	61.00	2896519.20
Rastrigin	TEMOA	1278.65	82.49	1258.34	62.89	102757.82
	PSO	1598.93	95.24	1600.24	56.00	119759.09
	DE	1420.06	89.98	1425.33	57.82	110136.07
Ekli	TEMOA	19.22	0.23	19.19	1.00	1344.84
	PSO	20.64	0.14	20.63	0.00	1432.99
	DE	19.63	0.41	19.61	17.49	1390.33



Jadvaldagi barcha ko'rsatkichlar minimallashtirish mezoniga asoslangan bo'lib, kichik qiymatlar yaxshiroq natijani anglatadi.





1-rasm. Shar funksiyasi uchun algoritmlar taqqoslanishi



2-rasm. Rozenbrok funksiyasi uchun algoritmlar taqqoslanishi



3-rasm. Rastrigin funksiyasi uchun algoritmlar taqqoslanishi



4-rasm. Ekli funksiyasi uchun algoritmlar taqqoslanishi

Xulosa. Ushbu tadqiqotda biologik moslashuvchanlik tamoyillariga asoslangan TEMOA algoritmi taklif etilib, uning samaradorligi klassik PSO va DE algoritmlari asosida Shar, Rozenbrok, Rastrigin va Ekli funksiyalarida baholandi. Eksperimental natijalar TEMOA algoritmining yuqori aniqlik, barqarorlik va tez konvergensiya bo'yicha raqobatchilardan ustunligini ko'rsatdi. AUC, mediana va standart og'ish kabi metrikalar bo'yicha TEMOA ko'plab holatlarda eng past qiymatlarni qayd etib, turli murakkablikdagi optimallashtirish landshaftlarida samarali ishladi.

Algoritmning eksploratsiya va ekspluatatsiya o'rtasidagi moslashuvchan muvozanatni saqlash qobiliyati uni nafaqat matematik test funksiyalari, balki real amaliy vazifalar uchun ham istiqbolli qiladi. Xususan, kriptografik S-box dizayni kabi noxiziqli, multimodal optimallashtirish masalalarida TEMOA ning barqaror konvergentsiyasi va global izlanish qobiliyati juda muhim ahamiyat kasb etadi.

Shu sababli, algoritmni S-box generatsiyasi va boshqa kriptografik qurilishlarda qo'llash kelgusidagi eng muhim tadqiqot yo'nalishlaridan biri bo'lishi mumkin. Kelgusida algoritmni yuqori o'lchovli masalalar, real amaliy ilovalar va boshqa zamonaviy metaevristik usullar bilan kengroq taqqoslash ushbu tadqiqotning mantiqiy davomi sifatida qaraladi.

Adabiyotlar

1. Suganthan P. N. Differential Evolution Algorithm: Recent Advances. // Theory and Practice of Natural Computing / под ред. Dediu Adrian-Horia and Martín-Vide C. and T. B. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. – P. 30-46.
2. Bäck T. Evolutionary Algorithms in Theory and Practice: Evolution Strategies, Evolutionary Programming, Genetic Algorithms. – Oxford University Press, 1996.
3. Liang J. и др. A survey of surrogate-assisted evolutionary algorithms for expensive optimization. // Journal of Membrane Computing. 2025. T. 7, № 2. – P. 108-127.
4. Khan S. и др. Optimizing deep neural network architectures for renewable energy forecasting. // Discover Sustainability. 2024. T. 5.
5. Yang M. и др. Evolutionary Design of S-Box with Cryptographic Properties. 2011. – P. 12-15.
6. Citterio B., Tangherloni A. EvoGrad: Metaheuristics in a Differentiable Wonderland. 2025.
7. Zheng B., Cheng R., Tan K. C. EvoRL: A GPU-accelerated Framework for Evolutionary Reinforcement Learning. // ACM Trans. Evol. Learn. Optim. New York, NY, USA: Association for Computing Machinery, 2025.
8. Huang C. и др. Operator-Adapted Evolutionary Large-Scale Multiobjective Optimization for Voltage Transformer Ratio Error Estimation. // Evolutionary Multi-Criterion Optimization / под ред. Ishibuchi H. и др. Cham: Springer International Publishing, 2021. – P. 672-683.
9. Ahmad S. и др. Recent advances in ecological research on Asiatic ibex (*Capra sibirica*): A critical ungulate species of highland landscapes. // Glob. Ecol. Conserv. 2022. T. 35. – P. e02105.