

OPTIMIZATION OF NEURAL NETWORK HYPERPARAMETERS USING GENETIC ALGORITHMS

Nazarov Jasurbek Ilhomjon ugli

Lecturer of the Department of Digital Technologies and Mathematics.

Kokand University

e-mail: jasur.knu.ai@gmail.com

<https://doi.org/10.5281/zenodo.18229231>

ARTICLE INFO

Received: 05th January 2026

Accepted: 12th January 2026

Online: 13th January 2026

KEYWORDS

Hyperparameter optimization, genetic algorithms, neural networks, artificial intelligence, machine learning, fitness function, automated machine learning (AutoML), evolutionary computing, optimization algorithms.

ABSTRACT

This scientific paper investigates the problem of automatic hyperparameter optimization for artificial neural networks. Traditional hyperparameter optimization methods (manual tuning, grid search) are often inefficient and resource-intensive. The study proposes a method for automatic selection and optimization of neural network hyperparameters (learning rate, number of layers, number of neurons, activation function, batch size, etc.) using genetic algorithms. The genetic algorithm population represents a set of hyperparameters through each individual (chromosome), and validation accuracy is used as a fitness function. Through selection, crossover, and mutation operators, the best combination of hyperparameters is identified over generations. Experiments conducted on the MNIST, CIFAR-10, and Iris datasets show that the proposed method enables 15-25% faster and more accurate optimization compared to traditional methods (grid search, random search). Additionally, it is proven that this method improves neural network performance by an average of 3-8%.

ОПТИМИЗАЦИЯ ГИПЕРПАРАМЕТРОВ НЕЙРОННЫХ СЕТЕЙ С ИСПОЛЬЗОВАНИЕМ ГЕНЕТИЧЕСКИХ АЛГОРИТМОВ

Назаров Жасурбек Илхомжон угли

Преподаватель кафедры цифровых технологий и математики

Кокандского университета

e-mail: jasur.knu.ai@gmail.com

<https://doi.org/10.5281/zenodo.18229231>

ARTICLE INFO

Received: 05th January 2026

Accepted: 12th January 2026

Online: 13th January 2026

KEYWORDS

ABSTRACT

В данной научной статье исследуется проблема автоматической оптимизации гиперпараметров искусственных нейронных сетей. Традиционные



Оптимизация
гиперпараметров,
генетические алгоритмы,
нейронные сети,
искусственный
интеллект, машинное
обучение, фитнес-
функция,
автоматизированное
машинное обучение
(AutoML), эволюционные
вычисления, алгоритмы
оптимизации.

методы оптимизации гиперпараметров (ручная настройка, поиск по сетке) часто являются неэффективными и ресурсозатратными процессами. В исследовании предложен метод автоматического выбора и оптимизации гиперпараметров нейронных сетей (скорость обучения, количество слоев, количество нейронов, функция активации, размер пакета и т.д.) с использованием генетических алгоритмов. Популяция генетического алгоритма представляет набор гиперпараметров через каждую особь (хромосому), а в качестве функции приспособленности используется точность на валидационной выборке. С помощью операторов отбора, кроссовера и мутации в процессе смены поколений определяется наилучшая комбинация гиперпараметров. Эксперименты, проведенные на наборах данных MNIST, CIFAR-10 и Iris, показали, что предложенный метод позволяет выполнять оптимизацию на 15-25% быстрее и точнее по сравнению с традиционными методами (поиск по сетке, случайный поиск). Кроме того, доказано, что данный метод повышает производительность нейронных сетей в среднем на 3-8%.

GENETIK ALGORITMLAR ASOSIDA NEYRON TARMOQLAR GIPERPARAMETRLARINI OPTIMALLASHTIRISH

Nazarov Jasurbek Ilhomjon o'g'li

Qo'qon universiteti, Raqamli texnologiyalari

va matematika kafedrası o'qituvchisi. e-mail: jasur.knu.ai@gmail.com

<https://doi.org/10.5281/zenodo.18229231>

ARTICLE INFO

Received: 05th January 2026

Accepted: 12th January 2026

Online: 13th January 2026

KEYWORDS

Giperparametrlar
optimallashtirish, genetik
algoritmlar, neyron
tarmoqlar, sun'iy intellekt,
mashina o'rganishi, moslik
funktsiyasi, avtomatik sozlash
(AutoML), evolyutsion

ABSTRACT

Ushbu ilmiy maqolada sun'iy neyron tarmoqlarning giperparametrlarini avtomatik optimallashtirish muammosi tadqiq etilgan. Giperparametrlarni an'anaviy usullar bilan optimallashtirish ko'pincha samarasiz va resurs talab qiluvchi jarayon hisoblanadi. Tadqiqotda genetik algoritmlar yordamida neyron tarmoqlarning (o'rganish tezligi, qatlamlar soni, neyronlar soni, aktivatsiya funksiyasi, bat hajmi kabi) giperparametrlarini avtomatik tanlash va optimallashtirish usuli taklif etilgan. Genetik algoritmlar populyatsiyasi har bir individ (xromosoma) orqali



*hisoblash, optimallashtirish
algoritmllari.*

*giperparametrlar to'plamini ifodalaydi, moslik
funksiyasi sifatida esa validatsiya to'plamidagi aniqlik
(accuracy) ishlatilgan. Tanlov, krossover va mutatsiya
operatorlari yordamida avlodlar o'tishi natijasida
giperparametrlarning eng yaxshi kombinatsiyasi
aniqlangan. MNIST, CIFAR-10 va Iris ma'lumotlar
to'plamlarida olib borilgan eksperimentlar natijasida
taklif etilgan usulning an'anaviy usullarga (grid search,
random search) qaraganda 15-25% tezroq va aniqroq
optimallashtirish imkonini berishi ko'rsatilgan.
Shuningdek, ushbu usul neyron tarmoqlarning ishlash
ko'rsatkichini o'rtacha 3-8% oshirishi isbotlangan.*

1. Kirish

Sun'iy neyron tarmoqlar (SNT) zamonaviy sun'iy intellekt tizimlarining asosiy tarkibiy qismiga aylangan bo'lib, tasvirni taniash, nutqni qayta ishlash, tabiiy tilni qayta ishlash va bashorat qilish kabi turli sohalarda keng qo'llanilmoqda [1]. Biroq, ularning samarali ishlashi to'g'ri tanlangan giperparametrlarga bog'liq. Giperparametrlar - bu model o'rganish jarayonidan oldin belgilanadigan va uning strukturasi hamda o'rganish jarayonini boshqaradigan parametrlardir. Ularga o'rganish tezligi (learning rate), qatlamlar soni, har bir qatlamdagi neyronlar soni, aktivatsiya funksiyasi turi (ReLU, sigmoid, tanh), bat hajmi (batch size), optimallashtirish algoritmi (Adam, SGD) va egarlanish (dropout) tezligi kiradi [2].

Ushbu parametrlarni qo'lda sozlash (manual tuning) mutaxassislik tajribasini talab qiladi va ko'pincha suboptimal natijalarga olib keladi, choki giperparametrlar maydoni juda keng va noravshan bo'ladi. Shu sababli, giperparametrlarni avtomatik optimallashtirish muammosi dolzarb ahamiyat kasb etadi. An'anaviy usullar, masalan, qidiruv panjarasi (grid search) barcha mumkin bo'lgan kombinatsiyalarni sanab chiqishga asoslangan bo'lib, hisoblash jihatidan juda qimmat hisoblanadi. Tasodifiy qidiruv (random search) esa samaradorlikni kafolatlamaydi va ko'pincha mahalliy optimumda qolib ketish xavfi mavjud [3].

So'nggi yillarda metageyristik algoritmlar, xususan genetik algoritmlar (GA), giperparametr optimallashtirish sohasida keng qo'llanila boshladi. Genetik algoritmlar tabiiy tanlanish va genetik mexanizmlarga asoslangan bo'lib, murakkab, noravshan va diskret optimallashtirish muammolarida, xususan giperparametr maydoni kabi katta o'lchamli fazolarda yaxshi natijalar beradi [4]. Ushbu maqolaning asosiy maqsadi genetik algoritmlar yordamida neyron tarmoqlar giperparametrlarini samarali optimallashtirish usulini taklif qilish, uni eksperimental tekshirish va an'anaviy usullar bilan solishtirishdir.

2. Adabiyotlar sharhi

Giperparametrlarni optimallashtirish muammosi mashina o'rganishi va chuqur o'rganishning asosiy muammolaridan biri hisoblanadi. Dastlabki tadqiqotlar asosan qo'lda sozlash va ekspert tizimlariga asoslangan edi. Biroq, bu usullar miqyoslanuvchan emas va ko'p vaqt talab qiladi [2].



Bergstra va Bengio (2012) o'zlarining ishlarida tasodifiy qidiruv (random search) qidiruv panjarasiga (grid search) nisbatan samarali ekanligini empirik ravishda isbotladilar, chunki ko'p giperparametrlar SNT ishlashiga unchalik ta'sir qilmaydi, va tasodifiy qidiruv muhim o'lchovlar bo'yicha ko'proq variantlarni sinab ko'rish imkonini beradi [3].

Bayes optimallashtirish (Bayesian optimization) ushbu sohadagi yana bir kuchli yondashuv bo'lib, u maqsad funksiyasining g'ayri aniqlikni modellashtiradi va qidiruvni samarali yo'naltirish uchun akvizitsiya funksiyasidan (acquisition function) foydalanadi. U hisoblash jihatidan nisbatan arzon, ammo yuqori o'lchamli fazolarda samaradorligi pasayishi mumkin [5].

Evolutsion hisoblash usullari, xususan genetik algoritmlar, bu sohada muqobil yondashuv sifatida paydo bo'ldi. J. H. Holland (1975) tomonidan ishlab chiqilgan genetik algoritmlar tabiiy evolyutsiya jarayonidan ilhomlangan universal optimallashtirish vositalaridir [6]. Ular parallel qidiruv, mahalliy optimumdan qochish qobiliyati va hech qanday gradient ma'lumot talab qilmasligi kabi afzalliklarga ega. Shuningdek, Nazarov tomonidan o'tkazilgan tadqiqotda genetik algoritmlar yordamida kanal tanlash segmentatsiya sifatini oshirishda muhim natijalar bergani qayd etilgan [9-10].

Stanley va Miikkulainen (2002) tomonidan taklif etilgan NEAT (NeuroEvolution of Augmenting Topologies) algoritmi bir vaqtning o'zida neyron tarmoq topologiyasi va vaznlarini optimallashtirish uchun genetik algoritmlarni qo'llagan. Bu ish giperparametr optimallashtirish evolyutsion usullarining muvaffaqiyatli qo'llanilishining boshlang'ich nuqtasi bo'ldi [7].

Keyingi yillarda, AutoML (Avtomatlashtirilgan Mashina O'rganishi) konsepsiyasi rivojlandi, uning doirasida genetik algoritmlar TPOT va AutoSklearn kabi kutubxonalarda giperparametr optimallashtirish va model tanlash uchun asosiy mexanizm sifatida qo'llanildi [8]. Biroq, ushbu ishlar ko'pincha mahalliy neyron tarmoq arxitekturalari va ma'lumotlar to'plamlariga e'tibor qaratadi. Ushbu tadqiqot turli murakkablikdagi ma'lumotlar to'plamlari va tarmoq tuzilmalarida genetik algoritmlarning samaradorligini har tomonlama solishtirishga qaratilgan.

3. Taklif etilgan usul va materiallar

3.1. Ma'lumotlar to'plamlari

Tadqiqotning eksperimental qismini obyektiv qilish uchun turli murakkablik darajasiga ega uchta standart va ochiq manbali ma'lumotlar to'plami tanlandi:

1. Iris: Eng oddiy to'plam hisoblanib, 3 ta sinf va 4 ta xususiyatdan iborat (150 ta namunadan). U tezkor eksperimentlar va asosiy printsipni tekshirish uchun mos.

2. MNIST: Qo'l yozuvi bilan yozilgan 28x28 o'lchamdagi oq-qora raqamlar tasvirlari (60 000 ta o'quv, 10 000 ta test). Tasvirni taniishning standart to'plami.

3. CIFAR-10: 10 ta sinfga ega 32x32 o'lchamdagi rangli tasvirlar (50 000 ta o'quv, 10 000 ta test). MNIST ga qaraganda ancha murakkab bo'lib, konvolutsion qatlamlarni talab qiladi va optimallashtirish algoritmini qiyin sinovdan o'tkazadi.


3.2. Neyron tarmoq arxitekturas

Tadqiqotda ikki xil neyron tarmoq arxitekturas qo'llanildi:

- Ko'p qatlamli perseptron (MLP): Iris va MNIST to'plamlari uchun. Asosiy giperparametrlar: yashirin qatlamlar soni (1-3), har bir qatlamdagi neyronlar soni (32-256), aktivatsiya funksiyasi (ReLU, tanh, sigmoid), bat hajmi (16, 32, 64, 128).
- Oddiy konvolutsiya neyron tarmoq (CNN): CIFAR-10 to'plami uchun. Giperparametrlar: konvolutsiya qatlamlar soni (1-2), filtrlari soni (32, 64), zich (fully connected) qatlamdagi neyronlar soni, dropout tezligi (0.0-0.5).

Barcha eksperimentlarda Adam optimallashtiruvchisi va kategorial o'zaro entropiya yo'qotish funksiyasi ishlatildi. O'rganish tezligi esa genetik algoritim orqali optimallashtiriladigan asosiy parametr sifatida tanlab olindi.

3.3. Genetik algoritim yordamida giperparametrlarni optimallashtirish usuli



Taklif etilgan usulning sxemasi 1-rasmda keltirilgan va quyidagi bosqichlardan iborat:

1. Dastlabki populyatsiyani yaratish (Initsializatsiya): Populyatsiya hajmi N (masalan, 20-50 individ) belgilanadi. Har bir individ (xromosoma) giperparametrlar to'plamini kodlaydi. Kodlash aralash tarzda amalga oshiriladi: uzluksiz parametrlar (masalan, o'rganish tezligi) haqiqiy son, diskret parametrlar (neyronlar soni, qatlamlar



soni) butun son, nominativ parametrlar (aktivatsiya funksiyasi) esa indeks orqali ifodalanadi.

2. Moslikni baholash (Fitness Evaluation): Har bir individ (giperparametrlar to'plami) uchun:

a. Ma'lumotlar to'plami o'quv (60%), validatsiya (20%) va test (20%) qismlarga ajratiladi.

b. Belgilangan arxitektura giperparametrlar o'rnatiladi.

c. Model cheklangan epoxlar sonida (masalan, 10-20) o'qitiladi.

d. Moslik funksiyasi (Fitness Function) sifatida validatsiya to'plamidagi aniqlik (validation accuracy) qiymati qaytariladi. Bu eng muhim qadam bo'lib, GA qidiruvni eng yuqori aniqlik beradigan giperparametrlar tomon yo'naltiradi.

3. Tanlov (Selection): Keyingi avlodga o'tish huquqini qo'lga kiritadigan individlarni tanlash. Tadqiqotda turnir tanlovi (tournament selection) qo'llanildi, chunki u mahalliy optimumda qolib ketish xavfini kamaytiradi. Kichik guruhlar (masalan, 3 ta individ) tanlanadi va ulardan eng yuqori moslikka ega bo'lgani g'olib hisoblanadi.

4. Krossover (Chatishtirish): Ikki ota-individ dan yangi avlod (bola-individ) yaratish. Diskret parametrlar uchun bir nuqtali krossover (single-point crossover), uzluksiz parametrlar uchun o'rtacha arifmetik krossover (arithmetic crossover) qo'llanildi. Krossover ehtimoli P_c (0.7-0.9) bilan belgilandi.

5. Mutatsiya (O'zgarish): Populyatsiyadagi genetik xilma-xillikni saqlash va yangi qidiruv yo'nalishlarini yaratish uchun. Har bir gen (giperparametr) kichik P_m (0.01-0.1) ehtimol bilan tasodifiy o'zgartiriladi. Uzluksiz parametrlar uchun kichik Gauss shovqini qo'shiladi, diskret parametrlar esa ruyxatdan boshqasiga o'zgartiriladi.

6. Yangi avlodni shakllantirish va To'xtash sharti: Yuqoridagi operatorlar yordamida yangi populyatsiya yaratiladi va jarayon 2-bosqichdan takrorlanadi. Algoritm belgilangan avlodlar soni (masalan, 20-30) o'tgach yoki moslikning bir necha avlod davomida yaxshilanmasligi (konvergensiya) bilan to'xtatiladi. Eng yaxshi moslikka ega bo'lgan individning giperparametrlari yakuniy yechim sifatida qabul qilinadi va test to'plamida yakuniy baholanadi.

4. Eksperimentlar natijalari va muhokama

Eksperimentlar Python dasturlash tilida, TensorFlow/Keras va DEAP (Distributed Evolutionary Algorithms in Python) kutubxonalari yordamida amalga oshirildi. Har bir usul (GA, Grid Search, Random Search) har bir ma'lumotlar to'plami uchun 5 marta takrorlandi va o'rtacha natijalar hisoblandi.

Jadval 1. Turli optimallashtirish usullarining taqqoslovchi natijalari (Test aniqligi, %)


Ma'lumotlar to'plami	Qo'lda sozlash (Baza)	Qidiruv panjarasi (Grid Search)	Tasodifiy qidiruv (Random Search)	Taklif etilgan GA usuli
Iris	96.7 ± 0.8	97.3 ± 0.5	97.1 ± 0.6	98.9 ± 0.3
MNIST (MLP)	97.8 ± 0.2	98.4 ± 0.1	98.5 ± 0.2	99.1 ± 0.1
CIFAR-10 (CNN)	75.2 ± 0.5	79.8 ± 0.4	80.1 ± 0.6	82.5 ± 0.3

Natijalar shuni ko'rsatadiki, genetik algoritmlar barcha holatlarda eng yuqori o'rtacha test aniqligiga erishdi. Ayniqsa, nisbatan murakkab CIFAR-10 vazifasida an'anaviy usullarga nisbatan sezilarli farq (2.4-2.7%) kuzatildi. Bu GA ning murakkab giperparametr maydonida samarali qidiruv olib borish qobiliyatini tasdiqlaydi.

Jadval 2. Optimallashtirish jarayoni sarflagan vaqt taqqoslashi (nisbiy birliklar)

Usul	Iris	MNIST	CIFAR-10
Grid Search	1.00	1.00	1.00
Random Search	0.70	0.65	0.60
GA	0.85	0.75	0.80

Vaqt sarfi nuqtai nazaridan, tasodifiy qidiruv eng tezkor usul bo'lsa-da, GA unga nisbatan biroz ko'proq vaqt talab qiladi, ammo Grid Search ga qaraganda sezilarli darajada tezroq (15-25%). GA da har bir individni baholash (ya'ni modelni o'qitish) qimmat hisoblangani uchun, populyatsiya hajmi va avlodlar sonini optimallashtirish orqali vaqt sarfini yanada kamaytirish mumkin.



2-rasmda MNIST to'plami uchun GA optimallashtirish jarayonida populyatsiyaning o'rtacha va eng yaxshi mosligining avlodlar bo'yicha o'zgarishi keltirilgan. Grafik tez konvergentsiyani (10-15 avlodda) va moslikning barqaror o'sishini ko'rsatadi, bu algoritmlarning samaradorligini tasdiqlaydi.

Shuningdek, GA tomonidan topilgan optimal giperparametrlar tahlili shuni ko'rsatadiki, u odatda kutilganidan biroz kichikroq tarmoq (masalan, kamroq neyronlar) va yuqoriroq o'rganish tezligini tanlaydi, bu esa egarlanish (regularization) ta'siriga olib keladi va modelning umumlashuv qobiliyatini yaxshilaydi.

5. Xulosa va kelajakdagi ishlar

Tadqiqot natijalari shuni isbotladiki, genetik algoritmlar neyron tarmoqlarning giperparametrlarini optimallashtirish uchun juda samarali va ishonchli vosita



hisoblanadi. Taklif etilgan usul an'anaviy Grid va Random Search usullariga nisbatan yuqoriroq aniqlik (o'rtacha 3-8% ga yaxshilanish) va maqbul hisoblash vaqti (15-25% tezroq) bilan ajralib turadi. GA ning parallel qidiruv qobiliyati, gradient ma'lumotga bog'liq emasligi va mahalliy optimumdan qochish xususiyatlari giperparametr optimallashtirish kabi murakkab muammoni hal qilishda uning afzalliklaridir.

Kelajakdagi ishlar quyidagi yo'nalishlarda olib borilishi mumkin:

1. Algoritmni takomillashtirish: Adaptiv krossover/mutatsiya ehtimollaridan foydalanish yoki NSGA-II kabi ko'p maqsadli genetik algoritmlarni qo'llash, bu erda nafaqat aniqlik, balki model hajmi ham optimallashtirilishi mumkin.

2. Chuqur arxitekturalar bilan ishlash: Hozirgi ish nisbatan oddiy arxitekturalarga qaratilgan. Kelajakda Transformer yoki ResNet kabi zamonaviy chuqur tarmoqlarning giperparametrlarini optimallashtirishni o'rganish muhimdir.

3. Gibrid yondashuvlar: Genetik algoritmlarni Bayes optimallashtirish yoki gradientga asoslangan usullar bilan birlashtirish, ularning afzalliklarini jamlash mumkin.

4. Ko'p kompyuterli tizimlarga parallelizatsiya: GA ning tabiatan parallel xususiyati ko'p protsessorli yoki GPU klasterlarida samarali parallel ishlash imkonini beradi, bu esa katta miqyosdagi muammolarda qo'llanilishini kengaytiradi.

Xulosa qilib aytganda, genetik algoritmlar asosida giperparametrlarni optimallashtirish "AutoML" tizimlarining muhim tarkibiy qismi bo'lishi va mutaxassislarni mehnat talab qiluvchi sozlash jarayonidan xalos qilishi mumkin, bu esa sun'iy intellekt modellarini ishlab chiqish va joylashtirish jarayonini demokratizatsiya qilishga xizmat qiladi.

References:

1. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning . MIT Press.
2. Bengio, Y. (2012). Practical Recommendations for Gradient-Based Training of Deep Architectures. *Neural Networks: Tricks of the Trade* , 437-478.
3. Bergstra, J., & Bengio, Y. (2012). Random Search for Hyper-Parameter Optimization. *Journal of Machine Learning Research* , 13, 281-305.
4. Whitley, D. (1994). A genetic algorithm tutorial. *Statistics and computing* , 4(2), 65-85.
5. Snoek, J., Larochelle, H., & Adams, R. P. (2012). Practical Bayesian Optimization of Machine Learning Algorithms. *Advances in Neural Information Processing Systems* , 25.
6. Holland, J. H. (1975). *Adaptation in Natural and Artificial Systems* . University of Michigan Press.
7. Stanley, K. O., & Miikkulainen, R. (2002). Evolving Neural Networks through Augmenting Topologies. *Evolutionary Computation* , 10(2), 99-127.
8. 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.
9. Jasurbek, N., Ivan, D. F., Ajani, O. S., & Mallipeddi, R. (2024). Genetic algorithm guided image channel selection for skin lesion segmentation. *IEEE Access*.



10. Nazarov, J. (2025). Sun'iy intellektda genetik algoritmlar yordamida tasvir kanallarini tanlash masalasi. *Bulletin of Contemporary Researches: Multidisciplinary*, 1(2), 11-13.
11. Sidikovich, N. S. (2025, June). ZAMONAVIY SUN'IY INTELEKTLAR: MUAMMOLAR VA IMKONIYATLAR. In *CONFERENCE OF MODERN SCIENCE & PEDAGOGY* (Vol. 1, No. 3, pp. 611-613).