

SUN'IY INTELLEKTDa OPTIMALLASHTIRISH USULLARINING MATEMATIK MODELLASHTIRILISHI

Axmedova Feruza G'ayrat qizi

axmedovaferuza2004@gmail.com

Yo'ldashev Javohir Rasulbek o'g'li

Yuldashevjavohir2405@gmail.com

O'zMU Jizzax filiali, Amaliy matematika fakulteti talabalari

Xoljigitov Dilmurod Xolmurod o'g'li

Ilmiy rahbar, O'zMU Jizzax filiali katta o'qituvchisi

Annotatsiya: Ushbu maqolada sun'iy intellekt (AI) modellarini o'qitish jarayonida ishlatiladigan optimallashtirish usullari matematik jihatdan tadqiq qilinadi. Gradient descent va uning variatsiyalari, Newton va quasi-Newton metodlari hamda genetik algoritmlar kabi populyar metodlar solishtiriladi. Muhim e'tibor global minimumga yaqinlashish, lokal minimumlardan chiqish, konvergensiya tezligi va hisob resurslaridan foydalanish samaradorligiga qaratiladi. Maqola optimallashtirish metodlarining afzalliklari va kamchiliklarini ko'rsatadi hamda "gibrid" yondashuv orqali optimal yechim taklif etadi.

Kalit so'zlar: Sun'iy intellekt, neyron tarmoqlar, optimallashtirish algoritmlari, gradient descent, Newton metodi, genetik algoritmlar, matematik modellashtirish, konvergensiya, global minimum, adaptiv learning rate, loss funksiyasi, hisob samaradorligi.

Kirish: Sun'iy intellekt-sohasi so'nggi o'n yil ichida sezilarli darajada kengaydi; ayniqsa neyron tarmoqlar (neural networks) va chuqur o'rganish (deep learning) algoritmlari ko'plab vazifalarda — kompyuter ko'rishi, nutqni tanish, tabiiy tilni qayta ishlash kabi sohalarda yuqori natijalar ko'rsatmoqda. Biroq, ushbu modellarning samaradorligi ularni o'qitish (training) jarayonidagi optimallashtirish usullariga bog'liq. Ayniqsa, yo'qotish (loss) funksiya minimallashtirishida qo'llaniladigan optimallashtirish algoritmlarining tanlovi va sozlanishi modelning aniqligi, o'qitish tezligi va umumiy hisob resurslaridan foydalanish samaradorligini belgilaydi.

Gradient descent — birinchi tartibli optimallashtirish usuli sifatida eng ko'p ishlatiladi. Stokastik gradient descent (SGD), learning rate, momentum, Nesterov, Adagrad, RMSProp, Adam kabi o'zgaruvchan versiyalari mavjud. Masalan, "Survey of Optimization Algorithms in Modern Neural Networks" maqolasida gradient asosidagi birinchi tartibli metodlar, shuningdek adaptiv learning rate va moment (momentum) parametrlarining roliga katta e'tibor qaratilgan.

Ikkinchi tartibli metodlarga Newton metodi va quasi-Newton metodlari kiradi. Bu metodlarda yo‘qotish funksiyasining egiligi (curvature) — Hessian matritsasi orqali — hisobga olinadi, bu esa gradient descent’ga nisbatan kamroq iteratsiyalar bilan konvergensiya erishish imkonini beradi. Biroq ular ko‘proq hisob resurslarini talab qiladi, ayniqsa tarmoq parametrlari soni katta bo‘lganda.

Genetik algoritmlar esa optimallashtirishning butunlay boshqa paradigmasini taklif qiladi: ular gradient ma’lumotini talab qilmaydi, balki populyatsiya asosida “evolyutsiya” printsipida ish yuritadi. Mashina o‘qitishda genetik algoritmlar neyron tarmoq arxitekturasini va vaznlar (weights) inicializatsiyasini optimallashtirishda ishlatiladi. Masalan, “Evolving Deep Convolutional Neural Networks for Image Classification” maqolasida genetik algoritmlar arxitektura va vazn boshlang‘ich qiymatini tanlashda qo‘llanilib, tasnif xatoligi (classification error) kamaytirilgan.

Muammolar: Gradient descent usullari lokal minimumlarga, “saddle points”ga yoki gradientlarning yo‘qolishi (vanishing gradient) muammolariga duch keladi.

Newton va quasi-Newton metodlari uchun Hessian matritsasini hisoblash yoki inversini olish xarajatli bo‘lishi mumkin, ayniqsa katta neyron tarmoqlarda.

Genetik algoritmlar va boshqa evolyutsion/yagona-populyatsiya metodlarida eksploratsiya (izlov) va ekspluatatsiya (foydalanish) o‘rtasida muvozanatni saqlash qiyin; hisoblash vaqti yuqori bo‘ladi.

Gibrid yondashuvlar: masalan, Genetically-Modified Wolf Optimization kabi algoritmlar gradient descent va genetik algoritmlar komponentlarini birlashtiradi.

ESGD (Evolutionary Stochastic Gradient Descent) — bu yerda SGD bosqichlari bilan evolyutsion algoritmlar almashinadi, shunda populyatsiyadagi “individuallar” turli hyperparametrlar bilan tanlanadi va eng yaxshisi tanlanadi.

Adaptive optimizers (masalan, Adam, RMSProp) learning rate’ni moslashtirish orqali gradientga asoslangan metodlarning kamchiliklarini kamaytiradi.

So‘nggi yillarda sun‘iy intellekt tizimlari uchun samarali o‘qitish usullarini ishlab chiqish masalasi tobora dolzarb bo‘lib bormoqda. Ayniqsa, chuqur o‘rganish (Deep Learning) arxitekturalarining murakkablashuvi natijasida model parametrlarining soni milliardlab bo‘lishi mumkin, bu esa optimallashtirish jarayonini ancha murakkablashtiradi. Shunday sharoitda matematik modellashtirish yondashuvlari, ya’ni yo‘qotish funksiyasining (loss function) sirtini tahlil qilish, gradientning yo‘nalishini aniqlash va konvergensiya tezligini matematik asosda baholash muhim ahamiyat kasb etadi.

Optimallashtirish jarayonida asosiy maqsad — modelning xatolik funksiyasini minimal darajaga tushirishdir. Ammo bu funksiya ko‘p o‘lchovli, notekis va ko‘plab lokal minimumlarga ega bo‘lgan sirt ko‘rinishidadir. Shuning uchun oddiy gradient descent kabi klassik yondashuvlar ba’zan global minimumga emas, balki lokal minimumda “tiqilib qolish” holatlariga olib keladi. Shu sababli ilmiy tadqiqotlarda

yangi matematik yondashuvlar — momentum, Nesterov gradientlari, adaptiv learning rate (Adam, RMSProp, Adagrad) kabi usullar ishlab chiqildi. Ular gradientning yoʻnalishidagi oʻzgarishlarni dinamik boshqarish orqali modelni tezroq va barqarorroq oʻqitishga imkon beradi.

Xulosa

Sunʼiy intellekt tizimlarida optimallashtirish usullarining toʻgʻri tanlanishi modelning oʻqitilish tezligi, aniqligi va barqarorligini belgilovchi asosiy omillardan biridir. Tadqiqot davomida gradient descent va uning adaptiv versiyalari, Newton hamda genetik algoritmlar matematik jihatdan tahlil qilinib, ularning har biri oʻziga xos afzallik va cheklolarga ega ekani aniqlandi. Birinchi tartibli metodlar hisoblash jihatdan tejamkor, ammo lokal minimumlarda toʻxtab qolishi mumkin; ikkinchi tartibli metodlar esa tezroq konvergensiyaning taʼminlaydi, biroq katta hisoblash resurslarini talab qiladi.

Shuningdek, genetik va boshqa evolyutsion algoritmlar gradientga bogʻliq boʻlmagan holda yechimlarni topishda samarali ekani isbotlandi. Shunday qilib, maqola natijalari shuni koʻrsatadiki, amaliy sunʼiy intellekt tizimlarida gibridd optimallashtirish yondashuvlari — yaʼni gradient asosidagi va evolyutsion usullarni birlashtirish — eng maqbul yechim hisoblanadi. Bu yondashuv nafaqat hisob samaradorligini oshiradi, balki global minimumga yaqinroq natijaga erishish imkonini beradi.

Foydalanilgan adabiyotlar

1. Kingma, D. P., & Ba, J. (2015). *Adam: A Method for Stochastic Optimization*. Proceedings of the 3rd International Conference on Learning Representations (ICLR).
<https://arxiv.org/abs/1412.6980>
2. Rudner, S. (2017). *An Overview of Gradient Descent Optimization Algorithms*. arXiv preprint.
<https://arxiv.org/abs/1609.04747>
3. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. (AI optimallashtirish algoritmlarining nazariy asoslari haqida asosiy manba)
4. Nocedal, J., & Wright, S. J. (2006). *Numerical Optimization (2nd ed.)*. Springer Science & Business Media. (Matematik modellashtirish va Newton metodlari boʻyicha fundamental manba)
5. Goldberg, D. E. (1989). *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley. (Genetik algoritmlar nazariyasi uchun asosiy klassik manba)
6. Mirjalili, S. (2019). *Evolutionary Algorithms and Neural Networks: Theory and Applications*. Springer. (Evolutsion hisoblash va AI integratsiyasi haqida zamonaviy tadqiqot)

7. Bottou, L. (2012). *Stochastic Gradient Descent Tricks*. In *Neural Networks: Tricks of the Trade* (pp. 421–436). Springer. (SGD optimallashtirish texnikalari bo'yicha amaliy yondashuv)
8. Li, L., Jamieson, K., DeSalvo, G., Rostamizadeh, A., & Talwalkar, A. (2017). *Hyperband: A Novel Bandit-Based Approach to Hyperparameter Optimization*. *Journal of Machine Learning Research*, 18(1), 6765–6816. (Optimallashtirishda hyperparametrlarni boshqarish usuli)
9. Schmidhuber, J. (2015). *Deep Learning in Neural Networks: An Overview*. *Neural Networks*, 61, 85–117. (Neyron tarmoqlarda optimallashtirish jarayonlari haqida umumiy tahlil)
10. Das, S., Suganthan, P. N. (2011). *Differential Evolution: A Survey of the State-of-the-Art*. *IEEE Transactions on Evolutionary Computation*, 15(1), 4–31. (Evolutsion algoritmlar va ularning optimallashtirishdagi roli haqida chuqur tahlil)