

SUN'IY NEYRON TARMOQLARNING ASOSLARI VA ULARNING QO'LLANILISHI**Muxiddinova Jasmina Faxriddinovna**

Samarqand Davlat Universiteti

Sun'iy intellekt va raqamli texnologiyalar Kompyuter ilmlari va dasturlash texnologiyalari
3-kurs talabasi.<https://doi.org/10.5281/zenodo.19664757>

Annotatsiya. Ushbu maqolada sun'iy neyron tarmoqlarning nazariy asoslari, tuzilishi, o'qitish jarayoni, asosiy turlari va amaliy qo'llanilish sohalari ilmiy nuqtai nazardan ko'rib chiqiladi. Maqolada neyron, perceptron, aktivatsiya funksiyalari, tarmoq arxitekturasi, backpropagation algoritmi va gradient tushish usullari batafsil yoritilgan. Bundan tashqari, ANN, CNN va RNN kabi asosiy neyron tarmoq turlari tahlil qilinib, ularning tibbiyot, ta'lim, biznes, axborot xavfsizligi va sun'iy intellekt tizimlaridagi o'rni muhokama qilingan.

Kalit so'zlar: sun'iy neyron tarmoqlar, perceptron, aktivatsiya funksiyasi, backpropagation, CNN, RNN, mashinaviy o'qitish, chuqur o'qitish.

Kirish

XXI asrning ikkinchi yarmida texnologik taraqqiyot shiddat bilan kechmoqda. Bugungi kunda raqamli iqtisodiyot, to'rtinchi sanoat inqilobi va "Katta ma'lumotlar" (Big Data) davri sun'iy intellekt (SI) zamonaviy fan va texnologiyaning markaziga chiqarmoqda. Inson miyasining ishlash mexanizmlaridan ilhomlanib yaratilgan sun'iy neyron tarmoqlar (SNT) esa SI sohasining eng istiqbolli yo'nalishlaridan biri hisoblanadi.

Statistik ma'lumotlarga ko'ra, 2023-yilda global sun'iy intellekt bozorining hajmi 136 milliard AQSh dollarini tashkil etgan bo'lib, 2030-yilga kelib bu ko'rsatkich 1,8 trillion dollarga yetishi kutilmoqda. Bunday jadal o'sishning asosida aynan neyron tarmoq texnologiyalari yotadi. Google, Microsoft, Meta va boshqa yirik texnologik kompaniyalar o'z mahsulotlarining yuragida chuqur o'qitish (deep learning) asosidagi neyron tarmoqlardan foydalanmoqda.

Neyron tarmoqlar bugungi kunda tabiiy tilni qayta ishlash (NLP), kompyuter ko'rishi (computer vision), nutqni tanish, tibbiy diagnostika, moliyaviy prognozlash va avtomatlashtirilgan boshqaruv tizimlarida qo'llanilmoqda. ChatGPT, DALL-E, AlphaFold kabi inqilobiy tizimlar ham neyron tarmoq arxitekturasi asosida qurilgan.

Ushbu maqolaning asosiy maqsadi — sun'iy neyron tarmoqlarning nazariy poydevorini izchil va tizimli tarzda bayon etish, ularning o'qitish jarayonini algoritmik nuqtai nazardan tahlil qilish, turli arxitekturalar o'rtasidagi farqlarni ko'rsatish va amaliy qo'llanilish sohasini ilmiy asosda muhokama qilishdan iborat.

Sun'iy neyron tarmoqlarning nazariy asoslari

Sun'iy neyron tarmoqlarni tushunish uchun avvalo biologik neyronning tuzilishini ko'rib chiqish lozim. Inson miyasi taxminan 86 milliard neyron tashkil topgan bo'lib, ularning o'zaro bog'lanishi sinaps orqali amalga oshiriladi. Har bir biologik neyron dendritlar orqali kirish signallarini qabul qiladi, yadro (soma)da ushbu signallarni qayta ishlaydi va akson orqali chiqish signalini uzatadi.

Sun'iy neyron (artificial neuron yoki node) biologik neyronning matematik modeli bo'lib, quyidagi asosiy elementlardan iborat: kirish qiymatlari (x_1, x_2, \dots, x_n), og'irliklar (w_1, w_2, \dots, w_n), siljish (bias, b), yig'ish funksiyasi va aktivatsiya funksiyasi. Neyronning chiqish qiymati quyidagi formula asosida hisoblanadi:

$$y = f(w_1x_1 + w_2x_2 + \dots + w_nx_n + b) = f(\sum w_ix_i + b)$$

Bu yerda f — aktivatsiya funksiyasi, b — siljish (bias) koeffitsienti. Siljish koeffitsienti neyronning pragini boshqaruvchi parametr bo'lib, tarmoqning moslashuvchanligini oshiradi.

Perceptron — sun'iy neyron tarmoqlarning eng sodda shakli bo'lib, 1958-yilda amerikalik psixolog Frank Rosenblatt tomonidan taklif etilgan. U ikki sinfli klassifikatsiya muammolarini hal etish uchun mo'ljallangan bitta neyrondan iborat model hisoblanadi.

Klassik perceptron quyidagi tarzda ishlaydi: kirish vektoriga (x) og'irliklar vektori (w) skalar ko'paytiriladi va natija siljish b bilan yig'iladi. Agar natija noldan katta yoki teng bo'lsa, chiqish 1 qabul qilinadi, aks holda 0. Bu oddiy qoida "basamoqli aktivatsiya" deb ataladi.

Masalan, ikkita kirish uchun AND mantiqiy operatsiyasini perceptron yordamida modellashtirishni ko'raylik: kirish (0,0) uchun chiqish 0, (0,1) uchun 0, (1,0) uchun 0, (1,1) uchun 1. Perceptron to'g'ri og'irliklarni o'rganib, bu klassifikatsiyani amalga oshira oladi. Biroq XOR operatsiyasini yagona perceptron hal qila olmaydi — bu Minsky va Papert tomonidan 1969-yilda ko'rsatilgan va ko'p qatlamli tarmoqlarning rivojlanishiga sabab bo'lgan.

Aktivatsiya funksiyasi neyronning chiqishini belgilovchi matematik funksiya bo'lib, tarmoqqa chiziqsizlik (non-linearity) xususiyatini beradi. Chiziqsizliksiz, nechta qatlam bo'lmasin, tarmoq faqat chiziqli transformatsiyalarni amalga oshira oladi.

ReLU — hozirgi kunda eng keng tarqalgan aktivatsiya funksiyasi bo'lib, formulasi quyidagicha: $f(x) = \max(0, x)$. Ya'ni, kirish musbat bo'lsa o'zi qaytariladi, manfiy bo'lsa nol qaytariladi. ReLU afzalliklari: hisoblash jihatdan sodda, gradient yo'qolish (vanishing gradient) muammosini kamaytiradi, tarmoqni tezroq o'qitadi. Kamchiligi: manfiy kirishlarda gradient nolga teng bo'lib, ba'zi neyronlar "o'lib qolishi" mumkin (Dying ReLU muammosi). Yechim sifatida Leaky ReLU, ELU, GELU variantlari taklif etilgan.

Sigmoid funksiyasi formulasi: $f(x) = 1 / (1 + e^{-(x)})$. Bu funksiya chiqishni (0, 1) oraliqqa mashtablaydi, shuning uchun ikkilik klassifikatsiyaning chiqish qatlamida va ehtimollik hisoblashda qo'llaniladi. Kamchiliklari: katta mutlaq qiymatlarda gradient deyarli nolga yaqinlashadi (vanishing gradient), natijada chuqur tarmoqlarda o'qitish sekinlashadi. Shuningdek, sigmoid funksiyasi nolga markazlashmagan (non-zero-centered), bu esa gradient yangilanishida muammo tug'dirishi mumkin.

Tanh (giperbolik tangens) formulasi: $f(x) = (e^x - e^{-x}) / (e^x + e^{-x})$. Chiqish qiymatlari (-1, 1) oraliqda bo'lib, u sigmoiddan farqli o'laroq nolga markazlashgan. Bu xususiyat gradient yangilanishini samaraliroq qiladi. Lekin tanh ham vanishing gradient muammosidan xoli emas. Asosan RNN (rekurrent neyron tarmoqlar) arxitekturasida qo'llaniladi.

Ko'p qatlamli neyron tarmoq (Multilayer Perceptron, MLP) uchta asosiy qatlamdan iborat:

- Kirish qatlami (Input Layer): tashqi ma'lumotlarni qabul qiluvchi neyronlar joylashgan qatlam. Neyronlar soni kirish xususiyatlari (feature) soniga mos keladi. Masalan, 28x28 piksellik rasmni qayta ishlash uchun 784 ta kirish neyron kerak bo'ladi.

- Yashirin qatlamlar (Hidden Layers): kirish va chiqish qatlamlari orasidagi bir yoki bir nechta qatlam. Ushbu qatlamlar ma'lumotdagi murakkab, noxiziqli bog'liqliklarni o'rganadi.

Qatlamlar soni va har birining neyron soni arxitektura dizayni jarayonida belgilanadi.

- Chiqish qatlami (Output Layer): tarmoqning natijasini beruvchi qatlam. Neyronlar soni masala turiga bog'liq: ikkilik klassifikatsiya uchun 1 ta, ko'p sinfli klassifikatsiya uchun sinf soni qadar neyron bo'ladi.

Agar tarmoqda ikkita yashirin qatlam bo'lsa, u Universal Approximation Theorem asosida har qanday uzluksiz funksiyani ixtiyoriy aniqlikda taxmin qila oladi.

Bu nazariy natija neyron tarmoqlarning qudratini asoslab beruvchi fundamental teorema hisoblanadi.

Neyron tarmoqni o'qitish jarayoni.

Neyron tarmoqni o'qitish uchun ma'lumotlar odatda uchta to'plamga bo'linadi: o'qitish to'plami (training set, 60-80%), tekshirish to'plami (validation set, 10-20%) va sinov to'plami (test set, 10-20%). O'qitish to'plami tarmoq parametrlarini o'rganish uchun, tekshirish to'plami giperhiperparametrlarni sozlash uchun, sinov to'plami esa so'nggi baholash uchun ishlatiladi.

Ma'lumotlarni oldindan qayta ishlash (preprocessing) muhim bosqich hisoblanadi.

Normallashtirish (normalization) — xususiyatlarni [0,1] yoki [-1,1] oralikka keltirish; standartlashtirish (standardization) — o'rtacha qiymati 0, standart chetlanishi 1 bo'lishini ta'minlash; kodlash (encoding) — kategorik o'zgaruvchilarni raqamli formatga o'tkazish kabi usullar qo'llaniladi. Ma'lumotlarning sifatli bo'lishi tarmoq samaradorligini belgilovchi eng muhim omil ekanligi e'tirof etilgan — "axlat kirs, axlat chiqadi" (Garbage In, Garbage Out) tamoyili.

Yo'qotish funksiyasi (Loss function yoki Cost function) tarmoqning bashorat qiymati bilan haqiqiy qiymat orasidagi farqni o'lchaydi. Bu funksiya tarmoqni o'qitish jarayonining yo'nalishini belgilaydi.

Regressiya masalalarida eng keng tarqalgan yo'qotish funksiyasi O'rtacha Kvadrat Xatosi (Mean Squared Error, MSE) bo'lib, formulasi: $MSE = (1/n) * \sum (y_i - \hat{y}_i)^2$. Bu yerda y_i haqiqiy qiymat, \hat{y}_i esa bashorat qiymati. Klassifikatsiya masalalarida

kross-entropiya (Cross-Entropy Loss) ishlatiladi: $L = -\sum (y_i * \log(\hat{y}_i))$. Bu funksiya ehtimollik taqsimotlari orasidagi farqni o'lchab, klassifikatsiya natijalarini optimallashtiradi.

Backpropagation (orqaga tarqalish) algoritmi 1986-yilda Rumelhart, Hinton va Williams tomonidan taqdim etilgan bo'lib, neyron tarmoqlarni o'qitishning asosiy mexanizmi hisoblanadi.

Algoritm ikki bosqichdan iborat:

Birinchi bosqich — oldinga uzatish (Forward Pass): kirish ma'lumotlari tarmoq orqali oxirigacha uzatilib, yo'qotish funksiyasi qiymati hisoblanadi.

Ikkinchi bosqich — orqaga uzatish (Backward Pass): zanjir qoidasi (Chain Rule) asosida yo'qotish funksiyasining har bir og'irlik bo'yicha hosilasi (gradient) hisoblanadi. Bu formulani ko'rsatish uchun: $dL/dw = dL/dy' * dy'/dw$. Zanjir qoidasi ko'p qatlamli funksiyaning hosilasini tashqi qatlamdan ichkariga tomon ketma-ket hisoblash imkonini beradi.

Har bir og'irlik yangilanadi: $w_{\text{yangi}} = w_{\text{eski}} - \eta * (dL/dw)$, bu yerda η (eta) — o'qitish tezligi (learning rate). Backpropagation algoritmining samaradorligi shundaki, u bitta o'tishda barcha gradientlarni hisoblaydi, bu esa hisoblash murakkabligini sezilarli darajada kamaytiradi.

Gradient tushish (Gradient Descent) — yo'qotish funksiyasini minimallashtirishning asosiy optimizatsiya usuli. Uch asosiy turi mavjud:

- To'liq partiyali gradient tushish (Batch Gradient Descent): barcha o'qitish namunalari bo'yicha gradientni hisoblaydi. Barqaror, lekin katta ma'umotlar uchun sekin ishlaydi.
- Stoxastik gradient tushish (Stochastic Gradient Descent, SGD): har bir namuna uchun alohida gradient hisoblaydi. Tezroq, lekin tebranishlari ko'p.
- Mini-partiyali gradient tushish (Mini-batch Gradient Descent): amaliyotda eng ko'p qo'llaniladigan usul. Odatda 32, 64 yoki 128 ta namunadan iborat mini-partiyalar bilan ishlaydi.

Ikkala usulning afzalliklarini birlashtiradi.

Zamonaviy optimallashtiruvchilar (optimizer) orasida Adam (Adaptive Moment Estimation) eng mashhuri hisoblanadi.

Adam har bir parametr uchun alohida o'qitish tezligini moslashtiradi, birinchi va ikkinchi tartibli momentlarni

kuzatib boradi. Bu xususiyat Adamni turli turdagi masalalar uchun ishonchli tanlov qiladi.

Neyron tarmoqning turlari.

ANN — sun'iy neyron tarmoqlarning umumiy nomi bo'lib, klassik to'liq bog'langan (fully connected) tarmoqlarni anglatadi. Ushbu arxitekturada har bir qatlamdagi barcha neyronlar keyingi qatlamdagi barcha neyronlar bilan bog'langan. ANN tuzilma tasniflash (classification), regressiya va klasterlash kabi asosiy ML vazifalari uchun qulay.

ANN ning cheklovi shundaki, u tasvirlar, matnlar va vaqt seriyalari kabi tuzilmali ma'lumotlar uchun samarali emas. Masalan, 1000x1000 piksellik rasmni to'g'ridan-to'g'ri ANN ga kiritish 1 million kirish neyronni talab qiladi, bu esa hisoblash jihatdan qimmat va parametrlar soni ko'p bo'lgan holda ortiqcha moslashish (overfitting) xavfini oshiradi.

CNN Yann LeCun tomonidan 1989-yilda taklif etilgan bo'lib, matritsali ma'lumotlar (tasvirlar, audio spektrogrammalari) bilan ishlash uchun mo'ljallangan. CNN ning asosiy elementi konvolyutsion qatlam (convolutional layer) bo'lib, u kichik filtrlar (kernel) yordamida ma'lumotlarning mahalliy xususiyatlarini ajratib oladi.

CNN arxitekturasi odatda quyidagi qatlamlardan tashkil topadi: konvolyutsion qatlam (xususiyat ajratish), ReLU aktivatsiyasi (chiziqsizlik kiritish), havzalash qatlami yoki pooling (o'lchamni kamaytirish, o'zgarishga chidamlilik), to'liq bog'langan qatlam (klassifikatsiya). LeNet, AlexNet, VGG, ResNet, EfficientNet kabi mashhur CNN arxitekturalari kompyuter ko'rishi sohasini inqilob qildi. ImageNet tanlovida (ILSVRC) CNN asosidagi AlexNet 2012-yilda avvalgi rekordni 10% dan ortiq ustunlik bilan yengdi.

RNN ketma-ket ma'lumotlar (matn, nutq, vaqt seriyalari) bilan ishlash uchun mo'ljallangan. ANN va CNN dan farqli ravishda, RNN neyronlari oldingi bosqichdagi axborotni "xotira" sifatida saqlaydi. Bu xususiyat RNN ni kontekstga bog'liq masalalar uchun mos qiladi.

Klassik RNN ning asosiy muammosi — uzoq muddatli bog'liqliklarni (long-term dependencies) saqlashda qiyinchilik. Bu muammoni hal qilish uchun LSTM (Long Short-Term Memory, 1997-yil, Hochreiter va Schmidhuber) va GRU (Gated Recurrent Unit, 2014-yil, Cho va boshqalar) arxitekturalari ishlab chiqilgan. LSTM maxsus kalit (gate) mexanizmlari — kirish, unutish va chiqish kanallar orqali uzoq muddatli bog'liqliklarni saqlash imkonini beradi.

Hozirgi kunda matn tarjimai, nutqni matnlashtirish (speech-to-text) va moliyaviy prognozlash kabi sohalarda RNN va LSTM keng qo'llaniladi. Biroq 2017-yilda taqdim etilgan Transformer arxitekturasi ko'plab NLP masalalarida RNN o'rnini bosmoqda.

Qo'llanilish sohalari.

Sun'iy neyron tarmoqlar tibbiyotda inqilobiy o'zgarishlar yasamoqda. Rasmiy diagnostikada CNN asosidagi tizimlar rentgen, MRI va CT tasvir tahlilida mutaxassislar darajasida aniqlikka erishmoqda. Masalan, Google tomonidan ishlab chiqilgan DeepMind tizimi ko'z kasalliklarini aniqlashda 94,5% aniqlik ko'rsatdi.

Genomika sohasida neyron tarmoqlar DNK ketma-ketliklaridagi mutatsiyalarni taxmin qilish, oqsil tuzilmasini bashorat qilish (AlphaFold2 tizimi ushbu muammoni hal etdi) va individuallashtirish tibbiyotida qo'llaniladi. Dori vositalarini kashf etishda ham neyron tarmoqlar katta salohiyat ko'rsatmoqda — Insilico Medicine 46 kunda yangi dori nomzodini yaratdi, bu an'anaviy usul bilan yillar davom etgan bo'lardi. Ta'limda neyron tarmoqlar adaptiv o'quv tizimlarini (Adaptive Learning Systems) yaratishda qo'llaniladi.

Bunday tizimlar har bir talabani o'zlashtirish tezligi, zaif tomonlari va o'rganish uslubini tahlil qilib, individuallashtirish o'quv rejasini shakllantiradi. Khan Academy, Duolingo va Coursera platformalari ushbu texnologiyadan foydalanmoqda.

Avtomatik baholash tizimlarida (Automated Essay Scoring) NLP asosidagi neyron tarmoqlar yozma ishlarni baholashda qo'llaniladi. Bundan tashqari, virtual o'qituvchilar va suhbat tizimlari talabalar bilan interaktiv ravishda muloqot qilib, savollarni javoblab, tushuntirishlar berishi mumkin. Ta'lim jarayonining prognozlashuvida neyron tarmoqlar talabani kurs oxirida qanday natijani ko'rsatishini taxmin qila oladi, bu esa muammolarni oldindan aniqlash imkonini beradi.

Biznes sohasida neyron tarmoqlar qo'llanilishining eng yorqin misoli tavsiya tizimlari (recommendation systems) hisoblanadi. Netflix, YouTube va Amazon kabi kompaniyalar foydalanuvchilar xatti-harakati, ko'rish tarixi va reyting ma'lumotlarini tahlil qilib, individuallashtirish tavsiyalar beruvchi neyron tarmoqlardan foydalanadi. Netflix ma'lumotlariga ko'ra, tavsiya tizimi kompaniyaga yiliga 1 milliard dollardan ortiq qo'shimcha foyda keltirmoqda.

Mijozlarning ketib qolishini bashorat qilish (churn prediction), kredit xavfini baholash (credit risk scoring) va firibgarlikni aniqlash (fraud detection) sohalari ham neyron tarmoqlar yordamida samarali hal etilmoqda. Sanoat kompaniyalarida prognozli texnik xizmat ko'rsatish (predictive maintenance) sohasida neyron tarmoqlar sensor ma'lumotlarini tahlil qilib, uskunalarning nosozligini avvaldan aniqlaydi.

Axborot xavfsizligida neyron tarmoqlar kiberhujumlarni aniqlash va oldini olish tizimlarida keng qo'llaniladi. Anomaliyalarni aniqlash (anomaly detection) sohasida autoencoderlar tarmoq trafigidagi g'ayrioddiy naqshlarni aniqlab, potentsial hujumlarni real vaqt rejimida bloklaydi. Deep Packet Inspection texnologiyasi ham neyron tarmoqlar yordamida samaralashtirilgan.

Zararli dasturlarni klassifikatsiya qilishda CNN va RNN asosidagi tizimlar imzosiz (signature-less) usulda yangi zararli dasturlarni ham aniqlay oladi. Parol kuchini baholash va fishing hujumlarini aniqlash tizimlarida ham neyron tarmoqlardan foydalaniladi. Deepfake (soxta audio-video) yaratish va uni aniqlash o'rtasidagi texnologik kurash ham GAN (Generative Adversarial Network) asosida kechmoqda.

Zamonaviy chatbot va katta til modellari (Large Language Models, LLM) Transformer arxitekturasi asosidagi neyron tarmoqlar hisoblanadi. OpenAI ning GPT seriyasi, Anthropic ning Claude modeli, Google ning Gemini modeli — barchasining yuragida milliardlab parametrlil transformer tarmoqlari yotadi.

Bu tizimlar matn yaratish, tarjima, savol-javob, kodni tushuntirish va yozish, ma'lumotlarni tahlil qilish kabi vazifalarni bajaradi. Ularning ishlash tamoyili oddiy: katta hajmdagi matn ma'lumotlari (internet sahifalari, kitoblar, ilmiy maqolalar) bilan oldindan o'qitilgan (pre-trained) tarmoq, so'ngra maxsus vazifalar uchun sozlanadi (fine-tuning).

Multimodal tizimlar esa matn, rasm, audio va video ma'lumotlarni bir vaqtda qabul qilib qayta ishlay oladi.

Afzalliklari va kamchiliklari.

Afzalliklari

- Murakkab naqshlarni o'rganish qobiliyati: Neyron tarmoqlar millionlab parametrlar yordamida ma'lumotlardagi eng nozik bog'liqliklarni avtomatik ravishda o'rganadi. Odamlar tomonidan qo'lda ajratib bo'lmaydigan xususiyatlarni ham tarmoq mustaqil kashf etadi.

- **Miqyoslilik (Scalability):** Ma'lumotlar va hisoblash quvvati oshgan sari neyron tarmoqlarning samaradorligi ham oshib boradi. Bu xususiyat ularni katta ma'lumotlar davrining texnologiyasiga aylantiradi.

- **Universallik:** Tasvirlar, matnlar, audio, vaqt seriyalari va tuzilmali ma'lumotlar kabi turli turdagi ma'lumotlar bilan ishlash uchun moslashtirish mumkin.

- **Transfer o'qitish (Transfer Learning):** Bir vazifada o'qitilgan tarmoqni boshqa vazifa uchun qayta sozlash imkoniyati mavjud. Bu esa kam ma'lumot bo'lgan holatlarda ham yaxshi natija beradi.

- **Real vaqt ishlash:** O'qitilgan neyron tarmoqlar juda tez ishlaydi, bu esa ularni real vaqt dasturlarida (self-driving cars, real-time translation) qo'llash imkonini beradi.

Kamchiliklari

- **"Qora quti" muammosi (Black Box Problem):** Neyron tarmoq nima uchun ma'lum bir qaror qabul qilganini tushuntirish qiyin. Bu xususiyat tibbiyot va huquq kabi shaffoflik talab qiluvchi sohalarda qo'llashni cheklaydi. Tushuntiruvchi AI (Explainable AI, XAI) sohasidagi tadqiqotlar ushbu muammoni hal qilishga qaratilgan.

- **Katta ma'lumot va hisoblash resurslari talab etilishi:** Neyron tarmoqlarni samarali o'qitish uchun ko'p miqdorda belgilangan ma'lumot va kuchli GPU (Graphics Processing Unit) kerak. Bu esa kichik kompaniyalar va muassasalar uchun cheklov yaratadi.

- **Ortiqcha moslashish (Overfitting):** Tarmoq o'qitish ma'lumotlarini yod olishi va yangi ma'lumotlarda yomon ishlashi mumkin. Bu muammoni hal qilish uchun dropout, regularizatsiya va data augmentation kabi usullar qo'llaniladi.

- **Tushunarsiz giperhiperparametrlar:** O'qitish tezligi, qatlamlar soni, neyronlar soni kabi giperhiperparametrlarni tanlash ko'pincha tajriba asosida amalga oshiriladi.

- **Raqibona hujumlarga sezgirligi (Adversarial Attacks):** Kirish ma'lumotlariga kichik, ko'rinmas o'zgarishlar kiritish orqali neyron tarmoqni aldash mumkin. Bu xavfsizlik jihatidan muhim muammo hisoblanadi.

Xulosa.

Ushbu ilmiy maqolada sun'iy neyron tarmoqlarning asosiy nazariy va amaliy jihatlari tizimli ravishda ko'rib chiqildi. Biologik neyronning matematik modeli bo'lgan sun'iy neyronlardan boshlab, to zamonaviy chuqur o'qitish arxitekturalarigacha bo'lgan evolyutsion rivojlanish tahlil etildi.

Maqolaning asosiy natijalarini quyidagicha umumlashtirish mumkin: birinchidan, neyron tarmoqlar — murakkab chiziqsiz funksiyalarni o'rganish qobiliyatiga ega, biologik miyadan ilhomlanib yaratilgan matematik tizimlar; ikkinchidan, backpropagation va gradient tushish algoritmlari tarmoqlarni o'qitishning asosiy mexanizmi bo'lib xizmat qiladi; uchinchidan, ANN, CNN va RNN kabi turli arxitekturalar turli muammo turlari uchun ixtisoslashgan; to'rtinchidan, neyron tarmoqlar tibbiyot, ta'lim, biznes, xavfsizlik va SI tizimlari kabi keng tarqalgan sohalarda inqilobiy o'zgarishlar yasamoqda.

Kelajak istiqbollari nuqtai nazaridan, neyron tarmoqlar sohasida bir nechta muhim yo'nalishlar ajralib turadi. Tushuntiruvchi AI (XAI) tadqiqotlari tarmoqlarning qaror qabul qilish jarayonini shaffof qilishga qaratilgan. Neyromorph hisoblash (neuromorphic computing) biologik miyaning energiya samaradorligini sun'iy tizimga ko'chirishni maqsad qiladi. Kvant neyron tarmoqlari (Quantum Neural Networks) kvant hisoblash bilan neyron tarmoqlarni birlashtirgan istiqbolli yo'nalish sanaladi.

Bundan tashqari, az sonli namuna bilan o'qish (few-shot learning), noldan o'qish (zero-shot learning) va metao'qitish (meta-learning) sohalari neyron tarmoqlarning insoniy o'rganish qobiliyatiga yaqinlashishi uchun asosiy yo'nalishlardir. Sun'iy umumiy intellekt (Artificial General Intelligence, AGI) sari yo'l esa neyron tarmoqlarning asosiy to'sig'i — umumlashish va moslashuvchanlik muammosini hal etishdan o'tadi.

Xulosa qilib aytganda, sun'iy neyron tarmoqlar hozirgi kunda sohasidagi mutaxassislar uchun majburiy bilim sohasiga aylangan. Ushbu sohani chuqur o'rganish kelajak mutaxassislarining raqobatbardoshligini ta'minlaydi va fan-texnikaning ravnaqiga munosib hissa qo'shish imkonini beradi.

FOYDALANILGAN ADABIYOTLAR RO'YXATI

1. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press. ISBN: 978-0262035613. URL: <https://www.deeplearningbook.org>
2. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
3. Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536.
4. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780.
5. Vaswani, A., et al. (2017). Attention Is All You Need. *Advances in Neural Information Processing Systems (NeurIPS)*, 30. arXiv:1706.03762.
6. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *CVPR 2016*. arXiv:1512.03385.
7. Chollet, F. (2021). *Deep Learning with Python (2nd ed.)*. Manning Publications. ISBN: 978-1617296864.
8. Nielsen, M. A. (2015). *Neural Networks and Deep Learning*. Determination Press. URL: <http://neuralnetworksanddeeplearning.com>
9. Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill. ISBN: 978-0070428072.
10. Haykin, S. (2009). *Neural Networks and Learning Machines (3rd ed.)*. Pearson. ISBN: 978-0131471399.