

NEYRON TARMOQLARINI FAOLLASHTIRISH FUNKSIYALARINI AMALGA OSHIRADIGAN MANTIQUIY AVTOMATLAR

Mardayev Azamatjon Abdusamat o'g'li

Renessans ta'lim universiteti
mas'uliyati cheklangan jamiyat

Dekan o'rinbosari

<https://doi.org/10.5281/zenodo.17360757>

So'nggi yillarda sun'iy intellekt va mashinaviy o'rganish texnologiyalari jadal rivojlanmoqda. Ularning asosiy elementi bo'lgan sun'iy neyron tarmoqlar (SNT) inson miyasi faoliyatidan ilhomlanib yaratilgan matematik modellar majmuasidir. Neyron tarmoqlarning asosiy maqsadi — murakkab ma'lumotlarni qayta ishlash, ularni o'rganish va natijani aniqlik bilan bashoratlashdir. Ushbu jarayonning muhim bosqichlaridan biri — faollashtirish funksiyasi (activation function) bo'lib, u kirish signallariga qarab neyronning chiqishini aniqlaydi. Shu sababli, faollashtirish funksiyalarini amalga oshiradigan mantiqiy avtomatlar neyron tarmoqlarning asosiy hisoblash yadrosi sifatida katta ahamiyat kasb etadi.

Sun'iy neyron tarmoq ko'plab bog'langan tugunlardan (neyronlardan) iborat bo'lib, har bir tugun kirish signallarini qabul qiladi, ularni og'irlik koeffitsientlari bilan ko'paytiradi va yig'indini hisoblaydi. Hosil bo'lgan qiymat keyin faollashtirish funksiyasi orqali o'tkazilib, chiqish signali hosil qiladi. Ana shu faollashtirish bosqichi neyronning "faollashish" yoki "faollashmaslik" holatini belgilaydi. Demak, neyron tarmoqning intellektual qaror qabul qilish qobiliyati asosan faollashtirish funksiyasining shakli va mantiqiy mexanizmiga bog'liq.

Faollashtirish funksiyasi — bu neyronning chiqish qiymatini chegaralovchi va nolinear (chiziqli bo'lmagan) o'zgartirishni amalga oshiruvchi matematik ifodadir. Agar barcha neyronlar chiziqli ishlasa, tarmoq murakkab masalalarni o'rganishga qodir bo'lmaydi. Shu sababli nolinear funksiyalar — masalan, sigmoid, ReLU, tanh, softmax kabi funksiyalar — neyron tarmoqlarga murakkablik va moslashuvchanlik beradi. Ular ma'lumotni turlicha "faollashtiradi" va tarmoqni murakkab naqshlarni tanishga o'rgatadi.

Kompyuter tizimlarida yoki apparat darajasida neyron tarmoqni tez ishlatish uchun faollashtirish funksiyalarini mantiqiy avtomatlar orqali modellashtirish samarali yechim hisoblanadi. Mantiqiy avtomat — bu kirish signallariga qarab holatini o'zgartiruvchi va chiqishni aniqlovchi raqamli tizimdir.

Masalan, sigmoid funksiyasini mantiqiy avtomat yordamida "ko'rsatkichli (exponential)" hisoblashsiz, oldindan aniqlangan qiymatlar jadvalidan (LUT — lookup table) chaqirish orqali tez bajarish mumkin. Shuningdek, ReLU (Rectified Linear Unit) funksiyasi mantiqiy darajada "agar $x > 0$ bo'lsa chiqish = x , aks holda 0" kabi oddiy shart operatori bilan amalga oshiriladi. Bu usul neyron tarmoqlarning apparat tezligini sezilarli darajada oshiradi.

Faollashtirish funksiyalarini hisoblovchi mantiqiy avtomatlar odatda kombinatsion yoki ketma-ket (sekventsial) sxemalarga asoslanadi. Kombinatsion avtomatlar kirish signallarini bir vaqtning o'zida qayta ishlaydi, bu esa ReLU yoki tanh kabi funksiyalar uchun qulay. Sekventsial avtomatlar esa vaqt omilini hisobga olib, holatlar ketma-ketligini saqlaydi — bu LSTM (Long Short-Term Memory) yoki RNN (Recurrent Neural Network) kabi neyron tarmoqlarda qo'llaniladi. Shuningdek, FPGA (Field Programmable Gate Array) va ASIC (Application Specific Integrated Circuit) kabi apparatlarda ushbu avtomatlar "parallel hisoblash" imkonini beradi.

Mantiqiy avtomat yordamida faollashtirish funksiyasini yaratishda asosiy maqsad — **aniqlik va tezlik orasida balansni topishdir**.

$$f(x) = \frac{1}{1+e^{-x}}$$

Masalan, sigmoid funksiyasining matematik ifodasi bo'lsa, apparat darajasida bu qiymat “chegaralangan polinom” yoki “qadamli chiziqli funksiya” bilan taxmin qilinadi.

ReLU funksiyasi uchun esa oddiy “mantiqiy eshiklar” (AND, OR, NOT) orqali signalni musbat yoki nol holatga o'tkazish kifoya. Bu esa energiya sarfini kamaytiradi va hisoblashni

Faollashtirish funksiyasi	Matematik ifoda	Mantiqiy avtomat asosidagi amalga oshirish	Afzalligi
Sigmoid	$f(x) = \frac{1}{1+e^{-x}}$	Lookup Table (LUT) yordamida yaqinlashtiriladi	Silliqliq chiqish, neyron o'rganishga qulay
ReLU	$f(x) = \max(0, x)$	Oddiy shart operatori ("agar $x > 0$ bo'lsa, chiqish= x ")	Tez ishlaydi, kam energiya sarfi
Tanh	$f(x) = \tanh(x)$	Polinom yoki jadval asosida mantiqiy model	Chiqish -1 dan $+1$ gacha, barqaror signal
Leaky ReLU	$f(x) = x, x > 0; 0.01x, x < 0$	Ko'paytirish va shart operatori kombinatsiyasi	O'rganish yo'qolmasligini ta'minlaydi
Softmax	$f(x_i) = \frac{e^{x_i}}{\sum e^j}$	Ketma-ket (sekvensial) avtomatlar orqali summatsiya va normalashtirish	Ko'p sinfli tasniflash uchun mos

1-rasm. Faollashtirish funksiyalarining mantiqiy modellari

Faollashtirish funksiyalarini mantiqiy avtomatlar orqali amalga oshirish usuli asosan real vaqt tizimlari, robototexnika, kompyuter ko'rish (Computer Vision) va sanoat avtomatikasida keng qo'llaniladi.

Masalan, kamera orqali ob'ektni aniqlovchi neyron tarmoqda faollashtirish funksiyasi apparat darajasida mantiqiy avtomat shaklida ishlasa, tasvirni qayta ishlash tezligi bir necha baravar oshadi. Shuningdek, energiya tejovchi qurilmalarda (IoT, smart sensorlar) ushbu yondashuv samaradorlikni oshiradi.

Kelajakda mantiqiy avtomatlar asosida neyron tarmoqlarni apparat darajasida optimallashtirishga oid tadqiqotlar yanada kengayadi. Xususan, kvant mantiqli avtomatlar, memristorli tarmoqlar, va optik neyron tizimlar bu borada yangi imkoniyatlar yaratadi.

Shuningdek, faollashtirish funksiyalarini “o'z-o'zidan moslashuvchi” (adaptive activation functions) tarzda ishlab chiqish, ularni apparat darajasida dinamik ravishda o'zgartirish imkonini beradi. Bu esa neyron tarmoqlarni aqlli, moslashuvchan va energiya jihatdan samarali qiladi.

Xulosa qilib aytganda, neyron tarmoqlarni samarali ishlashi uchun faollashtirish funksiyalarini mantiqiy avtomatlar orqali apparat darajasida amalga oshirish muhim ahamiyatga ega. Bunday avtomatlar yordamida hisoblash jarayoni tezlashadi, energiya sarfi kamayadi va real vaqt tizimlari uchun moslashuvchan yechimlar yaratiladi. Shu bois, kelgusida sun'iy intellekt, elektronika va mantiqiy avtomatika sohalarining o'zaro integratsiyasi zamonaviy neyron tarmoqlar arxitekturasining yangi avlodini shakllantiradi.

Foydalangan adabiyotlar ro'yxati

1. Haykin, S. (2011). Neural Networks and Learning Machines (3rd Edition). Pearson Education.
2. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.
3. Hecht-Nielsen, R. (1990). Neurocomputing. Addison-Wesley Publishing.
4. Lecun, Y., Bengio, Y., & Hinton, G. (2015). "Deep Learning." Nature, 521(7553), 436–444.