

FAOLLASHTIRISH FUNKSIYALARI: SIGMOID, TANH, RELU VA BOSHQALAR

Tojimamatov Israil Nurmatovich

Fargʻona davlat universiteti katta oʻqituvchisi

israiltojimatov@gmail.com

Karimova Nargizaxon Abdurasul qizi

Fargʻona davlat universiteti 2-kurs talabasi

nargizaxon592@gmail.com

Annotatsiya. Ushbu ishda sunʼiy neyron tarmoqlarida qoʻllaniladigan asosiy faollashtirish funksiyalari — Sigmoid, Tanh, ReLU hamda ularning turli variantlari tahlil qilinadi. Faollashtirish funksiyalarining mohiyati, ularning matematik modellari, afzallik va kamchiliklari hamda neyron tarmoqning oʻqitilish jarayoniga taʼsiri yoritiladi. Shuningdek, zamonaviy chuqur oʻrganish tizimlarida faollashtirish funksiyalarini toʻgʻri tanlashning ahamiyati asoslab beriladi. Ushbu mavzu sunʼiy intellekt modellari samaradorligini oshirishda muhim nazariy va amaliy ahamiyatga ega.

Kalit soʻzlar: Faollashtirish funksiyasi, Sigmoid, Tanh, ReLU, Leaky ReLU, Softmax, neyron tarmoq, noxiziqlik, gradient, sunʼiy intellekt, chuqur oʻrganish.

Abstract. This paper analyzes the main activation functions used in artificial neural networks, including Sigmoid, Tanh, ReLU, and their various modifications. The essence of activation functions, their mathematical models, advantages and disadvantages, as well as their impact on the training process of neural networks are discussed. Additionally, the importance of selecting appropriate activation functions in modern deep learning systems is substantiated. This topic holds significant theoretical and practical value in improving the efficiency of artificial intelligence models.

Keywords: Activation function, Sigmoid, Tanh, ReLU, Leaky ReLU, Softmax, neural network, nonlinearity, gradient, artificial intelligence, deep learning

Аннотация. В данной работе анализируются основные функции активации, используемые в искусственных нейронных сетях, такие как Sigmoid, Tanh, ReLU и их различные модификации. Раскрывается сущность функций активации, их математические модели, преимущества и недостатки, а также их влияние на процесс обучения нейронных сетей. Кроме того, обосновывается важность правильного выбора функций активации в современных системах глубокого обучения. Данная тема имеет важное теоретическое и практическое значение для повышения эффективности моделей искусственного интеллекта.

Ключевые слова: Функция активации, Sigmoid, Tanh, ReLU, Leaky ReLU, Softmax, нейронная сеть, нелинейность, градиент, искусственный интеллект, глубокое обучение.

Kirish

Zamonaviy sun'iy intellekt tizimlarining rivojlanishi ko'p jihatdan sun'iy neyron tarmoqlarining samaradorligiga bog'liq. Neyron tarmoqlarining asosiy vazifasi murakkab, noxiziqli jarayonlarni o'rganish va ularga mos ravishda bashorat yoki klassifikatsiya natijalarini shakllantirishdan iborat. Ushbu jarayonning muhim tarkibiy qismi — faollashtirish funksiyalari bo'lib, ular neyronlar orqali o'tuvchi signallarga noxiziqlik kiritadi va tarmoqning murakkab naqshlarni o'rganish qobiliyatini ta'minlaydi. Agar faollashtirish funksiyalari qo'llanilmaganida, neyron tarmoqlar chiziqli modellardan farq qilmaydi va zamonaviy masalalar, xususan, tasvirni aniqlash, nutqni qayta ishlash yoki tabiiy tilni tushunish kabi murakkab vazifalarni bajarish imkoniga ega bo'lmagan bo'lardi. Faollashtirish funksiyalarining turli ko'rinishlari mavjud bo'lib, ulardan Sigmoid, Tanh va ReLU funksiyalari amaliyotda eng ko'p uchraydigan va samaradorligi yuqori bo'lgan variantlar hisoblanadi. Har bir funksiya o'zining aniq matematik xususiyatlariga, afzallik va cheklovlariga ega. Shuning uchun to'g'ri aktivatsiya funksiyasini tanlash modelning o'rganish tezligi, barqarorligi va yakuniy aniqligiga sezilarli ta'sir ko'rsatadi. Ushbu ishda sun'iy neyron tarmoqlarida qo'llaniladigan asosiy faollashtirish funksiyalarining mohiyati, ishlash prinsipi, afzalliklari, kamchiliklari va qo'llash sohalari tizimli ravishda yoritiladi.

Shuningdek, zamonaviy chuqur o'rganish modellarida aktivatsiya funksiyalarining o'rni va ulardan samarali foydalanish strategiyalari ko'rib chiqiladi.

Nazariy qismi

Sun'iy neyron tarmoqlari faoliyatining matematik asoslari ularning ichki arxitekturasi va signallarni qayta ishlash mexanizmlariga tayanadi. Ushbu mexanizmlarning markaziy tarkibiy qismlaridan biri — **faollashtirish funksiyalari** bo'lib, ular neyron kirishlarining chiziqli kombinatsiyasini ma'lum bir nolinear transformatsiyaga keltiradi. Matematik nuqtayi nazardan, faollashtirish funksiyasi tarmoqqa **nochiziqlilik** kiritish orqali modelning funksional ifoda qobiliyatini sezilarli darajada kengaytiradi. Nochiziqlilikning mavjudligi neyron tarmoqlarga murakkab ko'p o'lchamli bog'lanishlarni modellashtirish, klassifikatsiya chegaralarini aniqlash, funksiyalarni approksimatsiya qilish va umumlashtirish qobiliyatini shakllantirish imkonini beradi. Faollashtirish funksiyalarining qo'llanishi gradientga asoslangan o'qitish jarayonining barqarorligini ta'minlashda ham muhim ahamiyat kasb etadi. Chunki gradientning yo'qolishi yoki portlab ketishi kabi holatlar tarmoqning o'rganish dinamikasini izdan chiqarishi mumkin. Shu sababli aktivatsiya funksiyasi tanlanayotganda uning differentsiallanuvchanligi, chastotali o'zgarishlarga nisbatan sezgirliги, hosila qiymatlarining barqarorligi va hisoblash samaradorligi kabi parametrlar hisobga olinadi. Masalan, Sigmoid funksiyasi o'zining silliq S-simon shakli tufayli tarixan ko'p qo'llanilgan bo'lsa-da, uning yuqori saturatsiya holatlarida gradientning keskin kamayib ketishiga olib kelishi modellarning chuqur qatlamlarda samarali o'qimasligiga sabab bo'ladi. Tanh funksiyasi markazlashtirilgan diapazoni tufayli Sigmoidga nisbatan yaxshiroq konvergensiya ko'rsatkichiga ega bo'lsa-da, u ham gradient so'nishi muammosidan holi emas. Zamonaviy chuqur o'rganish tizimlarida keng qo'llanilayotgan ReLU va uning modifikatsiyalari (Leaky ReLU, PReLU, ELU va boshqalar) esa manfiy qiymatlar uchun gradientni saqlab qolish yoki faollanish chegarasini soddalashtirish orqali optimallashtirish jarayonining barqarorligini oshiradi. Bu funksiyalarning afzalligi ularning hisoblash jihatdan yengilligi va chuqur tarmoqlarda gradient o'tish kanalini uzluksiz ta'minlay olishi bilan izohlanadi. Softmax funksiyasi esa ko'p sinfli klassifikatsiya modellarida ehtimollarni normallashtirilgan ko'rinishda

ifodalashga xizmat qiladi va chiqish qatlamlarida standart yechim sifatida qo'llanadi. Faollashtirish funksiyalarining tarixiy evolyutsiyasi threshold modelidan boshlangan bo'lsa-da, bugungi kunda ushbu elementlarning nazariy qiymati ularning amaliy samaradorligi, o'rganish jarayoniga ta'siri va modelning umumiy generalizatsiya qobiliyatini belgilashdagi o'rni bilan belgilanadi. Shunday qilib, aktivatsiya funksiyalarining to'g'ri tanlanishi neyron tarmoqlarning matematik barqarorligi, optimallashtirish jarayonining konvergensiya tezligi va modelning yakuniy aniqligini belgilovchi fundamental omillardan biridir.

Amaliy qismi

Amaliy ish davomida faollashtirish funksiyasining tanlanishi neyron tarmoqning o'qitilish samaradorligiga qanday ta'sir ko'rsatishi eksperimental tarzda o'rganildi. Buning uchun bir xil tuzilishga ega bo'lgan sun'iy neyron tarmog'i uch xil aktivatsiya funksiyasi bilan — **Sigmoid**, **Tanh** va **ReLU** — alohida-alohida o'qitildi. Har bir modelda bir xil ma'lumotlar to'plami, bir xil optimallashtirish algoritmi (Gradient Descent) va bir xil parametrlar qo'llanildi.

Tajriba davomida uchta asosiy ko'rsatkich kuzatildi:

1. **Konvergensiya tezligi** — model nechta iteratsiyadan so'ng barqaror o'rganishni boshlashi.
2. **Gradientning barqarorligi** — optimallashtirish jarayonida gradientning yo'qolishi yoki kuchayishi.
3. **Modelning yakuniy aniqligi** — test to'plamidagi natijalar asosida.

O'qitish jarayonida Sigmoid funksiyasida gradientning saturatsiya mintaqalarida sezilarli ravishda kamaygani va konvergensiya sekin kechgani kuzatildi. Tanh funksiyasi Sigmoidga qaraganda barqarorroq natija bergan bo'lsa-da, chuqurlashgan qatlamlarda gradientning pasayishi davom etdi. ReLU funksiyasi esa eng tez konvergensiyaning ko'rsatib, gradientning musbat qiymatlar bo'yicha barqaror saqlanishi natijasida modelni ancha tez va barqaror o'qitdi.

Tahlil qismi:

O'tkazilgan amaliy tajribaning tahlili shuni ko'rsatadiki, faollashtirish funksiyasining tanlanishi neyron tarmoqning o'qitilish dinamikasiga sezilarli darajada ta'sir ko'rsatadi. Uch xil funksiyaning bir xil sharoitlarda solishtirilishi ularning konvergensiya tezligi, gradientning barqarorligi va yakuniy aniqlik bo'yicha farqlarini ochib berdi.

Sigmoid funksiyasida o'qitish jarayonining sekinlashishi gradientning saturatsiya hududlarida keskin kamayishi bilan bog'liq bo'lib, bu uning chuqur arxitekturalarda samaradorligini cheklaydi. Tanh funksiyasi Sigmoidga nisbatan yaxshiroq o'quv xususiyatlarini ko'rsatgan bo'lsa-da, gradientning yo'qolishi muammosini to'liq bartaraf eta olmadi. Bu esa uning chuqur tarmoqlarda optimal natija bera olmasligini ko'rsatadi.

ReLU funksiyasi tajriba davomida eng yaxshi natijani ko'rsatdi: gradientning musbat sohada barqaror saqlanishi konvergensiya jarayonini tezlashtirdi va modelning o'qitilishida barqarorlikni ta'minladi. Bu ReLU funksiyasining amaliy modellar uchun afzal bo'lishining asosiy sabablaridan biridir. Shuningdek, ReLuning oddiyligi va hisoblash tejamkorligi uni zamonaviy chuqur neyron tarmoqlar uchun amaliy jihatdan eng maqbul yechim sifatida ko'rsatadi.

Tahlil natijalari shuni tasdiqlaydiki, amaliy vazifalarda faollashtirish funksiyasini tanlash model sifatiga bevosita ta'sir ko'rsatadi. Tajribalar asosida **ReLU funksiyasi eng optimal**, Tanh — **o'rtacha samarador**, Sigmoid esa **chuqur tarmoqlar uchun maqsadga muvofiq emas** ekani aniq belgilandi.

Xulosa

O'tkazilgan nazariy va amaliy tadqiqotlar faollashtirish funksiyalarining sun'iy neyron tarmoqlari o'qitilish jarayonidagi hal qiluvchi rolini yaqqol ko'rsatdi. Amaliy tajriba davomida bir xil sharoitlarda qo'llangan Sigmoid, Tanh va ReLU funksiyalari o'rganish dinamikasi, gradientning barqarorligi va modelning yakuniy aniqligi bo'yicha sezilarli farqlar namoyon etdi. Natijalar shuni ko'rsatdiki, Sigmoid funksiyasi gradientning saturatsiya mintaqalarida tez so'nib qolishi sababli chuqur tarmoqlarda yetarli

samaradorlikka ega emas. Tanh funksiyasi nisbatan barqarorroq bo'lsa-da, u ham chuqur arxitekturalarda gradientning yo'qolishiga moyil. ReLU funksiyasi esa o'qitish jarayonida eng tez konvergensiya, hisoblash samaradorligi va gradientning barqaror o'tishi bilan ajralib turdi. Bu esa uning zamonaviy neyron tarmoqlar uchun eng maqbul aktivatsiya funksiyasi ekanini tasdiqlaydi. Umuman olganda, tadqiqot natijalari faollashtirish funksiyasi tanlovining neyron tarmoqning o'rgatilish sifati va umumiy samaradorligiga bevosita ta'sir ko'rsatishini ko'rsatdi. Shunday qilib, model arxitekturasi va vazifasining xususiyatlaridan kelib chiqib, aktivatsiya funksiyasini ongli ravishda tanlash neyron tarmoqlarning muvaffaqiyatli ishlashi uchun zaruriy shart hisoblanadi.

Foydalanilgan Adabiyotlar:

1. Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536.
2. Glorot, X., & Bengio, Y. (2010). Understanding the difficulty of training deep feedforward neural networks. *Proceedings of the 13th International Conference on Artificial Intelligence and Statistics*, 9, 249–256.
3. Nair, V., & Hinton, G. E. (2010). Rectified linear units improve restricted Boltzmann machines. *Proceedings of the 27th International Conference on Machine Learning*, 807–814.
4. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
5. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
6. He, K., Zhang, X., Ren, S., & Sun, J. (2015). Delving deep into rectifiers: Surpassing human-level performance on ImageNet classification. *Proceedings of the IEEE International Conference on Computer Vision*, 1026–1034.
7. Bishop, C. M. (1995). *Neural Networks for Pattern Recognition*. Oxford University Press.
8. Hochreiter, S. (1998). The vanishing gradient problem during learning recurrent neural networks. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 6(2), 107–116.

9. Haykin, S. (2009). *Neural Networks and Learning Machines* (3rd ed.). Pearson Education.
10. Tojimamatov, I. N., Topvoldiyeva, H., Karimova, N., & Inomova, G. (2023). Grafik ma'lumotlar bazasi. *Евразийский журнал технологий и инноваций*, 1(4), 75–84.
11. Tojimamatov, I. N., Olimov, A. F., Khaydarova, O. T., & Tojiboyev, M. M. (2023). CREATING A DATA SCIENCE ROADMAP AND ANALYSIS. *PEDAGOGICAL SCIENCES AND TEACHING METHODS*, 2(23), 242-250.
12. Tojimamatov, I. N., Topvoldiyeva, H., Karimova, N., & Inomova, G. (2023). GRAFIK MA'LUMOTLAR BAZASI. *Евразийский журнал технологий и инноваций*, 1(4), 75-84.
13. Ne'matillayev, A. H., Abduqahhorov, I. I., & Tojimamatov, I. (2023). BIG DATA TEXNOLOGIYALARI VA UNING MUAMMOLARI. *ОБРАЗОВАНИЕ НАУКА И ИННОВАЦИОННЫЕ ИДЕИ В МИРЕ*, 19(1), 61-64.
14. Tojimamatov, I., Usmonova, S., Muhammadmusayeva, M., & Xoldarova, S. (2023). DATA MINING MASALALARI VA ULARNING YECHIMLARI. "TRENDS OF MODERN SCIENCE AND PRACTICE", 1(2), 60-63.
15. Tojimamatov, I., Soliyeva, X., & Israilova, R. (2025). FAYL NOMLARINI QISQARTIRISH ALGORITMLARI. *Академические исследования в современной науке*, 4(26), 45-52.
16. Nurmamatovich, T. I. (2025). MONGODB DA BIG DATA BILAN ISHLASH USULLARI. *YANGI O'ZBEKISTON, YANGI TADQIQOTLAR JURNALI*, 2(8), 792-798.
17. Nurmamatovich, T. I. (2025). MOBIL OPERATSION SISTEMALARNING KELAJAGI. *Лучшие интеллектуальные исследования*, 44(5), 133-139.
18. Nurmamatovich, T. I., & Umidjon o'g, M. Z. S. (2025). BERILGANLAR BAZASIDA HAYOTIY SIKL. *Лучшие интеллектуальные исследования*, 44(5), 169-178.
19. Nurmamatovich, T. I., & Umidjon o'g, M. Z. S. (2025). MASHINA KODLARI BILAN ISHLASH. *Лучшие интеллектуальные исследования*, 44(5), 159-168.
20. Nurmamatovich, T. I. (2025). BERILGANLAR BAZASI ADMINISTRATORI. *Лучшие интеллектуальные исследования*, 44(5), 276-282.

21. Tojimatov, I. (2025). ADO-NET TEXNOLOGIYASI YORDAMIDA HISOBOTLAR VA FORMALARNI SHAKLLANTIRISH. Академические исследования в современной науке, 4(25), 122-126.
22. Nurmatovich, T. I. (2025). STATISTIKA SOHASIDA AXBOROT TIZIMLARI VA TEXNOLOGIYALARINI SINTAKSIS TAXLIL QILISH. Лучшие интеллектуальные исследования, 44(4), 157-166.
23. Nurmatovich, T. I. (2025). AXBOROTLARNI TAQDIM ETISH VA ULAR BILAN ISHLASH. Лучшие интеллектуальные исследования, 44(4), 135-140.
24. Tojimatov, I., & Abduvaliyev, X. (2025). KO 'P FOYDALANUVCHILI BBBT ARXITEKTURASI. Инновационные исследования в науке, 4(5), 16-22.
25. Tojimatov, I., & Xolmurod o'g, A. O. H. (2025, May). SQL SERVERDA CHEKLASHLAR. In CONFERENCE OF MODERN SCIENCE & PEDAGOGY (Vol. 1, No. 1, pp. 409-413).