



## O'QUVCHILAR XATTI-HARAKATINI ANIQLASHDA O'RAMALI NEYRON TARMOQ AKTIVATSIYA FUNKSIYASINI TAKOMILLASHTIRISH

**Egamberdiyev Nodir Abdunazarovich**

*Muhammad al-Xorazmiy nomidagi TATU "Raqamli texnologiyalar  
konvergensiya" kafedrasini mudiri*

**Toliyev Xurshid Ilhamovich**

*Muhammad al-Xorazmiy nomidagi TATU "Raqamli texnologiyalar  
konvergensiya" kafedrasini katta o'qituvchisi*

**Abduraimov Abdurasul Ismoil o'g'li**

*"Muhammad al-Xorazmiy nomidagi Toshkent Axborot Texnologiyalari  
Universiteti" magistratura talabasi*

**Annotatsiya:** Ushbu maqolada sinf xonada o'quvchilar xatti-harakatini avtomatik aniqlashda ResNet50 klassifikator arxitekturasidagi aktivatsiya funksiyasining o'quv tanlanmadagi kam sonli sinflar aniqligiga ta'siri tahlil qilindi. Bundan tashqari har bir ResNet blokida  $\beta$  parametri alohida o'rganiluvchi LSwish aktivatsiya funksiyasi taklif etildi. Taklif etilgan LSwish funksiyasi sinf xonada eng muhim harakatlardan biri bo'lgan qo'l ko'tarish sinfi uchun  $F1 = 92.35\%$  bilan barcha taqqoslangan aktivatsiyalar orasida eng yuqori ko'rsatkichni ta'minladi.

**Kalit so'zlar:** ResNet50, LSwish, aktivatsiya funksiyasi, kam sonli sinf, F1-score.

Sinf xonada o'quvchilarning xatti-harakatini avtomatik monitoring qiluvchi zamonaviy sun'iy intellekt tizimlari uchun aynan kam uchraydigan, ammo pedagogik jihatdan eng muhim bo'lgan qo'l ko'tarish (hand-raising), muhokama qilish (discuss), o'rindan turish (standing) kabi harakatlar eng muhim belgilar hisoblanadi. Aynan shu sinflar o'quvchining darsga faol ishtirokini, tushunmovchilikni va muloqot ehtiyojini ko'rsatadi. Ammo real ta'lim sharoitida to'plangan o'quv tanlanmalarda ushbu sinflar ustun sinflar bilan taqqoslaganda 5:1 nisbatdan oshiq disbalansga uchraydi, natijada zamonaviy CNN modellari yuqori umumiy aniqlikka erishsada, kam sonli sinflarning F1 ko'rsatkichi past chiqadi. Mazkur maqolada ResNet50 arxitekturasida aktivatsiya funksiyasini tanlash orqali kam sonli sinflar aniqligini oshirishga empirik yondashiladi. Bunda har bir ResNet blokida  $\beta$  parametri mustaqil o'rganiluvchi LearnableSwish (LSwish) funksiyasi taklif etilib, uning muvaffaqiyatli o'qitilishi uchun zarur bo'lgan optimizator parametrlari aniqlab beriladi hamda beshta zamonaviy aktivatsiya funksiyasi



bir xil sharoitda tizimli solishtiriladi.

Tadqiqotda balanslangan YOLO sinf xonadagi o'quvchilar xatti-harakati ma'lumotlar to'plami ishlatildi. Model arxitekturasi asosi sifatida ResNet50 (23.52 M parametr) olindi, oxirgi to'liq bog'langan qatlam 7 sinfli chiqishga almashtirildi. Aktivatsiyani funksiyasi ustida quyidagicha almashtirish amalga oshirildi: ResNet50 ichidagi barcha 17 ta nn.ReLU modul rekursiv ravishda tanlangan funksiyaga o'zgartirildi.

LSwish ning samarali o'qitilishi uchun optimizator AdamW ikki guruhli parametrlar bilan konfiguratsiyalandi: asosiy og'irliklar uchun  $lr = 10^{-3}$ ,  $weight\_decay = 0.01$ ;  $\beta$  parametrlari uchun  $lr = 5 \cdot 10^{-3}$ ,  $weight\_decay = 0$ . Dastlabki tajribalar shuni ko'rsatdiki,  $\beta$  parametrini asosiy og'irliklar bilan bir xil guruhda yangilaganda  $\beta$  qiymatlari dastlabki 1.0 yaqinida qolib ketadi (0.81–1.40 oralig'i) va LSwish SiLU dan deyarli farqlanmaydi. Boshqa aktivatsiya funksiyalar (ReLU, Mish, SiLU, GELU) bitta parametr guruhi ( $lr = 10^{-3}$ ,  $wd = 0.01$ ) bilan o'qitildi.

Beshta aktivatsiya funksiyasining umumiy natijalari 1-jadvalda, har bir sinf uchun F1-score natijalari esa 2-jadvalda keltirilgan.

1-jadval Aktivatsiya funksiyalari bo'yicha umumiy natijalar

| Aktivatsiya | Top-1 Acc | F1-macro | Precision-macro | Recall-macro | Training vaqti |
|-------------|-----------|----------|-----------------|--------------|----------------|
| ReLU        | 0.9169    | 0.9272   | 0.9208          | 0.9346       | 56m 52s        |
| Mish        | 0.9139    | 0.9240   | 0.9187          | 0.9301       | 1h 4m 12s      |
| SiLU        | 0.9139    | 0.9264   | 0.9220          | 0.9314       | 1h 2m 29s      |
| GELU        | 0.9162    | 0.9259   | 0.9216          | 0.9308       | 1h 0m 39s      |
| LSwish      | 0.9160    | 0.9260   | 0.9190          | 0.9341       | 1h 27m 18s     |

2-jadval Har bir sinfi bo'yicha F1-score natijalari



| Sinf         | Train  | Val   | ReLU  | Mish  | SiLU  | GELU  | LSwish |
|--------------|--------|-------|-------|-------|-------|-------|--------|
| discuss      | 4 169  | 494   | 99.30 | 99.09 | 99.40 | 99.40 | 99.29  |
| focus        | 20 000 | 2 000 | 90.70 | 90.57 | 90.52 | 90.49 | 90.76  |
| hand-raising | 3 850  | 333   | 91.37 | 91.29 | 92.17 | 90.28 | 92.35  |
| read         | 20 000 | 2 000 | 88.11 | 87.58 | 87.34 | 88.08 | 88.00  |
| standing     | 3 662  | 439   | 98.64 | 98.42 | 98.41 | 98.52 | 98.07  |
| turn-head    | 4 787  | 552   | 86.52 | 85.57 | 86.48 | 86.98 | 85.32  |
| write        | 20 000 | 2 000 | 94.39 | 94.26 | 94.13 | 94.42 | 94.42  |


Umumiy yuqori aniqlikka ega sinflar ko'rsatkichlari barcha besh aktivatsiya uchun 0.30% oraliq'ida (91.39%–91.69%) joylashdi, bu esa umumiy aniqlik darajasida aktivatsiya tanlashining bir xil natija berishini ko'rsatadi. LSwish aktivatsiya funksiyasi ReLU ga statistik jihatdan teng natija (91.60% vs 91.69%, farq 0.09%) qayd etdi.

Har bir sin bo'yicha tahlilda esa sezilarli farqlar kuzatildi. Taklif etilgan LSwish aktivatsiya funksiyasi hand-raising sinfi uchun barcha taqqoslangan aktivatsiyalar orasida eng yuqori  $F1 = 92.35\%$  natijani ta'minladi. Ushbu sinf o'quvchilar uchun pedagogik jihatdan eng muhim xatti-harakat signallaridan biri bo'lib, o'quvchining faol ishtiroki va savol berish istagini ko'rsatadi. Shuningdek, LSwish aktivatsiya funksiyasi focus sinfi uchun ham  $F1 = 90.76\%$  bilan eng yuqori natijani berdi. Write sinfida LSwish GELU bilan teng eng yuqori  $F1 = 94.42\%$  natijaga erishdi. ReLU aktivatsiya funksiyasi read va standing sinflarida yetakchilik qildi, bu esa uning sodda va samarali ekanligini ko'rsatadi, ammo kam sonli sinflarda LSwish aktivatsiya funksiyasidan ancha



past natija ko'rsatdi.

LSwish aktivatsiya funksiyasi yordamida modelni o'qitish yakunida har blokdan olingan  $\beta$  qiymatlarining taqsimoti modelning aktivatsiya shaklini qatlam bo'yicha moslashtirish qobiliyatini tasdiqladi (1-rasm). Birinchi konvolyutsion qatlam va layer 4.1 bloki aktivatsiya funksiyasini dastlabki SiLU shakliga yoki undan silliqroq variantga yaqinlashtirdi. Bu taqsimot LSwish aktivatsiya funksiyasining shunchaki o'rganilmaydigan parametr emas, balki ma'lumotdan haqiqatan moslashuvchi element ekanligini isbotlaydi.



1-rasm LSwish aktivatsiya funksiyasining har blokda o'rganilgan  $\beta$  parametrlari

Beshta zamonaviy aktivatsiya funksiyasini bir xil sharoitda tizimli solishtirish shuni ko'rsatdiki, ResNet50 modelining umumiy aniqligi sinf xonadagi o'quvchilar xatti-harakatini sinflashtirishda aktivatsiya tanlashiga kuchli bog'liq emas. Shu bilan birga, per-class tahlil ozchilik sinflar darajasida aniq farqlarni ochib beradi: taklif etilgan LearnableSwish aktivatsiya funksiyasi pedagogik jihatdan eng muhim kam sonli sinf bo'lgan qo'l ko'tarish (hand-raising) uchun eng yuqori F1 ni (92.35%) ta'minladi va bu ReLU aktivatsiya funksiyasi natijasidan ancha yuqori. Bu talaba faolligini real vaqtda monitoring qiluvchi amaliy tizimlar uchun muhim afzallik hisoblanadi. Shuningdek, LSwish focus sinfida eng yuqori F1 ga erishdi va write sinfida eng yuqori natijani qayt etdi. O'rganilgan  $\beta$  qiymatlari 0.82–1.81 oralig'ida tasvirlanib, adaptiv mexanizm empirik tasdiqlandi.

## FOYDALANILGAN ADABIYOTLAR RO'YXATI

1. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition // IEEE CVPR. — 2016. — P. 770–778.
2. Ramachandran P., Zoph B., Le Q.V. Searching for Activation Functions // arXiv:1710.05941. — 2017.



3. Misra D. Mish: A Self Regularized Non-Monotonic Activation Function // BMVC. — 2020.
4. Hendrycks D., Gimpel K. Gaussian Error Linear Units (GELUs) // arXiv:1606.08415. — 2016.
5. Elfving S., Uchibe E., Doya K. Sigmoid-Weighted Linear Units for Neural Network Function Approximation in Reinforcement Learning // Neural Networks. — 2018. — Vol. 107. — P. 3–11.
6. Loshchilov I., Hutter F. Decoupled Weight Decay Regularization // ICLR. — 2019.
7. Deng J., Dong W., Socher R. et al. ImageNet: A Large-Scale Hierarchical Image Database // IEEE CVPR. — 2009.
8. Yang K. Dataset of Student Classroom Behavior [Dataset]. Kaggle. <https://www.kaggle.com/datasets/kaiyueyyds/dataset-of-student-classroom-behavior>