



**Tasvirlarni klassifikatsiya qilishda xususiyatlarni birlashtirish
usuli orqali model aniqligini oshirish**

Raximov Baxtiyor Saidovich

Toshkent tibbiyot akademiyasi Urganch filiali

“Biofizika va axborot texnologiyalari” kafedrası mudiri

O‘razmatov Tohir Quronbayevich

Muhammad al-Xorazmiy nomidagi TATU Urganch filiali

“Axborot texnologiyalari” kafedrası katta o‘qituvchisi

tohir20314@gmail.com

Annotatsiya: Ushbu maqolada tasvirlarni klassifikatsiya qilishda model aniqligini oshirish uchun xususiyatlarni birlashtirish usullari tahlil qilinadi. EfficientNetB0 modelining ishlatilishi, xususan, Global Average Pooling (GAP) va Softmax funksiyalari orqali modelning sinflar orasidagi farqlash qobiliyati oshirilgani ko‘rsatilgan. GAP usuli fazoviy o‘lchamlarni qisqartirish orqali har bir kanal uchun o‘rtacha qiymat hisoblash imkonini beradi va maxsus tortishish koeffitsientlariga ehtiyoj sezmasdan, samaradorlikni oshiradi. Softmax esa chiqish qiymatlarini ehtimollik sifatida ifodalash imkonini beradi. Bu maqola, ayniqsa, tasvir klassifikatsiyasiga qaratilgan konvolyutsion neyron tarmoqlarni samarali ishlatishda foydali bo‘lishi mumkin.

Kalit so‘zlar: Global average pooling, softmax funksiyasi, neyron tarmoq, Efficient NetB0



EfficientNetB0 modelda Global average pooling ishlatilgan. **Global Average Pooling (GAP)** — bu ko‘p hollarda konvolyutsion neyron tarmoqlarda oxirgi qatlamda qo‘llaniladigan pooling turi. GAP blokining asosiy vazifasi — kiruvchi tensorning fazoviy (2D) o‘lchamlarini bitta o‘lchamga qisqartirish va har bir kanal uchun o‘rtacha qiymatni hisoblash. GAP maxsus tortishish koeffitsientlarini o‘rgatishni talab qilmaydi va juda sodda bo‘lishiga qaramasdan juda samarali hisoblanadi, ayniqsa klassifikatsiya vazifalarida. Farqli ravishda an'anaviy pooling (masalan, max-pooling) faqat ma'lum bir qismda (patch) ishlov bersa, global average pooling butun fazoviy o‘lcham bo‘yicha o‘rtacha qiymatni hisoblaydi. GAP natijasida o‘lcham bitta vektorli chiqishga qisqaradi. GAP qatlami har bir kanal uchun o‘rtacha qiymatni hisoblaydi [159; 20-b.]. Agar kiruvchi tensor X fazoviy o‘lchamlari $H \times W$ bo‘lgan va C kanaldan iborat bo‘lsa, unda har bir kanal X^c uchun GAP quyidagicha aniqlanadi:

$$y^c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X_{i,j}^c \quad (1)$$

$X_{i,j}^c$ - kiruvchi tensorning i, j -chi joylashgan qismidagi c -kanal qiymati;

y^c - c -kanal uchun global o‘rtacha qiymat.

Har bir kanal bo‘yicha $H \times W$ o‘lchamdagi fazoviy qism o‘rtacha bir qiymatga qisqartiriladi. Yakuniy natija har bir kanal uchun o‘rtacha qiymatni ifodalovchi $1 \times 1 \times C$ o‘lchamli vektor bo‘ladi.

Global Average Poolingning ishlash jarayoni. Kiruvchi ma’lumot misol uchun $H \times W \times C = 7 \times 7 \times 512$ bo‘lsa, unda bizda 512 ta kanal bor va har bir kanal fazoviy jihatdan 7×7 bo‘ladi. Har bir kanal bo‘yicha o‘rtacha qiymat olinadi, ya’ni har bir 7×7 matritsa bitta o‘rtacha qiymatga qisqartiriladi. Shunday qilib, har bir kanalning fazoviy



qismi bitta raqamga o'tadi. Yakuniy chiqish $1 \times 1 \times C$, ya'ni har bir kanal uchun bitta qiymat. Oldingi misolda bu chiqish $1 \times 1 \times 512$ bo'ladi [160; 7-b., 162; 1030-b.].

Misol uchun X kiruvchi tensor $3 \times 3 \times 2$ bo'lsin, ya'ni 2 ta kanal bor, har bir kanal 3×3 o'lchamda. GAP algoritmi quyidagicha bo'ladi:

1-kanal uchun:

$$X^1 = \begin{bmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \\ 7 & 8 & 9 \end{bmatrix}$$

O'rtacha qiymat:

$$y^1 = \frac{1}{9} \sum_{i=1}^3 \sum_{j=1}^3 X_{i,j}^1 = \frac{1}{9} (1 + 2 + 3 + 4 + 5 + 6 + 7 + 8 + 9) = \frac{45}{9} = 5$$

2-kanal uchun:

$$X^2 = \begin{bmatrix} 9 & 8 & 7 \\ 6 & 5 & 4 \\ 3 & 2 & 1 \end{bmatrix}$$

O'rtacha qiymat:

$$y^2 = \frac{1}{9} \sum_{i=1}^3 \sum_{j=1}^3 X_{i,j}^2 = \frac{1}{9} (1 + 2 + 3 + 4 + 5 + 6 + 7 + 8 + 9) = \frac{45}{9} = 5$$

Bunda natija chiqish vektori [5,5] ya'ni har bir kanalning o'rtacha qiymati.

Keyingi oxirgi qatlam softmax funksiyasi hisoblanadi. **Softmax** — bu neyron tarmoqlarida, ayniqsa klassifikatsiya vazifalarida keng qo'llaniladigan aktivatsiya funksiyasi bo'lib, u model chiqishini ehtimollik sifatida talqin qilish imkonini beradi. Softmax har bir elementni $[0, 1]$ oraliqdagi qiymatga o'giradi, va barcha elementlarning



yig'indisi 1 ga teng bo'ladi, bu ularni ehtimollik sifatida interpretatsiya qilish imkonini beradi[167; 22-b., 170; 25-b.].

Agar $z = [z_1, z_2, \dots, z_n]$ bo'lsa, neyron tarmog'ining chiqish qiymatlari $z_1, z_2, \dots, z_n$, unda softmax funksiyasi har bir z_i uchun quyidagicha ifodalanadi:

$$\sigma(z_i) = \frac{e^{z_i}}{\sum_{j=1}^n e^{z_j}} \quad (2)$$

bu yerda:

e-euler soni (taxminan 2718);

z_i -chiqishdagi i-elementning qiymati;l

n-chiqishdagi elementlar soni.

Softmax funksiyasi bir nechta sinfga tegishli bo'lishi mumkin bo'lgan chiqishlarni ehtimollik sifatida interpretatsiya qilish uchun ishlatiladi. Bu funksiya butunlay salbiy va ijobiy qiymatlarni normallashtiradi va ularni (0,1) oralig'iga keltiradi. Softmaxning eng katta qiymatga ega bo'lgan elementi chiqishda eng katta ehtimollikni oladi[3].

- Eksponensial o'zgarish. Har bir z_i qiymati uchun eksponensial amali qo'llaniladi:

$$e^{z_i}$$

Bu bosqichda har bir qiymat ijobiy bo'ladi, hatto z_i salbiy bo'lsa ham. Eksponensial funksiyasi eng katta qiymatlarni yanada kattalashtiradi va kichik qiymatlarni yanada kichik qiladi.

- Yig'indini hisoblash. Har bir eksponensial natijani qo'shamiz:

$$\sum_{j=1}^n e^{z_j}$$

Bu yig'indi kelajakdagi barcha chiqishlarning yig'indisi bo'ladi.



- Normallashtirish. Har bir qiymatni umumiy yig'indiga bo'lamiz, shunda har bir chiqish (0, 1) oralig'ida bo'ladi va barcha chiqish ehtimolliklarining yig'indisi 1 ga teng bo'ladi:

$$\sigma(z_i) = \frac{e^{z_i}}{\sum_{j=1}^n e^{z_j}} \quad (3)$$

Shu tarzda har bir z_i ga tegishli ehtimollik aniqlanadi.

Xulosa:

Tadqiqot natijalari shuni ko'rsatadiki, tasvirlarni klassifikatsiya qilishda Global Average Pooling (GAP) va Softmax funksiyalari samarali tarzda qo'llanilishi model aniqligini oshiradi. GAP har bir kanal uchun o'rtacha qiymatni hisoblash orqali kiruvchi tensorning fazoviy o'lchamlarini qisqartirishga imkon beradi, Softmax esa chiqishni ehtimollik ko'rinishida ifodalab, modelning farqlash qobiliyatini oshiradi. EfficientNetB0 modeli bilan amalga oshirilgan tajribalar sinflar orasidagi farqlashning aniqligi yuqori ekanligini ko'rsatdi. Xususiyatlarni birlashtirish orqali tasvirlarni klassifikatsiya qilishda an'anaviy usullarga nisbatan ancha yaxshi natijalar qo'lga kiritildi.

Foydalanilgan adabiyotlar ro'yxati:

1. Li, M. et al. (2020). "Global Average Pooling in Convolutional Neural Networks."
2. Howard, A. et al. (2019). "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks."
3. Goodfellow, I., Bengio, Y., Courville, A. (2016). "Deep Learning." MIT Press.
4. Simonyan, K., Zisserman, A. (2015). "Very Deep Convolutional Networks for Large-Scale Image Recognition."
5. Krizhevsky, A., Sutskever, I., Hinton, G.E. (2012). "ImageNet Classification with Deep Convolutional Neural Networks."
6. He, K. et al. (2016). "Deep Residual Learning for Image Recognition."



7. Chollet, F. (2017). "Xception: Deep Learning with Depthwise Separable Convolutions."
8. Szegedy, C. et al. (2015). "Going Deeper with Convolutions."
9. Zeiler, M.D, Fergus, R (2014) "Visualizing and Understanding Convolutional Networks."
10. Girshick, R. (2015). "Fast R-CNN."