INTERNATIONAL JOURNAL OF SCIENTIFIC RESEARCHERS
ISSN: 3030-332X Impact factor: 9,493 Volume 17, issue 1, Aprel 2026
https://wordlyknowledge.uz/index.php/IJSR worldly knowledge
Index: google scholar, research gate, research bib, zenodo, open aire.
https://scholar.google.com/scholar?hl=ru&as_sdt=0%2C5&q=wosjournals.com&btnG
https://www.researchgate.net/profile/Worldly-Knowledge
https://journalseeker.researchbib.com/view/issn/3030-332X

TASVIRLARNI TASNIFLASHDA DENSENET169 YONDASHUVI: SAMARADORLIK VA QIYOSIY TAHLIL

Jaxongir Jalilov

Muhammad al-Xorazmiy nomidagi Toshkent Axborot

Texnologiyalari Universiteti, Sun'iy Intellekt fakulteti

Annotatsiya: Sun'iy intellekt sohasida chuqur o'rganish usullari keyingi o'n yil ichida juda tez rivojlandi. Ayniqsa, kompyuter tasavvuri yo'nalishida tasvirlarni avtomatik tasniflash muammosi uzoq yillardan beri tadqiqotchilarning e'tiborini tortib kelmoqda. Ilk davrlarda bu muammo ko'p jihatdan qo'lda tuzilgan belgilar va klassik statistik usullar yordamida hal etilardi. Ammo neyron tarmoqlar, xususan konvolyutsion neyron tarmoqlar (CNN) paydo bo'lgandan so'ng, tasniflash sifati tubdan o'zgardi. Bugungi kunda ResNet, VGG, InceptionNet va DenseNet kabi arxitekturalar tasvirlarni tasniflash sohasida keng qo'llanilmoqda. Ushbu maqolada ana shunday arxitekturalardan biri — DenseNet169 — uning tuzilishi, ishlash tamoyili, samaradorligi va boshqa modellar bilan qiyosiy tahlili ko'rib chiqiladi.

Kalit so'zlar: Sun'iy intellekt, ResNet, Zich bog'langan tarmoq, CNN, InceptionNet.

DenseNet, ya'ni "Zich bog'langan tarmoq" (Densely Connected Convolutional Network) 2017 yilda Huang va boshqalar tomonidan taklif etilgan bo'lib, u ilmiy hamjamiyatda tez orada katta e'tiborga sazovor bo'ldi. Ushbu arxitekturaning asosiy g'oyasi — tarmoqdagi har bir qavatni oldingi barcha qavatlarga bevosita bog'lash. Ya'ni, an'anaviy CNN arxitekturalarida faqat qo'shni qavat chiqishi keyingi qavatga uzatilsa, DenseNetda birinchi qavatdan to oxirgi qavatgacha bo'lgan barcha chiqishlar bir-biriga ulangan. Bu yondashuv gradient yo'qolish muammosini sezilarli darajada kamaytiradi, xususiyat uzatishini yaxshilaydi va parametrlar sonini tejash imkonini beradi.

DenseNet169 o'z nomidan ko'rinib turibdiki, jami 169 qavatdan iborat. Tarmoq bir nechta "zich blok" (dense block) va ular orasida joylashgan "o'tish qavatlari" (transition layers) dan tashkil topgan. Har bir zich blok ichida qavatlar bir-biriga bevosita ulanib, konkatenatsiya (qo'shib birlashtirish) orqali xususiyatlar uzatiladi. O'tish qavatlari esa tarmoqning o'lchamini va kanallar sonini tartibga solish uchun ishlatiladi. DenseNet169 ning bu tuzilishi uni nafaqat kichik hajmdagi ma'lumotlar to'plamlarida, balki katta va murakkab tasvirlar bilan ishlashda ham samarali qiladi. Tarmoq parametrlarining umumiy soni taxminan 14 million atrofida bo'lib, bu ResNet50 yoki VGG16 ga nisbatan ancha ixcham hisoblanadi.

Tasvirlarni tasniflashda DenseNet169 ning ishlash prinsipi quyidagicha kechadi. Dastlab tasvir kirish qavati orqali tarmoqqa uzatiladi va boshlang'ich konvolyutsion amallar bajariladi. Keyin ma'lumot ketma-ket zich bloklardan o'tadi. Har bir blok ichida yangi xususiyat xaritalari oldingi barcha xususiyat xaritalariga qo'shiladi. Shunday qilib, chuqurroq qavatlarga o'tgan sari xususiyatlar bazasi boyib boradi. Yakuniy bosqichda global o'rtacha havzali qavatdan so'ng to'liq ulangan qavatlar yordamida tasniflash amalga oshiriladi. Oxirgi qavat tasvirning qaysi kategoriyaga mansubligini ehtimollik sifatida ifoda etadi.

DenseNet169 ning amaliy samaradorligini baholash uchun ko'plab tadqiqotlarda ImageNet, CIFAR-10, CIFAR-100 va tibbiyot tasvirlash kabi sohalardagi ma'lumotlar to'plamlari ishlatilgan. ImageNet da sinab ko'rilganida, DenseNet169 top-1 aniqlik ko'rsatkichi bo'yicha

76% dan yuqori natija ko‘rsatgan. Bu natija ResNet50 ning taxminan 75-76% ko‘rsatkichiga yaqin, ammo parametrlar soni kamligini hisobga olsak, DenseNet169 ancha samarali hisoblanadi. CIFAR-10 da esa DenseNet169 bazasidagi modellalar 95% dan yuqori aniqlikka erishgan, bu esa uni o‘rta darajadagi murakkablikdagi tasvirlar uchun ham mos ekanligini ko‘rsatadi.

Qiyosiy tahlil nuqtai nazaridan DenseNet169 ni boshqa mashhur arxitekturalar bilan solishtirib ko‘rish muhimdir. VGG16 arxitekturasi an’anaviy, ketma-ket qavatlangan tuzilishga ega bo‘lib, parametrlar soni 138 milliondan oshadi. Bu son DenseNet169 ga nisbatan deyarli o‘n baravar ko‘p. VGG16 oddiy va tushunarli arxitekturaga ega bo‘lsa-da, bunday katta parametrlar soni tufayli u ko‘proq xotira va hisoblash quvvatini talab qiladi. ResNet50 esa qoldiq ulanishlar (residual connections) g’oyasiga asoslangan bo‘lib, 25 million parametrga ega. ResNet50 gradient yo‘qolishini yaxshi boshqaradi, ammo DenseNet169 ning konkatenatsiya asosidagi yondashuvi xususiyat qayta ishlatishda yanada samaraliroq. InceptionV3 esa parallel konvolyutsion amallardan foydalanib, turli masshtablardagi xususiyatlarni bir vaqtning o‘zida olishga intiladi. Parametrlar soni jihatidan InceptionV3 taxminan 23 million darajasida.

Ushbu qiyosiy ko‘rinishdan shuni anglash mumkinki, DenseNet169 nisbatan oz sonli parametrlari bilan raqobatbardosh aniqlik ko‘rsatkichlarini namoyish etadi. Bu xususiyat uni chegaralangan hisoblash resurslariga ega tizimlarda qo‘llash uchun qulay qiladi. Ayniqsa mobil ilovalar yoki o‘rnatilgan tizimlar (embedded systems) uchun mo‘ljallangan loyihalarda DenseNet169 ning ixchambshuv afzalligi katta ahamiyat kasb etadi. Shuningdek, o‘tkazma o‘rganish (transfer learning) metodologiyasi doirasida DenseNet169 ImageNet da oldindan o‘qitilgan vaznlar asosida yangi sohalarda ham yaxshi natijalar ko‘rsatadi.

Tibbiyot tasvirlash sohasida DenseNet169 ning qo‘llanilishi alohida e’tiborga loyiq. Ko‘krak qafasi rentgen tasvirlarini tasniflashda, ko‘z kasalliklarini aniqlashda va teri kasalliklarini o‘rganishda DenseNet asosidagi modellar yuqori aniqlik ko‘rsatgani qayd etilgan. Bu sohalarda ma’lumotlar ko‘pincha cheklangan bo‘lganligi sababli, parametrlarni tejovchi DenseNet169 ortiqcha moslashish (overfitting) muammosiga kam uchraydi. Tadqiqotlardan birida ko‘krak qafasi rentgen tasvirlari asosida pnevmoniyani aniqlashda DenseNet169 asosidagi model 93% ga yaqin sezuvchanlik va aniqlik ko‘rsatgan. Bu natijalarga erishishda modelning zich ulanish tuzilishi kichik ma’lumotlar to‘plamlarida ham chuqur xususiyatlarni samarali o‘rganishga yordam bergan.

DenseNet169 ning bir muhim kamchiligi shundaki, hisoblash jarayonida oraliq xususiyat xaritalarini saqlash zaruriyati tufayli xotira sarfi yuqori bo‘lishi mumkin. Ayniqsa katta partiyalar (batch) bilan o‘qitishda GPU xotirasi tez to‘lib qolishi mumkin. Shu sababli amaliy loyihalarda partiya o‘lchamini kamaytirish yoki gradient namlash kabi usullarga murojaat etiladi. Bundan tashqari, tarmoqning murakkab ulanish tuzilishi uni vizual tushunish va disk raskadrovka qilishni biroz qiyinlashtiradi. Shunga qaramay, DenseNet169 ning asosiy afzalliklari kamchiliklaridan sezilarli darajada ustun turadi.

DenseNet169 arxitekturasining samaradorligini yanada oshirish maqsadida turli usullar qo‘llanilmoqda. Ma’lumotlarni ko‘paytirish (data augmentation) usullari — masalan, tasvirlarni burish, kengaytirish, rang o‘zgartirish — modelning umumlashish qobiliyatini mustahkamlaydi. Dropout qatlamlarini strategik joylash esa ortiqcha moslashish ehtimolini pasaytiradi. O‘rganish tezligi jadvalini to‘g’ri tanlash va erta to‘xtatish (early stopping) kabi giperparametr optimallashtirish usullari ham natijaga ijobiy ta’sir ko‘rsatadi. Zamonaviy tadqiqotlarda

DenseNet169 ni diqqat mexanizmlari (attention mechanisms) yoki transformatorlar bilan birlashtirish tendensiyasi ham kuzatilmoqda.

O‘zbekistondagi ilmiy-tadqiqot muhitida ham chuqur o‘rganish arxitekturalariga qiziqish ortib bormoqda. Toshkent Axborot Texnologiyalari Universiteti va boshqa oliy ta’lim muassasalarida kompyuter tasavvuri bo‘yicha dissertatsiyalar va loyihalar soni yildan yilga ko‘paymoqda. Mahalliy tadqiqotlar ko‘pincha o‘zbek tilidagi matn tanish, milliy kiyim tasniflash yoki qishloq xo‘jaligi sohasidagi kasalliklar diagnostikasi kabi mahalliy muammolarga yo‘naltirilgan. Aynan shu kontekstda DenseNet169 ning ixcham va samarali tuzilishi uni mahalliy loyihalarda qo‘llash uchun jozibali qiladi, chunki katta hisoblash resurslari har doim ham mavjud emas.

Xulosa qilib aytganda, DenseNet169 tasvirlarni tasniflash sohasida o‘ziga xos nish egallagan arxitektura sifatida baholanishi mumkin. U juda ko‘p parametrlarni sarf qilmasdan yuqori aniqlik ko‘rsatkichlariga erishadi, gradient oqimini yaxshi ta’minlaydi va kichik ma’lumotlar to‘plamlarida ham samarali ishlaydi. Boshqa arxitekturalar bilan solishtirganda, VGG16 ning parametrlarga boy, ResNet50 ning qoldiq ulanishlarga asoslangan va InceptionV3 ning ko‘p masshtabli yondashuvlariga nisbatan DenseNet169 ning konkatenatsiya tamoyili o‘ziga xos afzalliklar beradi. Amaliy ilovalar — tibbiyot, qishloq xo‘jaligi, sanoat nazorati va boshqa sohalarda — DenseNet169 o‘tkazma o‘rganish bilan birgalikda kuchli va ishonchli vosita bo‘lib xizmat qiladi. Kelgusida bu arxitekturaning transformator asosidagi modellar bilan integratsiyasi yanada qiziqarli natijalar berishi kutilmoqda.

Adabiyotlar ro‘yxati

1. Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 4700-4708).

2. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 770-778).

3. Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.

4. Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 2818-2826).

5. Rajpurkar, P., Irvin, J., Ball, R. L., Zhu, K., Yang, B., Mehta, H., ... & Lungren, M. P. (2017). Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. arXiv preprint arXiv:1711.05225.

6. Tan, M., & Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. In International conference on machine learning (pp. 6105-6114). PMLR.

7. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.

8. Chollet, F. (2021). Deep Learning with Python, Second Edition. Manning Publications.