

O'LCHAMGA XOS DETEKTORLAR GURUHIDAN FOYDALANGAN HOLDA SUN'IY YO'LDOSH TASVIRIDAN BINOLARNI ANIQLASH

Mashanpin Timur Vasikovich

*O'zbekiston Respublikasi "UNICON.UZ" DUK AKTni rivojlantirish va joriy etish
bo'yicha direktornong birinchi o'rinbosari*


Tavakkalov Muzaffarjon Murodiljon o'g'li

*O'zbekiston Respublikasi Muhammad al – Xorazmiy nomidagi Toshkent Axborot
texnologiyalari universiteti, Kompyuter tizimlari kafedrasini, Geoaxborot tizimlari va
texnologiyalari yo'nalishi magistranti.*

Annotatsiya. So'nggi yillarda konvolyutsion neyron tarmoqlari (KNT) binolarni aniqlash vazifalarida juda yuqori samaradorlikni ko'rsatmoqda. Ko'p yutuqlarga erishilgan bo'lsa-da, o'tmishda yaxshi ko'rib chiqilmagan ikkita jihat bor: bino hajmining keng o'zgarishini qanday hal qilish va yo'llar kabi kontekst ma'lumotlarini qanday qilib yaxshi birlashtirish kerak. Ushbu savollarga javob berish uchun biz oddiy, lekin samarali ko'p vazifali modelni taklif qilamiz. Model bir nechta detektorlarni o'rganadi, ularning har biri ma'lum bir o'lchamdagi binolarga bag'ishlangan. Bundan tashqari, model kontekst ma'lumotlaridan bir vaqtning o'zida binolarni aniqlash vazifasi bilan birga yo'lni ko'chirish vazifasini o'rgatish orqali bilvosita foydalanadi. Yo'l ekstraktori boshqa oldindan o'rgatilgan KNT dan bilimlarni to'plash orqali o'qitiladi, mashg'ulotlarda yo'llar uchun hech qanday yorliq kerak emas. Tajribalarimiz shuni ko'rsatadiki, taklif qilingan model binolarni aniqlashning aniqligini sezilarli darajada yaxshilaydi.

Kirish: Binolarni masofaviy zondlash tasvirlaridan avtomatik aniqlash uzoq vaqtdan beri maqsad bo'lib kelgan. Vazifa katta ahamiyatga ega, chunki qurilish xaritalari marketing, shahar boshqaruvi va mashhurlikni baholash kabi turli xil ilovalar uchun asosiy ma'lumotlarni taqdim etadi. So'nggi yillarda konvolyutsion neyron tarmoqlari (KNT) qurilishni aniqlash vazifalarida juda yuqori samaradorlikni ko'rsatmoqda. Ko'p yutuqlarga erishilgan bo'lsa-da, yaxshi ko'rib chiqilmagan ikkita jihat bor.

Bir jihati - bino hajmining o'zgarishi. 1-rasmda DeepGlobe tanlovida foydalaniladigan ma'lumotlar to'plamidagi binolar o'lchamlari taqsimoti ko'rsatilgan. Rasmda biz bino o'lchamidagi keng xilma-xillikni ko'rishimiz mumkin. Ko'pgina hollarda, katta binolar va kichik binolar juda ko'p turli xil vizual ko'rinishga ega (masalan, katta savdo markazi va kichik uy). Bundan tashqari, cheklangan fazoviy o'lchamlari tufayli, kichik binolar kattaroq bo'lsa ham, kattaroq binolar bilan bir xil bo'lmaydi. Bunday o'zgarishlarga qaramay, oldingi ishlar barcha binolarni bitta sinfga bo'lib, ulardagi o'zgarishlarni yaxshi hisobga olmaydi.



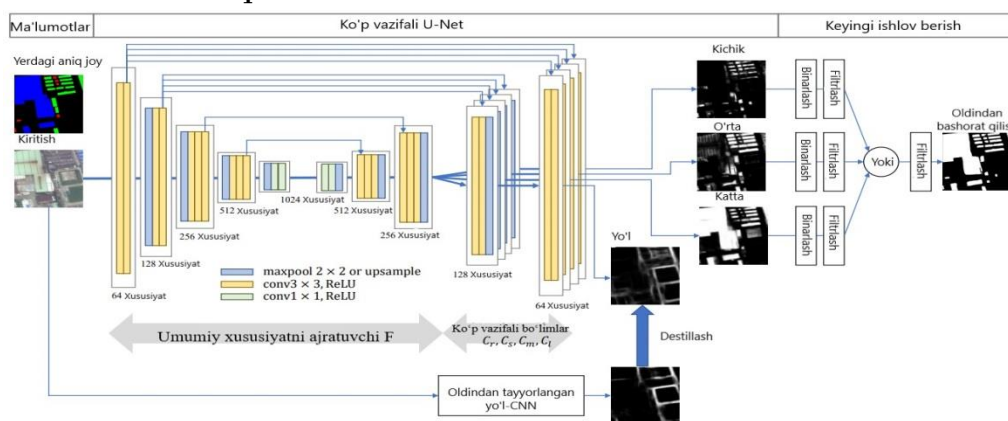
1-rasm. DeepGlobe tanlovida foydalanilgan ma'lumotlar to'plamida bino hajmining taqsimlanishi .

Ushbu maqoladagi o'zgarishlarni bartaraf etish uchun biz turli o'lchamdagi binolarni aniqlashni turli vazifalar sifatida ko'rib chiqamiz. Xususan, biz binolarning har bir o'lchamini aniqlash uchun o'lchamlarga xos detektorlarni o'rganadigan ko'p vazifali modelni taklif qilamiz. Ko'p vazifali modellashtirish topshiriq uchun mos keladi. Pastki darajalarda detektorlar barcha binolar uchun umumiy xususiyatlarni baham ko'rishlari mumkin, yuqori darajalarda esa har bir turdagi binolar uchun o'ziga xos xususiyatlarni o'rganishga e'tibor qaratishlari mumkin.

Boshqa jihat - kontekst ma'lumotlaridan foydalanish. Binolar atrofidagi kontekst ma'lumotlari ba'zan foydali bo'ladi. Ayniqsa, yo'llar haqidagi ma'lumotlar binolarni tanib olishga yordam beradi, chunki ular o'rtasidagi birgalikda sodir bo'ladi. Aslida, binolarni aniqlashning aniqligi bir vaqtning o'zida binolarni va yo'llarni aniqlaydigan ko'p toifali modelni o'rgatish orqali yaxshilanadi.

Muammolardan biri shundaki, ularning ko'p sinfli segmentatsiya modelini o'rgatish uchun ular ikkala sinf uchun yorliqlarga ega bo'lgan o'quv namunalari talab qiladi. Har bir sinf uchun faqat yorliqlari bo'lgan namunalarni o'qitish uchun ishlatib bo'lmaydi, bu esa mavjud o'quv namunalari sonini sezilarli darajada cheklaydi.

Mavjud barcha yorliqlardan to'liq foydalanish uchun biz yuqorida aytib o'tilgan tavsiya etilgan ko'p vazifali modelga yo'l ko'chirish bo'limini qo'shishni taklif qilamiz. Bo'lim o'qituvchi sifatida boshqa yo'l ko'chirish modelidan foydalangan holda bilimlarni distillash orqali o'qitiladi. O'qituvchi modelining chiqishidan yerdagi aniqlangan joy sifatida foydalanish orqali yo'lni ko'chirish bo'limi faqat qurilish belgilariga ega bo'lgan namunalarda uchun ham o'qitilishi mumkin.



2-rasm. Taklif etilayotgan usulning umumiy ko'rinishi. Ko'p vazifali U-Net (Markaz) umumiy xususiyatni ajratib chiqaruvchi F va Cr, Cs, Cm va Cl ketma-ket ko'p vazifa tarmoqlaridan iborat. Model kirish sifatida RGB tasvirlarini oladi va to'rt turdagi ehtimollik xaritalarini chiqaradi: biri yo'lni aniqlash natijalari uchun va uchta binoni aniqlash natijalari uchun. Uchta natijaning har biri "kichik", "o'rta" va "katta" o'lchamdagi binolarga mos keladi. Yo'l ko'chirish bo'limi boshqa oldindan tayyorlangan CNN modelidan bilimlarni distillash orqali o'qitiladi. Binoni aniqlash bo'limlari chap tomonda ko'rsatilgan ko'p o'lchamli yorliqlar yordamida o'qitiladi. Yorliqlarda qizil, yashil va ko'k ranglar mos ravishda "kichik", "o'rta" va "katta" binolarni ifodalaydi. Va nihoyat, binolarning har bir o'lchami uchun natijalar keyingi ishlov berishda yakuniy bashorat natijasiga birlashtiriladi (o'ngda).

Bizning tajribalarimizda bilimlarni distillash bilan taklif qilingan ko'p vazifali model ishlashning sezilarli yaxshilanishini ko'rsatadi. Barcha tajribalar DeepGlobe tanlovi ishtirokida o'tkaziladi.

Usullar 1. Umumiy ko'rinish

2-rasmda tavsiya etilgan modelning umumiy ko'rinishi ko'rsatilgan. Model arxitekturasi U-Net-ga asoslangan. Umumiy xususiyatni ajratib chiqaruvchi F model va Cr, Cs, Cm va Cl ketma-ket ko'p vazifali tarmoqlardan iborat. Bo'limlarning har biri turli vazifalarni hal qiladi: yo'l ko'chirish (Cr) va o'lchamga xos binoni aniqlash (Cs, Cm, Cl). Yo'qotish funksiyasi har bir bo'limdan yo'qotishlar yig'indisi sifatida aniqlanadi.

$$\mathcal{L} = \mathcal{L}_{kichik} + \mathcal{L}_{o'rta} + \mathcal{L}_{katta} + \mathcal{L}_{yo'l} \quad (1)$$

Quyida biz o'lchamlarga xos bo'lgan binolarni aniqlash bo'limi (2-bo'lim), yo'lni ko'chirish bo'limi (3-bo'lim) va keyingi ishlov berishni (4-bo'lim)da tushuntiramiz.

2. O'lchamga xos binolarni aniqlash

Taklif etilayotgan modelda uchta binoni aniqlash bo'limlari (Cs, Cm, Cl) mavjud bo'lib, ularning har biri "kichik", "o'rta" va "katta" binolarni aniqlash uchun javobgardir. Kirish $x \in X$ uchun bo'limlarning chiqishlarini quyidagicha yozish mumkin.

$$p^k = C_k(F(x)), k = \{s, m, l\} \quad (2)$$

Filiallarni o'rgatish uchun "binolarsiz", "kichik", "o'rta" va "katta" sinflarni belgilaydigan $\mathcal{Y}^i = \{c_n, c_s, c_m, c_l\}$ ko'p sinfli yorliqlar qo'llaniladi. E'tibor bering, ko'p toifali yorliqlarni tez-tez ishlatiladigan ikkilamchi bino yorliqlaridan olish mumkin. Yorliqlarning namunasi 2-rasmning chap tomonida ko'rsatilgan. Yorliqlardan foydalanib, "kichik" binolar uchun bo'limning yo'qotish funksiyasi bo'ladi.

$$\mathcal{L}_{kichik} = \sum_i I(\mathcal{Y}^i = c_s) \log p_i^s + I(\mathcal{Y}^i = c_n) \log(1 - p_i^s) \quad (3)$$

Bu yerda $I(\cdot)$ indikator funksiya bo'lib, agar argument to'g'ri bo'lsa 1 ni, noto'g'ri bo'lsa 0 ni qaytaradi. E'tibor bering, yo'qotish funksiyasida faqat kichik binolar yoki

binolarning piksellari yo'qotish qiymatiga ta'sir qiladi. Buning sababi shundaki, tarmoq doirasidan tashqarida bo'lgan piksellar (masalan, "o'rta" va "katta") kiruvchi xato signalini ishlab chiqaradi. Boshqa yo'qotish funktsiyalari ($\mathcal{L}_{or\text{ta}}$ va \mathcal{L}_{katta}) \mathcal{L}_{kichik} bilan bir xil tarzda aniqlanadi.

3. Yo'l ko'chirish modelidan distillash

C_r yo'l ko'chirish bo'limining chiqishi quyidagicha aniqlanadi.

$$p^r = C_r(F(x)) \quad (4)$$

Bo'lim yo'lni ko'chirish uchun boshqa ma'lumotlar to'plamidan foydalangan holda oldindan o'qitilgan o'qituvchi R modelidan bilimlarni distillash orqali o'qitiladi. X binoni aniqlash ma'lumotlar to'plamidagi har bir $x \in X$ tasviri uchun o'qituvchi modelning chiqishi quyidagicha hisoblanadi.

$$\hat{p} = R(x) \quad (5)$$

Trening davomida o'qituvchining \hat{p} chiqishi x kiritish uchun yerdagi aniq joy sifatida ishlatiladi. O'zaro entropiyadan foydalanib, bo'lim uchun yo'qotish funktsiyasi quyidagicha aniqlanadi.

$$\mathcal{L}_{yol} = \sum_i \hat{p}_i \log p_i^r + (1 - \hat{p}_i) \log(1 - p_i^r) \quad (6)$$

4. Keyingi ishlov berish

Qayta ishlashdan keyingi davrda har bir binoni aniqlash bo'limlaridan chiqish ehtimoli xaritalari birlashtiriladi. Integratsiya quyidagi bosqichlarda amalga oshiriladi. Birinchidan, chiqishlar oldindan belgilangan chegara yordamida binarlashtiriladi. Keyin har bir binarlashtirilgan xaritadan bino o'lchamidan tashqari yaroqsiz bino maskalari filtrlanadi. Keyin filtrlangan natijalar har bir piksel uchun mantiqiy yig'indini olish orqali birlashtiriladi. Va nihoyat, noto'g'ri bashorat sifatida juda kichik qurilish maskalari olib tashlanadi.

Binarizatsiya chegarasini aniqlash uchun o'lchamga xos bo'limlarning har biri tekshirish to'plamida baholanadi. Har bir bo'lim uchun eng yaxshi ishlash chegarasi [0,4, 0,6] oraliqdan tanlanadi, yerdagi aniq joy maskalarining tayinlangan o'lchamiga qarab hisoblangan eslash qiymati bo'yicha. Filtrlash diapazoni har bir tarmoq uchun belgilangan diapazonning pastki chegarasining yarmi va yuqori chegarasining ikki barobari bilan belgilanadi. Bu shuni anglatadiki, biz IoU > 0,5 ga ega bo'lishi mumkin bo'lgan barcha bashorat maskalarini o'zlariga tayinlangan diapazonda har qanday yerdagi aniqlangan joy maskalari bilan qoldiramiz. Modelning ishlashi filtr diapazonini tanlashga unchalik ta'sirchan bo'lmasa-da, biz juda qattiq filtrlash (masalan, filtrlash diapazoniga cheklov yo'qligi) yoki juda bo'sh filtrlash (masalan, filtrlashsiz) unumdorlikni pasaytiradi.

1 - Tajriba. Ma'lumotlar to'plami

Tajribalarimizda biz DeepGlobe tanlovida taqdim etilgan binolarni aniqlash ma'lumotlar to'plamidan foydalandik. Taqdim etilgan tasvirlar orasida biz 30 sm o'lchamdagi RGB tasvirlardan (keskinlashtirilgan RGB) foydalandik. Ichki tekshirish

uchun biz 10560 ta o'quv tasviridan tasodifiy tanlangan 300 ta rasmni ajratamiz. Maqolada biz modellarimizni baholash uchun tasdiqlash ma'lumotlaridan foydalandik. Mashg'ulotlar uchun 128×128 o'lchamdagi 5 million yamoq o'qitish tasvirlaridan kesilgan. Kesishda sinf muvozanati imkon qadar ko'rib chiqiladi. Bino o'lchamlari bo'linishini aniqlash uchun ma'lumotlar to'plamidagi bino hajmining kvadrat ildiziga k-o'rtacha klasterlash qo'llaniladi. Natijada, bo'linish quyidagicha bo'ladi: "kichik", "o'rta" va "katta" binolar uchun mos ravishda $S \leq 1150$, $1150 < S \leq 4540$ va $4540 < S$, bu erda S binoning piksel hajmini bildiradi. Ushbu maqolada biz faqat $k = 3$ ni sinab ko'rdik, lekin ko'proq yoki kamroq sinflarga ega bo'lish mumkin edi. Distillash uchun o'qituvchi modelini o'rgatish uchun biz tanlovning boshqa qismidan taqdim etilgan yo'l ko'chirish ma'lumotlar to'plamidan foydalandik.

1-jadval. DeepGlobe tanlovining ichki tekshirish to'plami va yakuniy bosqich test to'plamida baholangan har bir model uchun F1 ballari. Tasdiqlash to'plami uchun F1 ballari binolarning har bir o'lchami, shuningdek, umumiy binolar uchun ko'rsatiladi.

Model	F1 @ qiymat				F1 @ yakuniy
	kichik	o'rta	katta	umumiy	umumiy
VGG U-Net	45.07	80.24	80.04	67.4	-
+ Aug.	38.48	79.41	79.75	65.36	-
+ distil	47.27	81.69	79.83	68.95	-
+SS	53.91	85.11	84.83	72.36	-
+SS+Distil	53.65	85.28	83.49	72.32	-
Ansambl	54.70	85.52	85.12	73.04	71.99
Res-U-Net	50.51	83.97	82.88	71.60	-
+SS	56.92	85.89	86.12	74.41	73.70
Ansambl	56.90	86.51	85.96	74.67	73.91

2-jadval. Ko'p vazifali detektorlar uchun bo'lim nuqtasini tanlash uchun F1 ball. Har bir model uchun bo'lim nuqtasining holati dekoderdagi 3-blokdan 5-blokga o'zgartiriladi (ya'ni, pastdan yuqori qatlamga)


Model	Bo'lim nuqtasi		
	3-blok	4-blok	5-blok
VGG-U-Net+Distil	70.31	69.91	70.25
VGG-U-Net+SS	72.18	71.76	69.25

Ekspirimental sozlashlar

Biz U-Net arxitekturasi ikki turini asos sifatida quramiz: VGG-U-Net va Res-U-Net. Har bir arxitekturada VGG16-ning pool4 xususiyatlaridan va mos ravishda

Resnet-18-ning conv5 xususiyatlaridan, har biridan keyin ReLU faollashtirish funksiyalari bilan ikkita 3×3 konvolyutsiyadan iborat kodlovchi mavjud. Xususiyatlar xaritalarining o'lchamlari kichik binolarni aniqlash uchun muhim bo'lganligi sababli, biz Res-U-Net uchun kichik o'zgarishlar kiritdik: biz Resnet-18 dan birinchi maksimal yig'ish qatlamini yo'q qildik va conv1 qadamini 2 dan 1 ga o'zgartirdik. Natijada , enkoder chiqishining global qadami 16 ga aylanadi, bu VGG-U-Net bilan bir xil. Ikkala arxitektura uchun dekoderlar kodlovchilar sifatida simmetrik arxitektura ega. Keyinchalik, ushbu bazaviy ko'rsatkichlar taklif qilingan ko'p vazifali U-Net tarmog'iga bir nechta filiallarni qo'shish orqali kengaytiriladi, ya'ni o'lchamga xos bo'limlar (SS), yo'l ko'chirish shoxobchasi (Distil) va ularning kombinatsiyasi (SS+Distil). Barcha filiallar bir xil arxitektura ega va ular dekoderning to'rtinchi blokida tarmoqlanadi (VGG-UNet+SS+Distil uchun 2-rasmga qarang).

Shuningdek, biz taklif etilayotgan usulni ko'p miqyosli o'qitish bilan solishtiramiz, bu turli xil miqyosdagi ob'ektlar bilan ishlashda keng tarqalgan yondashuv. Xususan, VGG-U-Net-ni o'rgatish jarayonida biz tasodifiy ravishda kiritilgan tasvirlarni 0,5 1,0 va 2,0 (VGG-U-Net+Aug.) koeffitsienti bilan o'lchaymiz. Garchi biz sinov vaqtida ko'paytirishni ham sinab ko'rgan bo'lsakda, bu samaradorlikni sezilarli darajada yomonlashtirdi, chunki kichikroq kirishlardagi yaqin atrofdagi binolar haddan tashqari segmentlangan va bitta katta maskalarga kiritilgan.



3-rasm. Res-U-Net oilasining guruh modelining misol natijalari. 3-5-ustunda o'lchamga xos bo'lgan tarmoqlarning chiqish ehtimoli xaritalari ko'rsatilgan va keyingi ishlov berishdan keyingi yakuniy bashorat natijalari oxirgi ustunda ko'rsatilgan.

Tarmoqlarni ishga tushirish uchun ImageNet-da oldindan o'rgatilgan og'irliklar kodlovchidagi qatlamlar uchun ishlatiladi va boshqa qatlamlar yordamida ishga tushiriladi. ADAM $1,0e-4$ boshlang'ich o'rganish tezligi va $5,0e-4$ vazn pasayish koeffitsienti bilan optimallashtirish uchun ishlatiladi. O'rganish tezligi o'quv iteratsiyasi bilan birga chiziqli ravishda pasayadi.

Yo'lni ko'chirish uchun o'qituvchi modeli VGG U-Net bilan bir xil arxitektura va bir xil o'quv sozlamalariga ega.

Natijalar

1-jadvalda har bir model uchun baholash natijalari ko'rsatilgan. Asosiy ko'rsatkichlar bilan taqqoslaganda, yo'l ko'chirish bo'limi (+Distil) va o'lchamga xos bo'limlar (+SS) qo'shilishi samaradorlikni oshiradi. Yaxshilash, ayniqsa, "kichik" binolar uchun katta. Ikkala bo'limning kombinatsiyasi (+SS+Distil) unumdorlikni yanada oshirmaydi, lekin o'ziga xos o'lchamdagi bo'limlar bilan raqobatdosh ishlashni ko'rsatadi. Asosiy arxitekturani VGG16 dan Resnet-18 ga o'zgartirish orqali unumdorlikning katta o'sishiga erishiladi. 2-jadval bo'lim nuqtasini tanlashga nisbatan sezgirlikni o'rganadi. Muayyan o'lchamli bo'limlar (+SS) bo'lsa, dekoderda erta bo'linish yaxshiroq ko'rinadi, yo'l ko'chirish bo'limida (+Distil) bo'lim nuqtasini tanlash unumdorlikka unchalik ta'sir qilmaydi.

Ishlash samaradorligini oshirish texnikasi

1-jadvaldagi barcha natijalar sinov vaqtini ko'paytirish orqali olingan. Sinov tasvirlarining har biri aylanish (0, 90, 180 va 270 daraja) va aylantirish (vertikal va gorizontal) bilan 6 marta ko'paytiriladi va chiqishlar kengaytirilgan kirishlar bo'yicha o'rtacha hisoblanadi. Bundan tashqari, biz guruh modellarini eng yuqori sifatli modellarning chiqishini o'rtacha hisoblab yaratamiz. Biz VGG-U-Net oilasi uchun sakkizta model va Res-U-Net oilasi uchun to'rtta modeldan foydalandik. 1-jadvalda ko'rsatilganidek, Res-U-Net oilasi guruhi bizning ichki tekshirish ballimiz va yakuniy test balimiz bo'yicha eng yaxshi natijalarni ko'rsatadi. Guruh modelining ba'zi namunalari 3-rasmda ko'rsatilgan.

Xulosa: Ushbu maqolada biz turli o'lchamdagi binolar bilan samarali kurasha oladigan ko'p vazifali binolarni aniqlash modelini taklif qildik. Bundan tashqari, model yo'l belgilaridan foydalanmasdan yo'l haqidagi ma'lumotdan bilvosita foydalanadi. Taklif etilayotgan model an'anaviy U-Net modeliga nisbatan sezilarli yaxshilanishga erishdi. Ushbu maqolada biz binolarni aniqlash vazifasini o'lcham omili bilan birga kichik vazifalarga ajratsak ham, shaklning murakkabligi yoki me'moriy uslublar kabi o'rganishga arziydigan boshqa omillar ham mavjud. Bundan tashqari, yangi savol tug'iladi: optimal pastki vazifa dekompozitsiyasini avtomatik ravishda aniqlash usuli bormi? Biz bu narsalarni kelajakdagi ish uchun qoldiramiz

FOYDALANILGAN ADABIYOTLAR:

1. Chuqur neyron tarmoqlar bilan izlarni qurish segmentlarini ajratish uchun ko'p vazifalarni o'rganish. arXiv preprint arXiv:1709.05932, 2017. 1
2. I. Demir, K. Koperski, D. Lindenbaum, G. Pang, J. Huang, S. Basu, F. Xyuz, D. Tuia va R. Raskar. Deepglobe 2018: Yerni sun'iy yo'ldosh tasvirlari orqali tahlil qilish muammosi. arXiv preprint arXiv:1805.06561, 2018. 1, 2, 3
3. R. Xamaguchi, A. Fujita, K. Nemoto, T. Imaizumi va S. Hikosaka. Masofaviy zondlash tasvirlarida kichik ob'ekt misollarini segmentlash uchun kengaytirilgan konvolyutsiyalardan samarali foydalanish. 2018-yilda IEEE Qishki Konferentsiyasi Kompyuter Vision ilovalari (WACV), 2018. 3
4. G. Xinton, O. Vinyals va J. Din. Neyron tarmoqdagi bilimlarni distillash. NIPS 2014 Deep Learning Workshop, 2014. 1
5. V. Iglovikov, S. Mushinskiy va V. Osin. Chuqur konvolyutsion neyron tarmog'idan foydalangan holda sun'iy yo'ldosh tasviri xususiyatini aniqlash: Kaggle musobaqasi. arXiv preprint arXiv:1706.06169, 2017. 1
6. E. Maggiori, Y. Tarabalka, G. Charpiat va P. Alliez. Masofadan zondlash tasvir tasnifi uchun to'liq konvolyutsion neyron tarmoqlar. 2016 IEEE xalqaro geofan va masofadan zondlash simpoziumi (IGARSS), 2016. 1
7. O. Ronneberger, P. Fisher va T. Broks. U-net: biotibbiy tasvir segmentatsiyasi uchun konvolyutsion tarmoqlar. MICCAI, 234–241-betlar, 2015. 2
8. S. Saito, T. Yamashita va Y. Aoki. Konvolyutsion neyron tarmoqlari yordamida havo tasviridan bir nechta ob'ektni olish. Imaging Science and Technology jurnali, 60, 2016. 1
9. J. Yuan. Konvolyutsion tarmoqlardan foydalangan holda havo sahnalarida binolarni avtomatik ravishda qazib olish. arXiv preprint arXiv:1602.06564, 2016. 1