

UO'K 004.8, 004.93

QUYI VA O'RTA DARAJADAGI DESKRIPTORLAR ASOSIDA MASOFADAN OLINGAN TASVIRLARDI SAHNANI TASNIFLASH ALGORITMLARI

⁺Yusupov O.R.¹, Xandamov Y.X.², Eshonqulov E.Sh.¹

¹ Sharof Rashidov nomidagi Samarqand davlat universiteti, Samarqand, O'zbekiston

² Raqamli texnologiyalar va sun'iy intellekt rivojlantirish ilmiy-tadqiqot instituti, Toshkent, O'zbekiston

⁺ozodyusupov@gmail.com

Annotatsiya. Masofaviy zondlash tasvirlarini tahlil qilishda sahnani tasniflash muhim masalalardan biri hisoblanadi. Ushbu maqolada tasvir deskriptorlarini shakllantirish va sahnani tasniflash uchun mashinaviy o'qitish algoritmlarining qo'llanilishi o'rganildi. Tadqiqot doirasida past, o'rtada va yuqori darajadagi deskriptorlardan foydalanildi, jumladan, Local Binary Pattern (LBP), Histogram of Oriented Gradients (HOG), Scale-Invariant Feature Transform (SIFT), Oriented FAST and Rotated BRIEF (ORB), BRISK va BRIEF kabi deskriptorlar sinovdan o'tkazildi. Sahna tasniflash uchun SVM, Random Forest, Decision Tree, Naive Bayes, kNN, Logistic Regression algoritmlaridan foydalanildi. Tadqiqot natijalari deskriptorlar va klassifikatorlar kombinatsiyasining samaradorligini baholashni ko'rsatdi, bunda SIFT deskriptori eng yaxshi natijalarni taqdim etdi. Ammo umumiy natijalar sahnani tasniflashda yanada yuqori aniqlikka erishish uchun usullarni takomillashtirish zarurligini ko'rsatdi. Ushbu tadqiqot masofadan zondlash tasvirlarida sahnalarni tasniflash uchun quyida va o'rtada darajadagi deskriptorlar asosida algoritmlarni ishlab chiqish va qo'llash masalalarini o'rganadi. Tasvirlarni aniqlik bilan tasniflash uchun asosiy atributlar (masalan, tasvir o'lchamlari va formatlari), vizual xususiyatlar (masalan, rang va naqshlar), semantik ma'lumotlar (kontekstual bog'liqlik) va geometrik mosliklarni ifodalovchi deskriptorlarni shakllantirish muhim hisoblanadi. Tadqiqot ikki asosiy bosqichni o'z ichiga oladi: belgilarni ajratib olish va mashinaviy o'qitish algoritmlari (kNN, Naive Bayes, tasodifiy o'rmonlar, SVM, va logistika regressiyasi) asosida klassifikatorni o'qitish. Tadqiqot NWPU-RESISC45 ma'lumotlar to'plamida o'tkazilib, 45 turdagi sahna sinfi bo'yicha tasniflash amalga oshirildi. Natijalar SIFT va boshqa deskriptorlarning yuqori aniqlikka ega ekanligini ko'rsatadi, ammo tasniflash ko'rsatkichlarini yaxshilash uchun yanada tadqiqotlar olib borish talab qilinadi.

Kalit so'zlar: sahnali tasniflash, masofaviy zondlash tasviri, belgilar, deskriptor, klassifikator, NWPU-RESISC45.

1 KIRISH

Tasvirlardagi obyektlarni qidirish va tasniflash kompyuterli ko'rishi va sun'iy intellekt sohalarida asosiy masalalardan biridir. Tasvirlarni to'g'ri va yuqori aniq tasniflash uchun muhim belgilarni shakllantirish, ya'ni deskriptorlar qurish jarayoni bir qator bosqichlarni o'z ichiga oladi. Tasvir deskriptori qurishda asosiy belgilar, vizual belgilar, shakl va tuzilma, semantik belgilar, kontekstli ma'lumotlar, dastlabki ishlov berish jarayonlaridan foydalaniladi. Bu har bir jarayon, tasvirning o'ziga xos belgilarini aniqlash va tasniflash jarayonida yuqori aniqlikni ta'minlash bilan bog'liqdir. Masalan, asosiy belgilar tasvirning o'lchamlari, rang maydoni va fayl formatini o'z ichiga olgan holda, vizual belgilar ranglar gistogrammasi va naqshlar xususiyatlarini o'z ichiga oladi. Shuningdek, semantik belgilar obyektini aniqlash va sahnaga asoslangan tanib olish orqali tasvirlar o'rtasidagi kontekstual bog'liqlikni aniqlashga imkon beradi [1, 2].

Tasvirlarni taqqoslash (Image matching) bir xil sahnaning turli tomonlardan, bir xil yoki turli vaqtlarda, bir xil yoki turli qurilmalar yordamida olingan ikki yoki undan ortiq tasvirlarini geometrik jihatdan mosligini tekshirishdir. Bu tasvirni tahlil qilishdagi masalalar biri bo'lib, kompyuterli ko'rish va timsollarni tanib olish sohalarida keng qo'llaniladi. Tasvirlarni taqqoslash usullari ikki sinfga ajratiladi: sohaga asoslangan usul (area-based method) va belgilarga asoslangan usul (feature-based method) [3]. Sohaga asoslangan usullar tasvirlarning muhim belgilari shakllantirmasdan, optimallashtirish algoritmlaridan foydalangan holda etalon va berilgan tasvirlarning mos piksellar o'xshashligini baholash bilan aniqlashga

qaratadi [1, 4-7]. Bunday usullar intensivlik taqsimoti, yoritilgan sharoitlarini o'zgaruvchanligi, shovqinlar va murakkab geometrik deformatsiyalar mavjud bo'lgan tasvirlarni taqqoslash samarasiz natijalarga olib keladi. Belgilarga asoslangan usullar intensivlik taqsimoti, yoritilgan sharoitlarini o'zgaruvchanligi, shovqinlar va murakkab geometrik deformatsiyalar natijasida tasvirlarda bo'ladigan o'zgarishlarda keng qo'llaniladigan usullar hisoblanadi [8]. Bu usullar tasvir intensivligi qiymatlari taqqoslash o'rniga ikkita tasvirdan olingan belgilardan bevosita foydalanib tasvirlarni taqqoslash amalga oshiriladi. Bu usulni ko'p qo'llaniladigan masalalaridan biri masofadan zondlash va geoinformatsion tizimlar hisoblanadi [9].

Hozirgi kunda masofaviy zondlash asosida olingan tasvirlar masofaviy zondlash sahnalarini tasniflash, giperspektral tasvirlarni tasniflash, o'zgarishlarni aniqlash, geografik tasvirlar va yerdan foydalanish tasniflash kabi ko'plab amaliy masalalarni yechishda qo'llanilmoqda [1, 2, 10-13]. Biroq, masofaviy zondlash asosida olingan tasvirlarining murakkab fazoviy pattern egaligi va geografik struktura tasvirlarini tasniflashda yuqori murakkablikka olib keladi. Xususan, masofadan zondlash asosida olingan tasvirlari yer yuzasidagi obyektlar haqida batafsil fazoviy va semantik ma'lumotlarni taqdim etishi bilan birga ko'p holatlarda katta hududni qamrab oladi. Bunday tasvirlar yer yuzasidagi kerakli bo'lgan hududlarni yaxshiroq tahlil qilish uchun sahnalarga ajratiladi. Har bir sahna haqida to'liq ma'lumot olish strategik amaliyotlarning rivojlanishi uchun qimmatli ma'lumotlarni taqdim etadi [14-18]. Bu vazifani amalga oshirishda har bir sahna uchun semantik tarkibi nisbatan tegishli yorliq (sinf)ni aniqlash usuli bo'lgan **sahnali tasniflashdan foydalaniladi** [19].

Tabiiy tasvirlardagi sahnali tasniflashdan farqli ravishda masofadan zondlash tasvirlarida yer yuzasidagi obyektlarning murakkab tuzilish taqsimlanishga ega bo'ladi. Bu sabab bu tasvirlar makroskopik qamrov ega va biror sahnada odatda turli obyektlar joylashgan bo'ladi [20]. Bunga namuna qilib, masalan, "aeroport" sahnasi keltirsak, unda samolyotlar, avtomagistral, uchish-qo'nish yo'lagi va binolar obyektlar mavjud bo'ladi. Bunday tashqari, sahnalar orasidagi fazoviy, spektral va radiometrik ruxsatlarning bir xil emasligi, masshtab turli xilligi, piksel intensivligi, yorqinlik, kontrast kabi o'zgarishlar sababli sahnalarni tasniflashga aniqligi katta ta'sir ko'rsatadi.

1-rasmda ko'rish mumkinki, masofaviy zondlash tasvirlaridagi sahnalar, masalan, avtomagistral, yo'l o'tkazgich va uchish-qo'nish yo'lagi, tashqi ko'rinish bo'yicha bir-biriga o'xshash xususiyatlarga ega bo'lib, sahna ichida yuqori xilma-xillikni keltirib chiqaradi. Bundan tashqari, turli sinflarga mansub sahnalardagi bir xil obyektlar (masalan, binolar o'rta zichlikdagi va yuqori zichlikdagi yashash joylari sinflarida uchraydi) sahnalar o'rtasida past farqlanishga olib keladi. 1-rasmdan masofaviy zondlash tasvirlari bitta sinf tegishli sahnalarni xilma-xilligini va sinflararo kichik farqlanishni ko'rish mumkin. Sahnalar sinflar ichida ko'pincha kichik darajadagi vizual o'xshashliklar va obyektlar ega bo'lganligi sababli, faqat pikselar yoki obyektlar darajasini modellashtiradigan usullar sahnalarni tasniflash vazifasini yaxshi bajarish uchun yetarli bo'lmadi. Aslida, bu sahna turlaridagi obyektlar va hududlar o'rtasidagi bog'liqlikni yuqori darajada tushunishni va tavsiflashni talab qiladi. Masalan, rezidential (yashash hududlari) va industrial (sanoat) sahnalari sun'iy qurilmalar, yo'llar va daraxtlarni o'z ichiga olishi mumkin. Shunday qilib, sahnalarni tasniflash yondashuvlari tasvirdan qo'pol va nozik xususiyatlarni tavsiflay olishi, shuningdek, ushbu semantik elementlarning fazoviy ko'rinishi va bog'liqliklarini hisobga olishi kerak.

Sahnalarni tasniflash masalasi ikki bosqichda yechish amalga oshiriladi. Birinchi bosqichda, tasvirdan belgilar to'plamini ajratib olish. Ikkinchi bosqichda esa, ajratilgan belgilar to'plami asosida klassifikatorni o'qitish. Bu bosqichlar natijasida, klassifikator turli semantik sinflarga ajratadi. Ajratib olinadigan belgilar turiga qarab, kNN, Naïve Bayes, oddiy chiziqli tasniflash, random forest (tasodifiy o'rmon), support vector machines (SVM, tayanch vektorlar usuli) kabi klassifikatorlar qo'llanishi mumkin.

Masalaning qo'yilishi. Masofadan zondlash asosida olingan tasvirlarda turli sahnalarni ko'p sinfli tasniflash masalasi hisoblanadi. Masaladagi sahnalarda qishloq manzarasi, shaharning ko'cha ko'rinishi, binolar, (uy, ofis), o'rmon, plyaj va boshqalar bo'lishi mumkin. Masalani murakkabligi turli sinflarga tegishli sahnalarda o'xshash obyektlar mavjudligi va bitta sinfga tegishli sahnalarning turli-xilligi tasniflash aniqligi kamaytirish olib keladi. Shu sababli masala yechimi oshirish qaratilgan yechimni amalga oshiruvchi algoritmlarni ishlab chiqish va ular ustida tajribaviy tadqiqotlar olib borishga qaratiladi.

Yondashuvni amalga oshirish.

Tasvirlarda sahnani tasniflash masalasi yechish ikki bosqichda amalga oshiriladi.

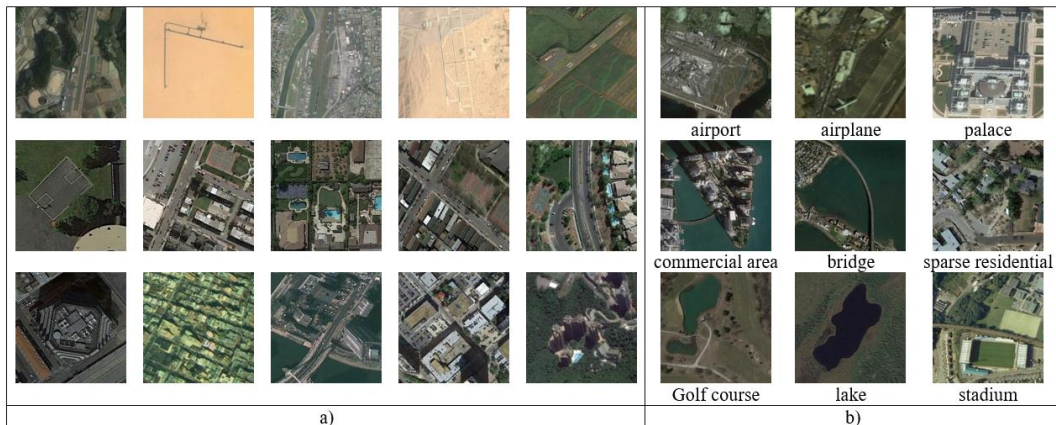
1-bosqich. Tasvirning semantik mazmuni ifodalovchi belgilarni ajratish.

2-bosqich. Shakllantirilgan belgilar asosida sahnaning sinfini aniqlovchi klassifikatorni qurish.

2 BELGILARNI AJRATIB OLISH USULLARI

So'nggi o'n yilliklarda sun'iy yo'ldosh qurilmalari asosida olingan sahnalarni tasniflash uchun bir qator usullarni ishlab chiqish bo'yicha faol ilmiy tadqiqotlar olib borilmoqda. Sahnalarni tasniflash odatda belgilar fazosida amalga oshirilganligi sababli, muhim belgilar to'plami asosida yuqori aniqlikdagi

sahnalarni tasniflash usul va algoritmlari ishlab chiqishda muhim rol o'ynaydi [1, 22]. [23] da mavjud sahnalarni tasniflash usullarida foydalanadigan belgilarni uchta asosiy sinfga ajratilgan: qo'lda yaratilgan belgilarga asoslangan usullar; nazoratsiz o'qitishga asoslangan belgilar usullari; chuqur o'qitishga asoslangan belgilar usullari. Shuni ta'kidlash kerakki, ushbu uchta sinf bir-biridan mustaqil bo'lmashligi mumkin va ba'zan bir xil usul turli sinflarga tegishli bo'lishi mumkin.



1-rasm. NWPU-RESISC45 ma'lumotlar bazasidan namunalar [21]:
(a) sinf ichidagi xilma-xillik. b) sinflararo o'xshashlik

Ushbu bo'linish tasvirni tavsiflashda qo'llaniladigan belgilarning murakkabligi va semantik mazmuniga bog'liq ravishda farqlanadi. Past darajadagi belgilar rang, tekstura va shakl kabi oddiy statistik belgilarga asoslangan bo'lsa, yuqori darajadagi belgilar chuqur o'rgatish (deep learning) orqali olingan semantik ma'lumotlarni o'z ichiga oladi. O'rta darajadagi belgilar esa ushbu ikki darajaning kombinatsiyasini tashkil etadi va ko'pincha obyekt darajasidagi ma'lumotlarni o'z ichiga oladi.

Tasvir sahnasini tasvirlash uchun past darajadagi belgilarni shakllantirishda rang, tekstura, shakl, spektral va fazoviy struktura kabi fazoviy belgilar muhim elementlar hisoblanadi. Umuman olganda, tasvirning lokal va global belgilari to'liq qamrab olish uchun bir nechta fazoviy belgilardan foydalanishni talab qilinadi.

Global belgilarning mosligi, masalan, rang gistogrammalari va tekstura deskriptorlari sahnani tasvirlashda va keyingi tasniflash hamda qidiruv masalalarida o'rganiladi. Global belgilardan farqli o'laroq, lokal belgilar tasvirni to'liq tasvirlash uchun qo'shimcha vazifalarni talab qiladi. Bunday vazifalarga belgilarni kodlash yoki yig'ish usullari (masalan, vizual so'zlar sumkasi — bag-of-visual-words, Fisher vektorlarini kodlash, fazoviy piramidali moslashish va boshqalar) kiradi [23].

Tasvirning lokal belgilari sahnani tasniflash uchun o'rta darajadagi (mid-level) vakillari orqali global belgilarga o'tkaziladi. [23, 24] ishlarida masofaviy zondlash tasvirlarini tasniflash uchun quyidagi belgilarni qurish usullari o'rganilgan: SIFT va BoVW, BoVW ning turli takomillashtirilganlari, BoVW va SPM belgilarning kombinatsiyalari, LLC.

Shuningdek, [25-27] manbalarda HOG belgilari asosida sahnalarni tasniflash usullari o'rganilgan. [28, 29] da klassifikatorlarni birlashtirish yondashuvlari asosida lokal va global belgilarning qurish usullaridan bir nechtasidan foydalanib, sahnani tasniflashni amalga oshirish taklif etilgan. Biroq, faqat past darajadagi belgilar bilan yuqori aniqlikda masofaviy zondlash asosida olingan tasvirlarning o'ziga xoslik xususiyatlarini to'liq ifoda etuvchi samarali o'rta darajaga kiruvchi usullarni yaratish murakkab masala hisoblanadi.

Yuqori darajadagi belgilarni ajratish chuqur neyron tarmoqlar asosida amalga oshiriladi. Bu usullar o'zlarining o'tkazuvchanlik va umumlashtirish imkoniyatlariga egadir. Chuqur neyron tarmoq asosida belgilarni ajratish usullari oldindan o'qitilgan modellar (pretuning), transfer o'qitish (Transfer Learning), Fine-tuning, Multiscale pooling strategiyasi va kovariatsiya deskriptorlariga ajratiladi. Oldindan o'qitilgan modellar AlexNet, VGG, ResNet, GoogLeNet kabi modellar ImageNet singari katta ma'lumotlar to'plamida o'qitiladi. Ushbu modellar asosida boshqa turdagi masalalarda belgilar shakllantirishda asos sifatida foydalaniladi. Transfer Learning oldindan o'qitilgan modelning ba'zi qatlamlaridan foydalanib, yangi masalalar uchun moslashtirilgan belgilar shakllantiriladi. Fine-tuningda oldindan o'qitilgan model yangi domen yoki ma'lumotlar to'plamiga moslashtiriladi. Multiscale pooling strategiyasida belgilarning invariantligini ta'minlash uchun bir nechta masshtablarda belgilarni qayta ishlash amalga oshiriladi. Bu murakkab va o'lichamlari turlicha bo'lgan obyektlarni aniqlashda yaxshi natija beradi. Kovariatsiya deskriptorlari turli qatlamlardan olingan belgilarni birlashtirishni amalga oshiradi. Bu esa murakkab obyektlarda keng qamrovli belgilarni hosil qiladi.

Mazkur tadqiqotning maqsadi yondashuvni amalga oshirish uchun tasvirlardan belgilarni ajratish olishning 3 ta sinflarining ba'zi usullarni tadqiq etish hamda mashinaviy o'qitish klassifikatorlari bilan birgalikda qo'llash algoritmlarini ishlab chiqishdir. Algoritmlar bo'yicha tajribaviy tadqiqotlar o'tkazilib, natijalar tahlili asosida tavsiyalar ishlab chiqish amalga oshiriladi.

Local Binary Pattern (LBP) algoritmi – bu tasvirni tahlil qilish uchun keng qo'llaniladigan, sodda va samarali deskriptor qurish usuli bo'lib, u asosan tekstura belgilarini shakllantirishni amalga oshiradi. LBP tasvir piksellari atrof-muhitining ikkilik ko'rinishdagi tavsifidir. Tasvirning ma'lum bir nuqtasida asosiy LBPda belgining qiymatini hisoblash uchun markaziy pikselga qo'shni piksellardan foydalaniladi va markaziy pikselning yorqinlik qiymati bo'sag'aviy qiymat (threshold) sifatida qabul qilinadi. Yorqinlik qiymati bo'sag'aviy qiymatdan katta yoki teng bo'lgan piksellar 1 qiymatiga, qolgan holatlarda esa 0 qiymatiga almashtiruvchi funksiya bilan amalga oshiriladi. Hisoblashni amalga oshirish ifodasi quyidagicha,

$$LBP(x, y) = \sum_{i=0}^{P-1} s(g_i - g_c) 2^i$$

bu yerda g_c markaziy pikselning yorqinlik qiymati, g_i P ta qo'shni piksellarning yorqinlik qiymati, $s(z)$ funksiya ifodasi quyidagicha bo'ladi,

$$s(z) = \begin{cases} 1, & z \geq 0; \\ 0, & z < 0. \end{cases}$$

Histogram of oriented gradients (HOG). HOG usulining asosiy g'oyasi lokal obyektlarning ko'rinishi va shakli lokal intensivlik gradiyentlar yoki chegaralar yo'nalishlari taqsimoti orqali aniq tavsiflanish mumkin deb faraz suriladi. HOG usuli tasvir lokal sohalardagi o'lchovlar taqsimotini umimlashtiradi va ayniqsa deformatsiyalanadigan shakllarga ega teksturali obyektlar uchun samaralidir. HOG belgisi tasvirdagi har bir maxsus nuqta (key point) uchun shakllantiriladi. Har bir maxsus nuqta atrofidagi sohalar bir necha bir xil masofadagi kichik soha(yacheyka)larga bo'linadi. Har bir yacheyka uchun gradiyent yo'nalishlari yoki chegaralar yo'nalishlari bo'yicha lokal gistogramma tegishli yacheykaning barcha piksellari bo'yicha hisoblash amalga oshiriladi. Bir maxsus nuqta atrofidagi barcha yacheykalarining gistogrammasining elementlari shu nuqtaning belgilarini hosil qiladi. Barcha maxsus nuqtalarning gistogrammalarini birlashtirilib, o'z navbatida, sintezlangan belgilar fazosidagi tasvirning bir butun sifatida tasvirini hosil qiladi.

Belgilar vektorini HOG usuli asosida aniqlash quyidagi tarzda amalga oshiriladi.

Agar maxsus nuqtaning lokal sohasini ifodalovchi tasvir oynasi yacheykalarga teng bo'lingan bo'lsa, u holda bu oynani quyidagicha ko'rsatish mumkin,

$$I = \bigcup_{t=1}^N C_t,$$

bu yerda C_t – t yacheykaga tegishli barcha piksellar to'plami.

I tasvirda joylashgan har bir piksel $p(x, y)$ uchun kontrast (magnituda) quyidagicha aniqlanadi,

$$g_p = g(x, y) = \sqrt{\Delta x^2 + \Delta y^2},$$

va gradiyent yo'nalishi esa quyidagicha hisoblanadi,

$$\theta_p = \theta(x, y) = \arctan \frac{\Delta y}{\Delta x}.$$

Gradiyent yo'nalishi H ta oraliqlarga (bins) bo'linadi. Bu bo'linish esa yacheyka uchun gistogramma vektorining uzunligi H ekanligini bildiradi. Keyin yacheyka uchun gistogramma vektorini quyidagicha hisoblash amalga oshiriladi,

$$b_t^i = \frac{\sum \{g_p \mid p \in C_t, \theta_p \in [i\theta_0 - \theta_0/2, i\theta_0 + \theta_0/2]\}}{|C_t|},$$

bu yerda $|C_t|$ – C_t to'plamning quvvati. t yacheyka uchun v_t gistogramma vektori quyidagi ifodalanadi:

$$v_t = \{b_t^0, b_t^1, b_t^2, \dots, b_t^{H-1}\}.$$

[30] da ta'kidlanganidek, HOG usulida yorug'lik va shovqinning yetarlicha o'zgarishligini ta'minlash uchun gistogramma vektorlarini hisoblash amalga oshirilgandan so'ng, bu vektorlarda quyidagi ifoda bo'yicha normallashtirish amalga oshiriladi,

$$v'_t = v_t / \sqrt{v_t^2 + \varepsilon^2},$$

bu yerda ε – bo'sh yacheykani hisobga oladigan regularizatsiyalash uchun qo'llaniladigan kichik musbat son.

SIFT. SIFT deskriptor – bu Gauss funksiyasi asosida kalit nuqtaning atrofidagi mahalliy gradiyentlarni hisoblash orqali hosil qilinadigan belgilar vektori. Deskriptorni qurish jarayonida kalit nuqtaning qo'shni nuqtalaridagi gradiyent yo'nalishlari aylana bo'ylab tahlil qilish bilan invariantlikka erishiladi. SIFT usuli tasvirni masshtablar, burish yoki piksel koordinatalarining o'zgarishlariga nisbatan invariant bo'lib, yacheykalardagi gradiyent taqsimotiga asoslanadi. SIFT algoritmi to'rtta asosiy qadamdan iborat:

1-qadam. Masshtab fazosida ekstremal qiymatlarni aniqlash. Ushbu qadamda Gauss farqi (Difference of Gaussian, DoG) funksiyasi yordamida tasvirning masshtab va yo'nalishi o'zgarish bo'lgan potensial kalit nuqtalari aniqlanadi. Bu nuqtalar tasvirning barqaror belgilarini aks ettiradi.

2-qadam. Kalit nuqtalarni lokallashtirish. Potensial kalit nuqtalar joylashuvi va masshtabi aniqlanadi. Har bir nuqta turg'unlik mezonlari asosida baholanadi va shovqinli yoki aniqligi past nuqtalar chiqarib tashlanadi.

3-qadam. Yo'nalishni belgilash. Har bir kalit nuqta atrofidagi lokal gradiyentlar hisoblanadi. Gradiyent yo'nalishlarining gistogrammasi qurilib, asosiy yo'nalish(lar) aniqlanadi. Bu qadam tasvirning burilishga invariant bo'lishini ta'minlaydi.

4-qadam. Deskriptorni qurish. Kalit nuqta atrofidagi soha bir necha yacheykalarga bo'linadi. Har bir yacheykada gradiyent yo'nalishlari va magnitudalari yig'ilib, gistogramma shakllantiriladi. Bu gistogrammalar birlashtirilib esa, har bir kalit nuqta asosida belgilar vektori hosil qilinadi.

SIFT usuli tasvirni tahlil qilishda yuqori samaradorlikka ega bo'lib, uning masshtab, burilish va pozitsiya o'zgarishlariga chidamliligi ko'plab amaliy sohalarda keng qo'llanilishini ta'minlaydi.

BRIEF deskriptori. BRIEF (Binary Robust Independent Elementary Feature) usuli $s \times s$ o'lchamli l –sohaning piksellerini mos juftlari taqqoslash (1) ifoda bilan aniqlanadi,

$$\tau(p, w, z) = \begin{cases} 1, & p(w) < p(z); \\ 0, & p(w) \geq p(z), \end{cases} \quad (1)$$

bu yerda $p(x)$ l –sohadagi $w=(u, v)$ koordinatali nuqtaning intensivligi. n_d o'lchamdagi bunday juft pikseller (w, z) to'plami "binar testlar" to'plami deb nomlanadi. Asosiy nuqta deskriptori n_d o'lchovli bit to'plami asosida quyidagi formula bilan aniqlanadi:

$$f_{n_d}(p) = \sum_{i=1}^{n_d} 2^{i-1} \tau(p, w, z). \quad (2)$$

n_d qiymatlari sifatida 128, 256, 512 lar biri tanlanadi. Binar sohani testlashda piksellarni tanlash muhim, [31] da w va z vektorlarini aniqlashning beshta usuli o'rganilgan.

BRIEF usulining asosiy kamchiliklari sifatida quyidagilarni keltirish mumkin: deskriptorni hisoblash uchun nuqtalarni optimal tanlamaslik; tanib olish jarayonida nuqtaning yo'nalishini hisobga olmaslik.

ORB deskriptor. ORB (Oriented FAST and Rotated BRIEF) [32] usuli BRIEF usulidagi asosiy kamchiliklarni bartaraf etishga qaratilgan. ORB usulida burchak yo'nalishini hisoblashda m_{pq} tasvir momentlari orqali hisoblangan C og'irlik markazining koordinatalaridan foydalaniladi:

$$m_{pq} = \sum_{x,y} x^p y^q I(x, y),$$

$$C = \left(\frac{m_{10}}{m_{00}}, \frac{m_{01}}{m_{00}} \right),$$

u holda burchakning yo'nalishi vektor tomonidan beriladi, uning boshlanishi markaziy nuqtada va oxiri og'irlik markazida bo'ladi. Burchak quyidagi ko'rinishda aniqlanadi

$$\theta = \arctg \left(\frac{m_{01}}{m_{00}} \right).$$

Ushbu yondashuvlar BRIEF “steered” usulida o‘z ifodasini topadi. Koordinatalari (x_i, y_i) bo‘lgan n o‘lchamli binar testlar to‘plami uchun $2 \times n$ o‘lchamli S matritsa quriladi:

$$S = \begin{pmatrix} x_1 \dots x_n \\ y_1 \dots y_n \end{pmatrix}.$$

Hisoblangan θ burchagidan foydalanib, R_θ aylanish matritsasi tuziladi, undan so‘ng $S_\theta = R_\theta S$ ifodadan aylanishni hisobga olgan holdagi S_θ matritsasini olish mumkin. Burchakni $2\pi/30$ qiymatga oshirish asosida diskretlashtiriladi, ya‘ni diskretlash qadami 12° tashkil etadi va deskriptorlar qidiriladi va S_θ bilan kelishuv amalga oshiriladi.


Deskriptor (2) ifodadan farqli o‘laroq, quyidagicha ko‘rinishga ega bo‘ladi:

$$g_n(p, \theta) = f_{n_d}(p) \Big|_{(x,y) \in S_\theta}.$$

[33] da deskriptorlarning sifatini keyingi taqqoslash nuqtai nazaridan aniqlash muammosi ko‘rib chiqiladi. Ma‘lumki, ba‘zi bir jinsli sohaning deskriptorlari kam farqlanadi va ko‘plab boshqa xususiyatlarga bog‘liq bo‘lib qoladi. Shuning uchun deskriptorlarning sifatini ko‘p hollarda o‘rtacha arifmetik va dispersiya parametrlari orqali baholash taklif etiladi.

BRIEF usuli muhim xususiyatga egaligi har bir deskriptor katta dispersiyaga ega va o‘rtacha qiymati 0,5 ga yaqindir. Lekin deskriptor asosiy nuqta yo‘nalishiga yo‘naltirilishi bu xususiyatni yo‘qotishga olib keladi. Binar testlarni o‘zaro bog‘liq emasligi ham muhim hisoblanadi. Bu yaxshi tanib olish ta‘minlaydi. Bunday muammolarni hal qilishda ORB usuli yuqori dispersiyaga ega, o‘rtacha qiymatlari 0,5 ga yaqin va bir-biri bilan bog‘liq bo‘lmaganlarni topishda barcha mumkin bo‘lgan binar testlar orasida qidiruvdan foydalanadi. Bunda natija rBRIEF deb ataladi. Ko‘p o‘lchovli ma‘lumotlarni o‘lchovlari deskriptorga mos kelish uchun o‘lchamni qisqartirishda LSH (Locality-sensitivity hashing) usuli qo‘llaniladi.

BRISK deskriptori. Buriilishga invariantlikka erishish uchun erishish uchun BRISK (Binary Robust Invariant Scalable Keypoints) deskriptorida nuqtalar 2-rasmdagi shablonga muvofiq amalga muvofiq tanlanadi.



2-rasm. BRISK deskriptorida nuqtalarni tanlash

Kalit nuqtaning yo‘nalishini hisoblash uchun p sohadagi $N(N-1)/2$ nuqtalar orasidagi (p_i, p_j) juft nuqta o‘rtasida lokal gradiyent hisoblanadi,

$$g(p_i, p_j) = (p_i - p_j) \frac{I(p_i, \sigma_j) - I(p_i, \sigma_i)}{\|p_i - p_j\|^2}$$

bu yerda $I(p_i, \sigma_j) - \sigma_i$ standart chetlanish bilan Gauss filtri qo‘llanilgan nuqta intensivliklari. A nuqta juftlarining butun to‘plamida S – “qisqa juftliklar” va L – “uzun juftliklar” bilan belgilanadi. Uzun

juftliklar uchun $-p_i - p_j < \delta_{\max}$, qisqalar juftliklar uchun esa $p_i - p_j \geq \delta_{\min}$ shart bilan aniqlanadi, bu yerda $\delta_{\max}, \delta_{\min}$ – bo'sag'aviy qiymatlar.

Uzun juftliklar L birlik nuqtaning yo'nalishini hisoblash uchun ishlatiladi. Yo'nalishni hisoblash uchun barcha "uzun gradiyentlar" yig'indisi aniqlanadi,

$$g = \begin{pmatrix} g_x \\ g_y \end{pmatrix} = \frac{1}{L} \sum_{(p_i, p_j) \in L} g(p_i, p_j)$$

va $\theta = \arctg\left(\frac{g_x}{g_y}\right)$ hisoblanadi. Binar deskriptorning o'zi BRIEFdagi kabi faqat "qisqa juftliklar" uchun hisoblanadi. Deskriptorlarni taqqoslash BRIEF usuli kabi amalga oshiriladi.

3 KLASSIFIKATORLAR

Klassifikator — bu mashinaviy o'qitishning asosiy elementlaridan biri bo'lib, u obyektlarni oldindan belgilangan sinflarga ajratish vazifasini bajaradi. Klassifikatorlar tasniflash masalalarini yechishda qo'llaniladi va ular turli sohalaridagi tasniflash masalalarini yechishda qo'llanilmoqda. Klassifikatorlar turli matematik usullarga asoslangan bo'lib, ular o'quv ma'lumot to'plami asosida o'qitiladi va o'qitish natijalari asosida qurilgan modelni yangi ma'lumotlarni tasniflashda qo'llaniladi. Shu maqsadda bu qismda masalani yechishda qo'llaniladigan klassifikatorlar haqidagi umumiy ma'lumotlar beriladi [34].

kNN. k ta eng yaqin qo'shnilar usuli eng oddiy tasniflash klassifikatordan hisoblanib, klassifikator x obyektning sinfini aniqlashni o'quv tanlamasidagi k ta eng yaqin x_i obyektlardan ular tegishli bo'lgan eng ko'p y_i sinfiga tegishlilik bo'yicha amalga oshiradi. Agar sinflar soni ikkita bo'lsa, k soni toq qiymat qilib tanlash lozim. Bu esa har xil sinflarga tegishli bo'lgan bir xil miqdordagi qo'shnilar noaniqlik holatlarini oldini oladi.

Algoritmida k ning qiymatini tanlash muammosi mavjud. Amaliyotda k tanlashda parametrning optimal qiymatini aniqlash odatda obyektlarni birma-bir chiqarib tashlash (leave-one-out, LOO) usuli asosida siljish-nazorat mezoniga nisbatan aniqlanadi. Aniqlash har bir $x_i \in X^\ell$ obyekt uchun k eng yaqin qo'shnilari asosida tasniflash to'g'ri yoki noto'g'ri amalga oshirilgani tekshiriladi, ya'ni

$$LOO(k, X^\ell) = \sum_{i=1}^{\ell} [a(x_i; X^\ell \setminus \{x_i\}, k) \neq y_i] \rightarrow \min_k.$$

Shuni ta'kidlash kerakki, agar tasniflanayotgan x_i obyekt o'quv tanlamasidan chiqarib tashlanmasa, uning eng yaqin qo'shnisi har doim o'zi x_i bo'ladi. Bu holda $LOO(k)$ funksionalining minimal (nol) qiymati $k=1$ da erishiladi.

Vaznli kNN. Sinflar soni uch yoki undan ortiq bo'lgan tasniflash masalalarida k soni toq qiymat bo'lsa ham har xil sinflarga tegishli bo'lgan bir xil miqdordagi qo'shnilar noaniqlik holatlarini uchrashi mumkin. Bunday holatlarda ko'p sinfli masalalarda esa umumiyroq yondashuv qo'llaniladi, ya'ni tasniflashda i -qo'shnining hissasini belgilovchi w_i vazn qiymatlarini kamayuvchi ketma-ketligi kiritish orqali noaniqlik yechiladi. U holda obyektning sinfi k eng yaqin qo'shni orasida eng katta umumiy vazn qiymatini to'playdigan sinfga tegishli bo'lishi bilan belgilanadi. **Vaznli kNN** tasniflash ifodasi quyidagicha amalga oshiriladi,

$$w(i, u) = [i \leq k] w_i;$$

$$a(u; X^\ell, k) = \arg \max_{y \in Y} \sum_{i=1}^k [y_u^{(i)} = y] w_i.$$

Vazn qiymatlari ketma-ketligi w_i ni tanlash evristik yondashuv hisoblanadi. Agar vazn qiymatlarini chiziqli kamayuvchi $w_i = \frac{k+1-i}{k}$ ifoda bilan aniqlansa, bunda ham noaniqliklar holati ham yuzga kelishi mumkin. Lekin **kNN** algoritmiga nisbatan kamroq yuzga keladi. Masalan, ikki sinf masalada birinchi va


to'rtinchi qo'shnilar 1-sinfni, ikkinchi va uchinchi qo'shnilar esa 2-sinfni aniqlash, natijada ovozlari yig'indisi tenglashadi. Natijada noaniqlik holati yuzaga keladi. Noaniqliklarni to'liq bartaraf etish uchun, ko'p holatlarda, geometrik progressiyaga asoslangan chiziqlimas kamayuvchi ketma-ketlikni qurish orqali amalga oshirish mumkin. Geometrik progressiya quyidagi aniqlanadi: $w_i = q^i$ bu yerda $q \in (0,1)$ progressiyaning maxraji bo'lib, algoritmi parametri b bo'lib hisoblanadi. Ushbu parametrlarni k qo'shnilarning soni aniqlashga o'xshash qilib LOO (Leave-One-Out) mezoniga muvofiq tanlash mumkin.

Qarorlar daraxti (Decision Tree). Mazkur klassifikator mashinaviy o'qitishda ishlatiladigan oddiy va samarali algoritmlardan biri bo'lib, tasniflash va regressiya masalalarini yechishda qo'llaniladi. Qarorlar daraxti ma'lumotlarni ketma-ket qismlar asosida qayta ishlaydi va yakuniy qaror qabul qilish uchun iyerarxik strukturani hosil qiladi. Ushbu iyerarxik struktura daraxt ma'lumotlar strukturasi hisoblanadi. Qarorlar daraxti konyunktiv qonuniyatlarni qidirishga asoslanib, mantiqiy tasniflash algoritmi hisoblanadi. Qarorlar ro'yxatidan farqli tomoni algoritmda daraxtni sintez qilishda barcha konyunksiyalar bir vaqtda quriladi.

Daraxt – bu uchlari to'plami V bo'lgan, siklga ega bo'lmagan va $v_0 \in V$ ajratilgan tugunga ega bo'lgan bog'lamlil grafdir. Ushbu tugunga hech bir qirra kiruvchi bo'lmaydi va u daraxtning ildizi deb ataladi. Chiquvchi qirralarga ega bo'lmagan tugun terminal tugun yoki barg deb ataladi. Qolgan tugunlar ichki tugunlar deb nomlanadi. Daraxt har bir ichki tugunlardan ikkita qirra chiquvchi daraxtga binar daraxt deyiladi. Chiquvchi qirralar har bir ichki tugunni L_v chap va R_v o'ng ostki tugunlar bilan bog'laydi.

Binar qaror daraxti binar daraxt ma'lumot strukturasi shaklda berilgan tasniflash algoritmidir. Bu daraxtda $v \in V$ har bir ichki tugunga predikat $\beta_v : X \rightarrow \{0,1\}$ va $v \in V$ har bir terminal tugunga sinf nomi $v \in Y$ birlashtiriladi. Obyekt $v \in V$ bo'yicha tasniflash daraxt bo'ylab ildizdan barggacha bo'lgan yo'nalish bo'yicha amalga oshiriladi. Ushbu jarayon **quyidagi algoritmi asosida** amalga oshiriladi.

1-qadam. $v := v_0$ ta'minlanadi;
 2-qadam. $\beta_v(x) = 1$ shart tekshiriladi, agar bajarilsa $v := R_v$ ta'minlanadi, aks holda $v := L_v$ ta'minlanadi;
 3-qadam. v tuguni ichki tugunga tekshirish. Agar shart bajarilsa, 2-qadam o'tiladi, aks holda keyingi qadamga o'tiladi;
 4-qadam. Algoritmi yakunlanadi.



Obyekt x tugun v ga faqat va faqat ildiz v_0 dan v gacha bo'lgan daraxt yo'lida joylashgan barcha ichki tugunlar predikatlaridan tuzilgan $K_v(x)$ konyunksiyasi bajarilganda yetib boradi. Daraxtning barcha terminal tugun to'plami T deb belgilash o'laylik. Terminal konyunksiyalar $v \in T$ bilan ajratilgan obyektlar to'plami $\Omega_v = \{x \in X : K_v(x) = 1\}$ bir-biri bilan kesishmaydi va ularning birlashmasi butun X fazoni qamrab oladi. Bundan kelib chiqadiki, qarorlar ro'yxatidan farqli qarorlar daraxti har doim yakuniy tasniflash amalga oshiradi va un binar qarorlar daraxtini ifodalovchi $a : X \rightarrow Y$ tasniflash algoritmini oddiy konyunksiyalar ovozigacha asoslangan holda quyidagicha yozish mumkin:

$$a(x) = \arg \max_{y \in Y} \sum_{v \in T} [c_v = y] K_v(x).$$

Bu yerda ixtiyoriy $x \in X$ uchun ushbu yig'indilarning faqat bitta hadi 1 ga mos keladi. Yig'indini qo'llash o'rni dizyunksiyadan foydalanish ham mumkin.

$K_v(x)$ konyunksiyalarning informativligini maksimal darajaga yetkazish talabi shuni anglatadiki, ularning har biri imkon qadar ko'proq o'quv obyektlarini ajratib ko'rsatishi va shu bilan birga xatoliklarni imkon qadar kichik bo'lishini talab etadi. Qarorlar daraxtining umumlashtirish qobiliyatini oshirish uchun terminal tugunlar soni imkon qadar kam bo'lishi lozim va ularning qism o'quv to'plamlari qariyb bir xil quvvatda bo'lishi lozim, ya'ni $|\Omega_v \cap X^\ell|$.

Tasodifiy o'rmon (Random Forest). Ushbu klassifikator mashinaviy o'qitishdagi bir nechta qaror daraxtlarini birlashtiruvchi ansambl hisoblanadi. U asosida tasniflash va regressiya masalalarini yechishda qo'llaniladi. Random Forest usuli bagging (bootstrap aggregating) strategiyasi bo'yicha bir nechta qaror

daraxtlarini har bir daraxt mustaqil ravishda ma'lumotlarning tasodifiy tanlangan qismi (bootstrap) asosida o'qitiladi va ularning natijalarini umumlashtiradi.

Tasodifiy o'rmon ko'p sonli qarorlar daraxtlarining ansamblidan iborat bo'lib, har bir daraxt o'quv tanlanmalar bilan mustaqil ravishda quriladi. Bu esa usulning yuqori aniqligini ta'minlaydi. Qayta o'qitish muammosi kamaytirishga erishiladi.

Logistik regressiya. Logistik regressiya usuli juda kuchli ehtimollik farazlariga asoslanishi bir vaqtning o'zida bir nechta qiziqarli natijalarga olib keladi. Birinchidan, tasniflash algoritmining chiziqiligi optimal Bayes klassifikatori ekanligi belgilaydi. Ikkinchidan, xatolik funksiyasi aniq belgilanadi. Uchinchidan, obyekttni tasniflash bilan bir qatorda, uning har bir sinfga tegishli bo'lish ehtimolini sonli baholash imkoniyatini beradi. Klassifikator binar va ko'p sinfli tasniflash masalalarini yechishda qo'llaniladi.

Logistik regressiya chiziqli regressiyaning g'oyasiga asoslanadi. Unda chiqish qiymati chiziqilimas holatga olib kelinadi. Klassifikatorni amalga oshirish biror obyektning ma'lum bir sinfga tegishli bo'lish ehtimoli sifatida qaraladi. Ehtimollik hisoblash uchun natijani $[0;1]$ oraliqqa tegishli bo'lishi kerak. Tegishli oraliqqa olib kelish uchun funksiya sifatida klassikator logistik(sigmoid) funksiyadan foydalaniladi,

$$P(y = 1 | x) = \frac{1}{1 + e^{-z}},$$

bu yerda $z = a_0 + a_1 \cdot x_1 + \dots + a_n \cdot x_n$.

Logistik regressiya sodda, ammo juda kuchli klassifikatorlar biri bo'lib, statistik tahlil va mashinaviy o'qitishda keng foydalaniladi. Bu klassifikator kichik miqdordagi o'quv tanlanmalar bilan yaxshi natijalarga olib kelish mumkin. Ko'p sinfli masalalarda asosan K ta modelni qurishni talab etadi. Bu esa ko'proq resurs talab etadi hamda bir-biriga yaqin bo'lgan sinflar bo'lgan masalalarda aniqlik past bo'lishi mumkin.

Naive Bayes. Naive Bayes klassifikatori statistik tasniflash algoritmi bo'lib, asosiy prinsipi Bayes teoremasiga asoslanadi. Ushbu usul, ayniqsa, katta hajmdagi o'quv tanlanmalar bilan ishlashda har bir belgini boshqalardan mustaqil deb farazi qisman yoki to'liq bajarilganda samarali bo'ladi. "Naive" (soddalashtirilgan) deb atash sababi aynan shu belgilarni bog'liqlikmaslik faraziga asoslanishi bilan bog'liqdir.

$x \in X$ obyektlar n ta sonli belgilar $f_j : X \rightarrow R, j = 1, \dots, n$ shaklda tavsiflash bilan amalga oshirilsin. Obyektlarning fazosi $X = R^n$ bo'lib, uning ixtiyoriy elementi $x = (\xi_1, \dots, \xi_n)$ bo'lsin, bu yerda $\xi_j = f_j(x)$ sifatida belgilash amalga oshirilsin. Bog'liqmas belgilar bo'yicha sinflarning haqiqiylik funksiyalari quyidagi ko'rinishda ifodalanadi:

$$p_y(x) = p_{y1}(\xi_1) \cdot \dots \cdot p_{yn}(\xi_n), \quad y \in Y,$$

bu yerda $p_{yj}(\xi_j)$ – y sinfi uchun j -belgi qiymatlarining taqsimot zichligi.

Bog'liqmaslik farazi masalani sezilarli darajada soddalashtiradi. Chunki n o'lehovli taqsimotni baholashdan ko'ra, n ta bir o'lehovli zichlikni baholash ancha osondir. Ammo, bu faraz amaliyotda juda kamdan-kam hollarda bajariladi. Shu sababli, yuqoridagi ifodadan foydalanadigan tasniflash algoritmlar "Naive" Bayes klassifikatori deb ataladi.

Naive Bayes klassifikator algoritmini bir o'lehovli zichliklarning empirik baholari $\hat{p}_{yj}(\xi)$ asosida quyidagicha yozish mumkin,

$$a(x) = \arg \max_{y \in Y} \left(\ln \lambda_y \hat{P}_y + \sum_{j=1}^n \ln \hat{p}_{yj}(\xi_j) \right),$$

bu yerda λ_y – sinflarning aprior ehtimolliklari nisbati, \hat{P}_y – y sinfnig aprior ehtimolligi.

Klassifikatorning asosiy afzalliklari – sodda va mashinaviy o'qitish hamda tasniflash jarayonida kichik hisoblash resurslarida ham ishlaydi. Belgilar deyarli bog'liqlikmas bo'lgan holatlarda, klassifikator deyarli optimal natijalarga erishadi. Kamchiligi sifatida esa – belgilar bir-biri bilan bog'liq bo'lganda tasniflash sifatining past bo'lishi qaraladi. Ushbu klassifikator odatda quyidagi holatlarda qo'llaniladi: tajribaviy natijalarni taqqoslashda boshqa algoritmlar uchun etalon sifatida foydalanish; algoritmik kompozitsiyalarda element qismlari sifatida "qurilish bloki" sifatida.

SVM. Support Vector Machine (SVM) – bu mashinaviy o‘qitish sohasidagi eng kuchli va samarali algoritmlardan biri bo‘lib, tasniflash, regressiya va anomalarni aniqlashda qo‘llaniladi. SVM usuli ma‘lumotlarni chiziqli yoki chiziqsiz bo‘lishdan qat’i nazar, samarali tasniflashni amalga oshiradi. SVM usulining asosiy g‘aysia ikki sinfni ajratadigan optimal ajratuvchi gipertekislikni (hyperplane) topishdir. Bu gipertekislik ikkita sinfni maksimal masofada ajratib turadigan sirt sifatida aniqlanadi. Sinflar o‘rtasidagi bu masofa margin(3azop) deb ataladi. SVM usuli ushbu marginni maksimal daraja kattalashtirishga qaratadi. SVM usulini o‘qitish kvadratik dasturlash masalasiga keltiriladi. Bu masala yagona yechimga ega va hatto yuz minglab obyektlardan iborat o‘quv tanlanmalarda ham samarali hisoblanadi. Optimal ajratuvchi gipertekislikning holati faqat o‘quv obyektlarining kichik bir qismiga bog‘liq bo‘ladi. Ushbu obyektlar tayanch vektorlari deb ataladi; qolgan obyektlar esa amaliy jihatdan jarayonda ishtirok etmaydi.

SVM usulining afzalliklari: kvadratik dasturlash masalasi yagona yechimga ega bo‘lib, uni topish uchun samarali usullar ishlab chiqilgan; superpozitsiya murakkabligi avtomatik avtomatik ravishda aniqlanadi. Ya’ni bu SVMni neyron kabi ifodalaganda birinchi qatlamdagi neyronlar sonini tayanch vektorlar soniga tenglashtiradi; sinflar orasidagi margin qiymatini kattalashtirish umumlashtirish qobiliyatini yaxshilaydi.

SVM usulining kamchiliklari: o‘quv tanlanma ma‘lumotlarga shovqinlarga nisbatan turg‘un emas; tayanch vektor sifatida tanlangan o‘quv tanlanamalargi obyektlardan tashqaridagi obyektlar o‘qitish natijalariga sezilarli ta’sir qiladi; yadro tanlashning umumiy usullari mavjud emasligi. Amaliyotda ma‘lum masalaning xususiyatlariga mos keluvchi “mantiqan mos” yadro tanlash ijobiy aniqlikka ega bo‘lmasligi mumkin; C parametr qiymatini aniqlash ko‘p marta tajriba-sinov va xatoliklar orqali amalga oshirilishi masalaning murakkabligini oshiradi.

4 HISOBLASH TAJRIBALARI

4.1 Tajriba uchun NWPU-RESISC45 ma‘lumotlar bazasi.

NWPU-RESISC45 ma‘lumotlar to‘plami 45 ta sahna sinfidan tashkil topgan 31500 ta masofadan zondlash tasvirlarini o‘z ichiga oladi. Har bir sinf 256×256 piksel o‘lchamdagi qizil, yashil, ko‘k (RGB) rangli fazodagi 700 ta tasvirni o‘z ichiga oladi. Ko‘pchilik sahna sinflari uchun tasvirlarning fazoviy o‘lchami piksel uchun 30 metr va 0,2 metr oralig‘ida tashkil etadi. Lekin "orollar", "ko‘l", "tog‘", va "muz tog‘lari" sahna sinflari fazoviy o‘lchami kichikdir. Ushbu ma‘lumotlar to‘plami ham masofadan zondlash tasvirlarini tahlil qilish bo‘yicha mutaxassislar tomonidan Google Earth (Google Inc.) dan olingan. Google Earth tasvirlarni sun‘iy yo‘ldosh tasvirlari, aerofotografiya va geografik axborot tizimi (GIS) orqali 3D globusga joylashtiradi.

31500 ta tasvir dunyoning 100 dan ortiq davlat va mintaqalarini, shu jumladan rivojlanayotgan, o‘tish davridagi va yuqori rivojlangan iqtisodlarni qamrab oladi. NWPU-RESISC45 ma‘lumotlar to‘plami mavjud sahna tasnifi bo‘yicha ma‘lumotlar to‘plamlariga nisbatan quyidagi uchta muhim xususiyatga ega: katta hajm. Bu xususiyat har bir sahna sinfida 700 tadan iboratligi hisobladi. Bu boshqa ma‘lumotlar to‘plamiga nisbatan sahna sinflari soni va tasvirlar umumiy soni bo‘yicha eng katta hajmga egaligini ko‘rsatadi; sinf ichidagi xilma-xillik va sinflar orasidagi o‘xshashlik. Sinf ichidagi xilma-xillik obyektlar yuqori darajada ta‘minlangan bo‘lsa, sinflar orasida semantik o‘xshashlik sahnalarini mavjud.

Ushbu ma‘lumotlar to‘plami sahnali tasniflash bo‘yicha ishlab chiqiladigan tasniflash usul va algoritmlarini tajribaviy baholash imkoniyatini beradi.

4.2 O‘tkazilgan tajribalar natijalari.

Sahnali tasniflash masalasi uchun deskriptorlar qurishda LBP, HOG, SIFT, ORB, BRISK, BRIEF usullaridan foydalanildi. Ushbu deskriptorlar asosida tasniflash SVM, Random Forest, Decision Tree, Naive Bayes, KNN, Logistic Regression algoritmlari asosida amalga oshirildi. Tasniflash natijalarini baholashda Accuracy, Precision, Recall, F1-Score o‘lchovlaridan foydalanildi. Tajribalar NWPU-RESISC45 ma‘lumotlar to‘plami asosida Python 3 dasturlash tili va kutubxonalar asosida o‘tkazildi. Ma‘lumotlar to‘plami tarjibada qo‘llaniladigan barcha klassifikatorlar uchun bir xil sharoitda amalga oshirish uchun 70% o‘quv tanlanmalar uchun, testlash tanlanmalari uchun 30% qilib ajratildi.

Hisoblash tajribalar natijalari 1 – 6 -jadvallarda keltirilgan. 1-jadvalda NWPU-RESISC45 ma‘lumotlar to‘plamining tasvirlariga LBP deskriptorini qo‘llash va ushbu deskriptor asosida sahnani tasniflash masalasi yechishni amalga oshirish uchun bir qator klassifikatorlarni o‘qitish natijalari keltirilgan. Natijalardan tajriba o‘tkazishda foydalanilgan klassifikatorlarda tasniflash baholash ko‘rsatkichlari 0.4 ga ham yetmaganini ko‘rish mumkin. Baholash ko‘rsatkichlari bo‘yicha eng yaxshi natijani LBP deskriptori asosida Random Forest klassifikatorim, eng past natijani esa Naive Bayes klassifikatori ko‘rsatdi.

1-jadval. LBP deskriptori asosida sahnani tasniflash natijalari

Klassifikator	Accuracy	Precision	Recall	F1-Score
SVM	0.3173	0.3303	0.3173	0.2963
Random Forest	0.3800	0.3756	0.3800	0.3731
Decision Tree	0.2438	0.2467	0.2438	0.2447
Naive Bayes	0.1780	0.1729	0.1780	0.1431
KNN	0.3131	0.3351	0.3131	0.3124
Logistic Regression	0.1922	0.1560	0.1922	0.1405

2-jadvalda NWPU-RESISC45 ma'lumotlar to'plamining tasvirlariga HOG deskriptorini qo'llash va ushbu deskriptor asosida sahnani tasniflash masalasi yechishni amalga oshirish uchun bir qator klassifikatorlarni o'qitish natijalari keltirilgan. Bu natijalardan tajriba o'tkazishda foydalanilgan klassifikatorlarda tasniflash baholash ko'rsatkichlari 0.35 ga ham yetmaganini ko'rish mumkin. Baholash ko'rsatkichlari bo'yicha eng yaxshi natijani HOG deskriptori asosida SVM klassifikatori, eng past natijani esa KNN klassifikatori ko'rsatdi.

2-jadval. HOG deskriptori asosida sahnani tasniflash natijalari

Klassifikator	Accuracy	Precision	Recall	F1-Score
SVM	0.3322	0.3310	0.3322	0.3246
Random Forest	0.1851	0.1658	0.1851	0.1675
Decision Tree	0.0647	0.0657	0.0647	0.0651
Naive Bayes	0.1849	0.1867	0.1849	0.1726
KNN	0.0571	0.2030	0.0571	0.0346
Logistic Regression	0.1778	0.1765	0.1778	0.1760

3-jadvalda NWPU-RESISC45 ma'lumotlar to'plamining tasvirlariga SIFT deskriptorini qo'llash va ushbu deskriptor asosida sahnani tasniflash masalasi yechishni amalga oshirish uchun bir qator klassifikatorlarni o'qitish natijalari keltirilgan. Bu natijalardan tajriba o'tkazishda foydalanilgan klassifikatorlarda tasniflash baholash ko'rsatkichlari 0.55 ga yaqinligini ko'rish mumkin. Baholash ko'rsatkichlari bo'yicha eng yaxshi natijani SIFT deskriptori asosida Logistic Regression klassifikatori, eng past natijani esa Decision Tree klassifikatori ko'rsatdi.

3-jadval. SIFT deskriptori asosida sahnani tasniflash natijalari

Klassifikator	Accuracy	Precision	Recall	F1-Score
SVM	0.4764	0.4822	0.4764	0.4691
Random Forest	0.4660	0.4601	0.4660	0.4565
Decision Tree	0.2791	0.2886	0.2791	0.2828
Naive Bayes	0.2969	0.3159	0.2969	0.2773
KNN	0.4253	0.4641	0.4253	0.4287
Logistic Regression	0.5378	0.5286	0.5378	0.5306

4-jadvalda NWPU-RESISC45 ma'lumotlar to'plamining tasvirlariga ORB deskriptorini qo'llash va ushbu deskriptor asosida sahnani tasniflash masalasi yechishni amalga oshirish uchun bir qator klassifikatorlarni o'qitish natijalari keltirilgan. Bu natijalardan tajriba o'tkazishda foydalanilgan klassifikatorlarda tasniflash baholash ko'rsatkichlari 0.3 ga yetmaganligini ko'rish mumkin. Baholash ko'rsatkichlari bo'yicha eng yaxshi natijani ORB deskriptori SVM klassifikatori, eng past natijani esa Decision Tree klassifikatori ko'rsatdi.

4-jadval. ORB deskriptori asosida sahnani tasniflash natijalari

Klassifikator	Accuracy	Precision	Recall	F1-Score
SVM	0.2427	0.2440	0.2427	0.2308
Random Forest	0.2018	0.1967	0.2018	0.1889
Decision Tree	0.0969	0.1007	0.0969	0.0984
Naive Bayes	0.1387	0.1564	0.1387	0.1072
KNN	0.1553	0.1768	0.1553	0.1461
Logistic Regression	0.1956	0.1712	0.1956	0.1737

5-jadvalda NWPU-RESISC45 ma'lumotlar to'plamining tasvirlariga BRISK deskriptorini qo'llash va ushbu deskriptor asosida sahnani tasniflash masalasi yechishni amalga oshirish uchun bir qator klassifikatorlarni o'qitish natijalari keltirilgan. Bu natijalardan tajriba o'tkazishda foydaniilgan klassifikatorlarda tasniflash baholash ko'rsatkichlari 0.3 ga yetmaganligini ko'rish mumkin. Baholash ko'rsatkichlari bo'yicha eng yaxshi natijani BRISK deskriptori Random Forest klassifikatori, eng past natijani esa Decision Tree klassifikatori ko'rsatdi.

5-jadval. BRISK deskriptori asosida sahnani tasniflash natijalari

Klassifikator	Accuracy	Precision	Recall	F1-Score
SVM	0.2271	0.2290	0.2271	0.1967
Random Forest	0.2807	0.2558	0.2807	0.2564
Decision Tree	0.1482	0.1489	0.1482	0.1481
Naive Bayes	0.1907	0.1845	0.1907	0.1587
KNN	0.2278	0.2416	0.2278	0.1996
Logistic Regression	0.2718	0.2494	0.2718	0.2545

6-jadvalda NWPU-RESISC45 ma'lumotlar to'plamining tasvirlariga BRIEF deskriptorini qo'llash va ushbu deskriptor asosida sahnani tasniflash masalasi yechishni amalga oshirish uchun bir qator klassifikatorlarni o'qitish natijalari keltirilgan. Bu natijalardan tajriba o'tkazishda foydaniilgan klassifikatorlarda tasniflash baholash ko'rsatkichlari 0.2 ga yetmaganligini ko'rish mumkin. Baholash ko'rsatkichlari bo'yicha eng yaxshi natijani BRIEF deskriptori SVM klassifikatori, eng past natijani esa Decision Tree klassifikatori ko'rsatdi.

6-jadval. BRIEF deskriptori asosida sahnani tasniflash natijalari

Klassifikator	Accuracy	Precision	Recall	F1-Score
SVM	0.1504	0.1597	0.1504	0.1393
Random Forest	0.1322	0.1240	0.1322	0.1213
Decision Tree	0.0680	0.0695	0.0680	0.0685
Naive Bayes	0.0944	0.0911	0.0944	0.0717
KNN	0.0951	0.1135	0.0951	0.0840
Logistic Regression	0.1031	0.0883	0.1031	0.0890

1–6 – jadvallarni tahlil qilib shuni aytish mumkin, baholash ko'rsatkichlari bo'yicha eng yaxshi natijaga SIFT deskriptori, eng yomon natijaga BRIEF deskriptori ko'rsatgan. Biroq, eng yaxshi ko'rsatgan SIFT deskriptorining natijalari ham Accuracy o'lchovi bo'yicha 0.53 tashkil etadi. Bu esa natijalarni yanada yaxshilash tadqiqot olib borishni taqozo etadi.

5 XULOSA

Maqolada masofaviy zondlash tasvirlarini tahlil qilish va sahnani tasniflashda deskriptorlarni shakllantirish usullari hamda klassifikatorlarning samaradorligi tahlil qilindi. Tadqiqot tajribalarida LBP, HOG, SIFT, ORB, BRISK va BRIEF deskriptorlar bilan birgalikda SVM, Random Forest, Decision Tree, Naive Bayes, kNN va Logistic Regression klassifikatorlar qo'llanildi. Natijalar shuni ko'rsatdiki, SIFT deskriptori va Logistic Regression klassifikatori birgalikda yuqori natijalar bergan bo'lsa-da, ularning tasniflash aniqligi qoniqarli darajada emasdir. Tajribalar o'tkazilgan usul va algoritmlar murakkab fazoviy tuzilmalar va semantik xilma-xillikni to'liq tavsiflash imkoniyatini bermasligini ko'rsatdi.

Kelgusida ushbu sohadagi tadqiqotlar natijalarini yaxshilash uchun quyidagilar tavsiya etiladi: chuqur o'qitishga asoslangan yuqori darajadagi deskriptorlarni shakllantirish yondashuvlarini tadqiq etish va ishlab chiqish; bir nechta deskriptorlarni birlashtirish asosida murakkab obyektlarni tavsiflash yondashuvlarini ishlab chiqish; ushbu deskriptorlarni klassifikatorlar bilan birgalikda qo'llashni ta'minlaydigan yangi algoritmlar ishlab chiqish.

Tasvirlarda sahnani tasniflash masalalari yechish uchun usul va algoritmlarni ishlab chiqish yoki takomillashtirishda ushbu tavsiyalarni e'tiborga olgan holda amalga oshirish tasniflash aniqligini yaxshilashga olib keladi.

ADABIYOTLAR

- [1] *Yusupov, O., & Eshonqulov, E. (2023). Masofadan zondlash asosida olingan tasvirlarda deskriptorlarni qurish usullarining qiyosiy tahlili. Mejdunarodnyj Zhurnal Teoreticheskix i Prikladnyx Voprosov Cifrovix Texnologiy, 6(4), 102–110. <https://doi.org/10.62132/ijdt.v6i4.142>.*
- [2] *Sh.Fazilov, O.Yusupov, E.Eshonqulov, Sun'iy yo'ldosh tasvirlarida superpiksel segmentlash yondashuvlari, Informatika va energetika muammolari, 6-son, 2023.*
- [3] *B. Zitová and J. Flusser, "Image registration methods: A survey", Image Vis. Comput., vol. 21, pp. 977-1000, 2003.*
- [4] *W. K. Pratt, "Correlation techniques of image registration", IEEE Trans. Aerosp. Electron. Syst., vol. AES-10, no. 3, pp. 353-358, May 1974*
- [5] *P. Viola and W. M. Wells, "Alignment by maximization of mutual information", Int. J. Comput. Vis., vol. 24, no. 2, pp. 137-154, Sep. 1997.*
- [6] *A. Myronenko and X. Song, "Intensity-based image registration by minimizing residual complexity", IEEE Trans. Med. Imag., vol. 29, no. 11, pp. 1882-1891, Nov. 2010.*
- [7] *X. Liu, Z. Tian and M. T. Ding, "A novel adaptive weights proximity matrix for image registration based on R-SIFT", AEU-Int. J. Electron. Commun., vol. 65, no. 12, pp. 1040-1049, 2011.*
- [8] *Yusupov O. et al. Analysis of superpixel segmentation approaches in remote sensing images //AIP Conference Proceedings. – AIP Publishing, 2024. – T. 3147. – №. 1.*
- [9] *S.Radjabov, O.Yusupov, E.Eshonqulov, Masofadan zondlash asosida olingan tasvirlarda anomaliyalarni aniqlash usullari, "O'zbekistonda uchinchi renessans va innovatsion jarayonlar" xalqaro ilmiy-amaliy onlayn anjuman materiallari. -Bosma, 2023-yil*
- [10] *Fazilov, S., Yusupov, O., Radjabov, S., Eshonqulov, E., & Abdieva, K. (2024, November). Analysis of pansharpening methods for multispectral satellite imagery. In AIP Conference Proceedings (Vol. 3244, No. 1). AIP Publishing.*
- [11] *Radjabov, S. S., Yusupov, O. R., & Eshonqulov, E. S. (2024). Masofadan zondlash asosida olingan tasvirlarda superpiksel segmentlash yondashuvlarini baholash mezonlari. International Journal of scientific and Applied Research, 1(3), 103-106.*
- [12] *S.Radjabov, O.Yusupov, E.Eshonqulov, Multispektral tasvirlarni segmentlash yondashuvlari sinflari va segmentlash natijalarini baholash, O'zbekiston, Toshkent davlat iqtisodiyot universiteti, "Sun'iy intellekt nazariyasi va amaliyoti: tajriba, muammolar va istiqbollar", Respublika ilmiy-amaliy konferensiyasi,. -Bosma, 2024-yil*
- [13] *S.S.Radjabov, O.R.Yusupov, E.Sh.Eshonqulov, Masofadan zondlash asosida olingan tasvirlar uchun shovqinni olib tashlash algoritmlarining tahlili, Mirzo Ulug'bek nomidagi O'zbekiston Milliy Universiteti Jizzax filiali, "Zamonaviy innovatsion tadqiqotlarning dolzarb muammolari va rivojlanish tendensiyalari: yechimlar va istiqbollar", Respublika miqyosidagi ilmiy-texnik konferensiya materiallari to'plami,. -Bosma, 2023-yil*
- [14] *Yang Y., Newsam S. Geographic image retrieval using local invariant features IEEE Trans. Geosci. Remote Sens., 51 (2013), pp. 818-832.*
- [15] *Hu J., Xia G.-S., Hu F., Zhang L. A comparative study of sampling analysis in the scene classification of optical high-spatial resolution remote sensing imagery Remote Sens., 7 (2015), pp. 14988-15013*
- [16] *Sh.Fazilov, O.Yusupov, E.Eshonqulov, Multispektral tasvirlarni segmentlash usullari, Informatika va energetika muammolari, 1-son, 2024*
- [17] *S.Radjabov, O.Yusupov, E.Eshonqulov, Masofadan zondlash asosida olingan multispektr tasvirlari uchun pansharpening yondashuvlar tahlili, Sharof Rashidov nomidagi Samarqand davlat universiteti, "Sun'iy intellekt va raqamli ta'lim texnologiyalari: amaliyot, tajriba, muammo va istiqbollari" mavzusidagi xalqaro ilmiy-amaliy konferensiya materiallari to'plami. -Bosma, 2024-yil*
- [18] *O.R.Yusupov, E.Sh.Eshonqulov, M.S.Abduraxmonov, Multispektr tasvirlarda pansharpening usullari uchun Lansosh interpolyatsiyani qo'llash, "Scientific foundations of raising the use of information technologies to a new level and modern problems of automation" III-international scientific conference, November 20, 2024*
- [19] *Cheng G., Han J., Lu X. Remote sensing image scene classification: Benchmark and state of the art Proc. IEEE, 105 (10) (2017), pp. 1865-1883, 10.1109/JPROC.2017.2675998*
- [20] *Xie L., Lee F., Liu L., Kotani K., Chen Q. Scene recognition: A comprehensive survey Pattern Recognit., 102 (2020), Article 107205, 10.1016/j.patcog.2020.107205*
- [21] *G. Cheng, J. Han and X. Lu, "Remote Sensing Image Scene Classification: Benchmark and State of the Art," in Proceedings of the IEEE, vol. 105, no. 10, pp. 1865-1883, Oct. 2017, doi: 10.1109/JPROC.2017.2675998*

- [22] *S.Radjabov, O.Yusupov, E.Eshonqulov*, Masofadan zondlash asosida olingan tasvirlarga ishlov berish masalalari, "Matematik modellash va axborot texnologiyalarining dolzarb masalalari" xalqaro ilmiy-amaliy anjuman, Nukus,. — Bosma, 2023-yil
- [23] *Cheng, Gong, Junwei Han, and Xiaoqiang Lu*. "Remote sensing image scene classification: Benchmark and state of the art." *Proceedings of the IEEE* 105.10 (2017): 1865-1883.
- [24] *Y. Yang, S. Newsam*, Comparing SIFT descriptors and gabor texture features for classification of remote sensed imagery, in: 2008 15th IEEE International Conference on Image Processing, 2008, pp. 1852–1855.
- [25] *G. Cheng, J. Han, P. Zhou, L. Guo*, Multi-class geospatial object detection and geographic image classification based on collection of part detectors, *ISPRS J. Photogramm. Remote Sens.* 98 (2014) 119–132.
- [26] *G. Cheng, J. Han, L. Guo, T. Liu*, Learning coarse-to-fine sparselets for efficient object detection and scene classification, in: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2015, pp. 1173–1181.
- [27] *G. Cheng, J. Han, L. Guo, Z. Liu, S. Bu, J. Ren*, Effective and efficient midlevel visual elements-oriented land-use classification using VHR remote sensing images, *IEEE Trans. Geosci. Remote Sens.* 53 (8) (2015) 4238–4249.
- [28] *Q. Zhu, Y. Zhong, B. Zhao, G.-S. Xia, L. Zhang*, Bag-of-visual-words scene classifier with local and global features for high spatial resolution remote sensing imagery, *IEEE Geosci. Remote Sens. Lett.* 13 (6) (2016) 747–751.
- [29] *J. Zou, W. Li, C. Chen, Q. Du*, Scene classification using local and global features with collaborative representation fusion, *Inform. Sci.* 348 (2016) 209–226.
- [30] *Shu C., Ding X., Fang C.* Histogram of the oriented gradient for face recognition // *Tsinghua Science and Technology*. – 2011. – Vol. 16, No. 2. – P. 216-224.
- [31] *Calonder, M.* BRIEF-binary robust independent elementary features / *M. Calonder, V. Lepetit, C. Strecha, P. Fua* // *European Conference on Computer Vision*. – 2010. – Part IV. – P. 778-792. – DOI: 10.1007/978-3-642-15561-1_56
- [32] *Rublee, E.* ORB: An efficient alternative to SIFT or SURF / *E. Rublee, V. Rabaud, K. Konolige, G. Bradski* // *IEEE International Conference on Computer Vision (ICCV)*. – 2011. – P. 2564-2571. – DOI: 10.1109/ICCV.2011.6126544.
- [33] *Сидякин, С.В.* Морфологические дескрипторы формы бинарных изображений на основе эллиптических структурирующих элементов / *С.В. Сидякин, Ю.В. Визильтер* // *Компьютерная оптика*. – 2014. – Т. 38, № 3. – С. 511-520. – DOI: 10.18287/0134-2452-2014-38-3-511-520.
- [34] *Воронцов К.В.* Машинное обучение (курс лекций). Часть первая. — Школа анализа данных, 2019. — URL: <http://www.machinelearning.ru>

Поступила в редакцию 07.12.2024

Citation: *Yusupov O.R., Xandamov Y.X., Eshonqulov E.Sh.* (2025). Quy va o'rtta darajadagi deskriptorlar asosida masofadan olingan tasvirlarda sahnani tasniflash algoritmlari. Raqamli texnologiyalarning nazariy va amaliy masalalari xalqaro jurnali. 8(1). – B. 7-21. <https://doi.org/10.62132/ijdt.v8i1.229>.

ALGORITHMS FOR SCENE CLASSIFICATION IN REMOTE SENSING IMAGES BASED ON LOW- AND MID-LEVEL DESCRIPTORS

⁺*Yusupov O.R.¹, Xandamov Y.Kh.², Eshonkulov E.Sh.¹*

¹ Samarkand State University named after Sharof Rashidov, Samarkand, Uzbekistan

² Research institute Development of digital technologies and artificial intelligence, Tashkent, Uzbekistan

⁺ozodyusupov@gmail.com

Abstract. Scene classification is one of the important tasks in the analysis of remote sensing images. This article examines the application of machine learning algorithms for forming image descriptors and classifying scenes. Within the scope of the study, low-, mid-, and high-level descriptors were used, including Local Binary Pattern (LBP), Histogram of Oriented Gradients (HOG), Scale-Invariant Feature Transform (SIFT), Oriented FAST and Rotated BRIEF (ORB), BRISK, and BRIEF descriptors. For scene classification, SVM, Random

Forest, Decision Tree, Naive Bayes, kNN, and Logistic Regression algorithms were employed. The results of the study demonstrated the effectiveness of the combinations of descriptors and classifiers, with the SIFT descriptor providing the best results. However, the overall results indicated the need to improve methods to achieve higher accuracy in scene classification. This study explores the development and application of algorithms based on low- and mid-level descriptors for scene classification in remote sensing images. For accurate image classification, it is important to form descriptors that express key attributes (such as image dimensions and formats), visual features (such as color and textures), semantic information (contextual relationships), and geometric consistency. The study consists of two main stages: feature extraction and training a classifier based on machine learning algorithms (kNN, Naive Bayes, Random Forest, SVM, and Logistic Regression). The study was conducted on the NWPU-RESISC45 dataset, and classification was performed across 45 different scene categories. The results show that SIFT and other descriptors possess high accuracy, but further research is required to improve classification performance.

Keywords: scene classification, remote sensing image, feature, descriptor, classifier, NWPU-RESISC45.

АЛГОРИТМЫ КЛАССИФИКАЦИИ СЦЕН НА ИЗОБРАЖЕНИЯХ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ НА ОСНОВЕ ДЕСКРИПТОРОВ НИЗКОГО И СРЕДНЕГО УРОВНЕЙ

⁺Юсупов О.Р.¹, Хандамов Й.Х.², Эшонкулов Э.Ш.¹

¹ Самаркандский государственный университет имени шарофа Рашидова,
Самарканд, Узбекистан

² Научно-исследовательский институт развития цифровых технологий и
искусственного интеллекта, Ташкент, Узбекистан

⁺ozodyusupov@gmail.com

Аннотация. Классификация сцен является одной из важнейших задач при анализе изображений дистанционного зондирования. В данной статье изучается применение алгоритмов машинного обучения для формирования дескрипторов изображений и классификации сцен. В рамках исследования использовались дескрипторы низкого, среднего и высокого уровня, в том числе такие как Local Binary Pattern (LBP), Histogram of Oriented Gradients (HOG), Scale-Invariant Feature Transform (SIFT), Oriented FAST and Rotated BRIEF (ORB), BRISK и BRIEF. Для классификации сцен были применены алгоритмы SVM, Random Forest, Decision Tree, Naive Bayes, kNN и Logistic Regression. Результаты исследования показали эффективность различных комбинаций дескрипторов и классификаторов, при этом наилучшие результаты продемонстрировал дескриптор SIFT. Однако общие результаты указывают на необходимость совершенствования методов для достижения более высокой точности классификации сцен. Данное исследование посвящено разработке и применению алгоритмов на основе дескрипторов низкого и среднего уровня для классификации сцен на изображениях дистанционного зондирования. Для точной классификации изображений важно формирование дескрипторов, отражающих основные атрибуты (например, размеры и форматы изображений), визуальные характеристики (например, цвет и узоры), семантическую информацию (контекстуальные связи) и геометрическое соответствие. Исследование включает два основных этапа: извлечение признаков и обучение классификатора на основе алгоритмов машинного обучения (kNN, Naive Bayes, случайные леса, SVM и логистическая регрессия). Исследование проводилось на наборе данных NWPU-RESISC45, охватывающем 45 классов сцен. Результаты показывают высокую точность дескрипторов SIFT и других, однако для улучшения показателей классификации требуются дополнительные исследования.

Ключевые слова: классификация сцен, изображение ДЗЗ, признак, дескриптор, классификатор, NWPU-RESISC45.