ULTRATOVUSHLI TIBBIY TASVIRLARNI SINFLASHTIRISHDA INFORMATIVLIK KO‘RSATKICHINI BAHOLASH ALGORITMI

Nishanov Axram Xasanovich[1], Mamatov Maxtumquli Jumanazarovich[2]

[1]Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti tizimli va amaliy dasturlash kafedrasi professori E-mail: nishanov_akram@mail.ru
[2]Denov tadbirkorlik va pedagogika instituti tayanch doktoranti
E-mal: maxtumqulim@gmail.com ORCID: 0009-0008-2534-5386

K E Y W O R D S

bachadon miomasi, ultratovush tasviri, tasvir informativligi, kontrast, entropiya, tekstura, chegara ravshanligi, sun’iy intellek

A B S T R A C T

Bachadon miomasini ultratovush tasvirlari asosida avtomatlashtirilgan aniqlashda tasvir sifatining o‘zgaruvchanligi muhim muammolardan biridir. Nuqtali shovqin, past kontrastlilik, to‘qima intensivligining notekis taqsimlanishi va patologik hudud chegaralarining xiraligi bir xil chuqur o‘qitish modeli turli tasvirlarda turlicha natija berishiga olib kelishi mumkin. Mazkur tadqiqotda ultratovushli tasvirning diagnostik va algoritmik jihatdan foydalilik darajasini oldindan baholash uchun kompleks informativlik ko‘rsatkichi ishlab chiqildi. Taklif etilgan algoritm kontrast, entropiya, tekstura, gradient asosidagi chegara ravshanligi va shovqin darajasini alohida hisoblab, ularni normallashtirish va vaznli birlashtirish orqali yagona informativlik qiymatini hosil qiladi. Tadqiqotda 3050 ta ultratovush tasviridan tashkil topgan balanslangan ma’lumotlar to‘plamidan foydalanildi; unda 1525 ta miomali va 1525 ta miomasiz tasvir mavjud bo‘ldi. Informativlikni hisoblash natijalari CRITIC, entropiya vaznlash usuli (EWM) va taklif etilgan kombinatsiyalangan W* yondashuvi bilan baholandi. Shifokor etaloni bilan qiyoslashda W* yondashuvi Accuracy-98,89%, Precision-98,22%, Recall-99,67% va Specificity-96,08% qiymatlarini ko‘rsatdi. Natijalar tasvir informativligini klassifikatsiyadan oldingi alohida bosqich sifatida hisobga olish ultratovush tasvirlarini avtomatlashtirilgan tahlil qilishda barqaror va obyektiv qaror qabul qilish uchun foydali ekanligini ko‘rsatadi.

I. KIRISH

Bachadon miomasi ayollarda uchraydigan eng ko‘p tarqalgan yaxshi sifatli ginekologik o‘smalardan biri bo‘lib, uning klinik ko‘rinishi o‘smaning soni, o‘lchami va bachadondagi joylashuviga qarab sezilarli farq qiladi. Zamonaviy klinik amaliyotda ultratovush tekshiruvi bachadon miomasini dastlabki aniqlash uchun asosiy tasvirlash usullaridan biri hisoblanadi. Shu bilan birga, miomaning ayrim atipik yoki degenerativ ko‘rinishlari diagnostik jihatdan murakkab bo‘lishi mumkin. Tasvirga asoslangan avtomatlashtirilgan tizimlar ushbu jarayonda shifokorga yordam berishi mumkin, biroq bunday tizimlarning natijasi faqat model arxitekturasiga emas, balki kiruvchi tasvirning sifatiga ham bog‘liq.

So‘nggi yillarda bachadon miomasini ultratovush tasvirlaridan aniqlashda chuqur o‘qitish usullarining imkoniyatlari kengaymoqda. Huo va hammualliflar patologik tasdiqlangan ma’lumotlar asosida DCNN modelini ishlab chiqib, model yordamida kichik tajribaga ega ultratovush mutaxassislarining diagnostik ko‘rsatkichlari yaxshilanganini ko‘rsatgan. Shahzad va hammualliflar VGG16, ResNet50, InceptionV3 hamda maxsus DPCNN arxitekturalarini taqqoslab, chuqur o‘qitishning bachadon miomasini aniqlashdagi salohiyatini ko‘rsatgan. Yang va hammualliflar esa EfficientNet xususiyatlarini YOLOv3 detektori bilan birlashtirib, real vaqtga yaqin mioma aniqlash tizimini taklif qilgan. Xi va Wang tadqiqotida attention mexanizmi bilan takomillashtirilgan EfficientNetB0 modeli ham yuqori aniqlik ko‘rsatgan.

Biroq ushbu ishlarning katta qismida asosiy e’tibor modelning klassifikatsiya yoki deteksiya

(cc) BY *dtai.uz*

aniqligiga qaratilgan. Tasvirning o‘zi diagnostik jihatdan qanchalik foydali ekanini modelga uzatishdan oldin miqdoriy baholash masalasi nisbatan kamroq yoritilgan. Bu masala ayniqsa ultratovush tasvirlari uchun muhim, chunki speckle shovqin, past signal-shovqin nisbati, chegaralarning xiraligi va kontrastning o‘zgarishi segmentatsiya hamda klassifikatsiya jarayonlarini murakkablashtiradi. Ultrasound tasvirlarini segmentatsiyalash bo‘yicha tadqiqotlarda speckle shovqinining zaif yoki yo‘qolgan chegaralar, past signal-shovqin nisbati va kontrast aniqligining pasayishiga olib kelishi ko‘rsatilgan.

Klassik tasvir sifati baholash yondashuvlari ko‘pincha inson sezgisiga yaqin umumiy sifatni yoki reference tasvir bilan o‘xshashlikni o‘lchaydi. Masalan, SSIM strukturaviy o‘xshashlikni baholashga asoslanadi. Ammo diagnostik ultratovush tasvirining “foydaliligi” oddiy vizual sifat bilan aynan bir xil emas. Mioma mavjud bo‘lgan hududni ajratish uchun patologik va sog‘lom to‘qima orasidagi intensivlik farqi, tekstura, chegaraning aniqligi va shovqin darajasi birgalikda hisobga olinishi kerak. Shu nuqtai nazardan Shannon entropiyasi tasvirdagi axborot miqdorini tavsiflash uchun, gradient kattaligi esa chegaralarning aniqligini baholash uchun foydali matematik vosita bo‘la oladi.

Tadqiqotning yana bir muhim jihati mezonlar vaznini obyektiv aniqlashdir. Oddiy teng vaznli yig‘indi har bir ko‘rsatkichning ma’lumotlar tarkibidagi farqlovchi kuchini bir xil deb qabul qiladi. CRITIC usuli mezonning dispersiyasi va boshqa mezonlar bilan o‘zaro korrelyatsiyasini hisobga olgan holda obyektiv vaznlarni aniqlaydi. Shannon entropiyasiga asoslangan EWM esa mezon qiymatlarining taqsimlanishidagi axborot miqdorini hisobga oladi. Mazkur ikki yondashuvning kuchli tomonlarini birlashtirish tasvir informativligini baholashda barqarorroq mezon olish imkonini beradi.

Shundan kelib chiqib, ushbu maqolaning maqsadi bachadon miomasining ultratovush tasvirlarini keyingi sun’iy intellekt tahliliga tayyorlash uchun kontrast, entropiya, tekstura, chegara ravshanligi va shovqin darajasiga asoslangan kompleks informativlik algoritmini ishlab chiqish va eksperimental baholashdan iborat. Tadqiqotning asosiy savollari quyidagicha shakllantirildi: (1) ultratovush tasvirining informativligini bir nechta fizik-statistik xususiyatlar orqali yagona ko‘rsatkichga keltirish mumkinmi; (2) obyektiv vaznlash usullari orasida qaysi biri tasvirlarni “informativ” va “informativ emas” guruhlariga ajratishda samaraliroq; (3) taklif etilgan W* kombinatsiyalangan ko‘rsatkich shifokor etaloni bilan qiyoslanganda qanchalik barqaror natija beradi?

II. METODLAR.

Tadqiqot dizayni. Tadqiqot eksperimental hisoblash tajribasi shaklida tashkil etildi. Asosiy obyekt sifatida bachadon miomasini aniqlashga mo‘ljallangan ultratovush tasvirlari olindi. Algoritmning vazifasi tasvirni “mioma mavjud” yoki “mioma mavjud emas” deb bevosita aniqlash emas, balki uning keyingi avtomatlashtirilgan tahlil uchun yetarlicha informativ ekanini miqdoriy baholashdan iborat.

Ma’lumotlar to‘plami. Tadqiqotda jami 3050 ta ultratovush tasviri ishlatildi. Ma’lumotlar to‘plami ikki sinfga balanslangan: 1525 ta miomali va 1525 ta miomasiz tasvir. Eksperimentlarda ma’lumotlar train, validation va test qismlariga mos ravishda 80%, 10% va 10% nisbatda ajratilgan. Ushbu tuzilma klassifikatsiya m odelining ma’lum bir sinfga og‘ib ketish ehtimolini kamaytirish va natijalarni obyektiv baholashga xizmat qildi. Tasvirlar CNN asosidagi keyingi tahlilga moslashtirish uchun standart o‘lchamga keltirildi.

Oldindan ishlov berish. Har bir tasvir uchun o‘lcham standartlashtirildi va piksel intensivliklari hisoblash uchun bir xil diapazonga keltirildi. Algoritmning asosiy maqsadi diagnostik axborotni yo‘qotmasdan tasvirning kontrast, tekstura va chegara xususiyatlarini o‘lchash bo‘lgani sababli, oldindan ishlov berishda ortiqcha agressiv denoising qo‘llanilmadi. Bu yondashuv ultratovushdagi tabiiy speckle tuzilmasini to‘liq yo‘qotib yubormaslikka qaratildi.

(cc) BY

1. Kontrast ko‘rsatkichi. Tasvirdagi maksimal va minimal intensivlik qiymatlari asosida kontrast quyidagicha aniqlandi:

$$C = I_{max} - I_{min}$$

Ushbu (14)-ifodada I_{max} – maksimal intensivlik, I_{min} –minimal intensivlik.

Kontrastning yuqori bo‘lishi patologik hudud bilan fon orasidagi farqni ajratishga yordam beradi.

2. Entropiya. Tasvirdagi intensivliklar taqsimotining axborot mazmunini baholash uchun Shannon entropiyasi ishlatildi:

$$H = -\sum p(i) log_2 p(i)$$

Ushbu (15)-ifodada $p(i)$ –piksel intensivligi ehtimoli. Entropiya tasvirda mavjud intensivlik xilma-xilligini tavsiflaydi. Biroq yuqori entropiya har doim diagnostik jihatdan yuqori sifatni anglatmasligi mumkin; shuning uchun u boshqa ko‘rsatkichlar bilan birgalikda ishlatildi.

3. Tekstura ko‘rsatkichi. Tasvirning intensivlik o‘zgaruvchanligini ifodalash uchun standart og‘ish tipidagi tekstura mezoni hisoblandi:

$$\boldsymbol{T} = \sqrt{\frac{1}{N}\sum_{i-1}^{N}(\boldsymbol{I_i} - \boldsymbol{\mu})^2}$$

Ushbu (16)-ifodada T – Tekstura ko‘rsatkichi, $\mathbf{I_i}$ – piksel intensivligi, $\boldsymbol{\mu}$ -o‘rtacha intensivligi, N – piksellar soni.

Ushbu ko‘rsatkich ultratovush tasviridagi to‘qima tuzilishining murakkabligini miqdoriy ifodalashga xizmat qiladi.

4. Chegara ravshanligi. Patologik hudud chegaralarining aniqligini baholash uchun gradient kattaligi ishlatildi:

$$G = \sqrt{G_x^2 + G_y^2}$$

Ushbu (17)-ifodada G_x –gorizontal gradient, G_y –vertikal gradient.

Gradient kattaligi katta bo‘lgan hududlarda intensivlik tez o‘zgaradi va bunday joylar anatomik yoki patologik chegaralarga mos kelishi mumkin.

5. Shovqin darajasi. Ultratovush tasvirlarida speckle shovqin diagnostik chegaralarni xiralashtirishi va tekstura xususiyatlarini o‘zgartirishi mumkin. Shovqin darajasi nisbiy variatsiya ko‘rsatkichi orqali baholandi:

$$N = \frac{\sigma_n}{\mu}$$

Ushbu (18)-ifodada $I(x, y)$ – boshlang‘ich tasvir, $n(x, y)$ – shovqin parametrlari, $I_n(x, y)$ –shovqin tasvir.

N ortishi tasvirning shovqin bilan ifloslanishi kuchayganini bildiradi. Shu sababli integral informativlik formulasida N manfiy yo‘nalishda hisobga olindi.

6. Normallashtirish. C, H, T, G va N ko‘rsatkichlari turli o‘lchov birliklari va diapazonlarga ega bo‘lganligi sababli, ularni yagona o‘lchovga keltirish zarur. Benefit ko‘rsatkichlar uchun min-max normallashtirishdan foydalanildi:

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}};\ 0 \le X' \le 1$$

7. Integral informativlik modeli. Normallashtirilgan ko‘rsatkichlar vaznli yig‘indi orqali birlashtirildi:

$$I = w_1 C + w_2 H + w_3 T + w_4 G - w_5 N$$

Ushbu (19)-ifodada I –tasvir informativligi, C – kontrast ko‘rsatkichi, H – entropiya, T –tekstura ko‘rsatkichi, G –chegara ravshanligi, N –shovqin darajasi, w_i –vazn koiffisentlari.

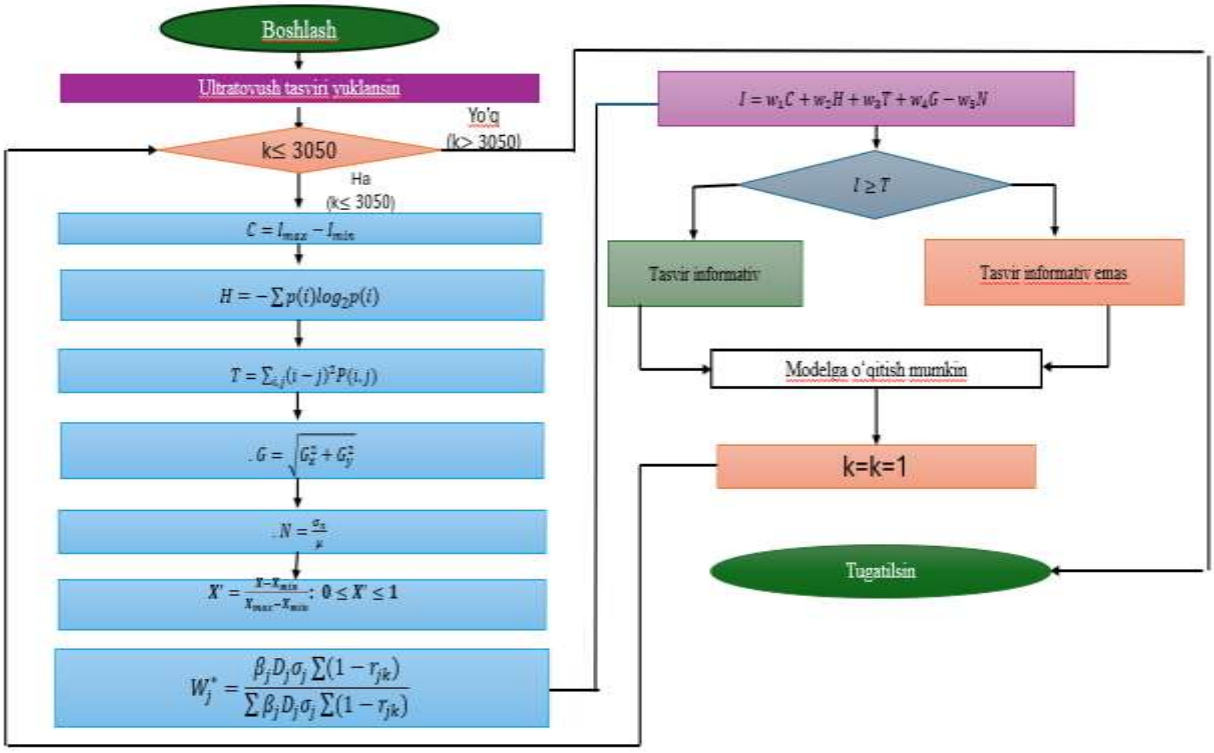
Formula diagnostik foydalilikka ijobiy ta’sir qiluvchi kontrast, entropiya, tekstura va chegara ravshanligini oshiradi, shovqinning ta’sirini esa kamaytiradi.

(cc) BY

8. Vaznlarni aniqlash. Vaznlar uch xil yondashuv orqali baholandi: CRITIC, EWM va W*. CRITIC usulida mezonning standart og‘ishi va mezonlararo korrelyatsiyasi hisobga olinadi. EWM usulida Shannon entropiyasi asosida obyektiv vaznlar olinadi. W* esa ikki obyektiv yondashuv natijalarini kombinatsiyalash uchun ishlatildi. Tadqiqot fayllaridagi yakuniy CRITIC vaznlari C=0,188197, H=0,207098, T=0,218292, G=0,170314 va N=0,216098; EWM vaznlari esa mos ravishda 0,056412, 0,291669, 0,225616, 0,247285 va 0,179017 qiymatlarini tashkil etdi. Bu natija turli usullar ayrim mezonlarning informatsion hissasini turlicha baholashini ko‘rsatadi.

9. Qaror qabul qilish. Integral I qiymati tanlangan threshold T bilan solishtirildi. Agar $I \geq T$ bo‘lsa, tasvir “Informativ” deb belgilanadi va keyingi klassifikatsiya yoki segmentatsiya bosqichiga uzatiladi. Agar $I < T$ bo‘lsa, tasvir “Informativ emas” deb belgilanadi; bunday tasvir qayta ishlanishi yoki alohida nazoratga yuborilishi mumkin.

Baholash mezonlari. Informativlikni baholash natijalarining samaradorligi Accuracy, Precision, Recall (Sensitivity) va Specificity orqali tekshirildi. Accuracy umumiy to‘g‘ri tasniflangan namunalar ulushini, Precision informativ deb topilgan tasvirlarning haqiqiy informativlik ulushini, Recall haqiqiy informativ tasvirlarning aniqlangan qismini, Specificity esa informativ bo‘lmagan tasvirlarning to‘g‘ri ajratilgan qismini ifodalaydi. Natijalar shifokor etaloni bilan qiyosiy baholandi.



1-rasm. Ultratovushli tasvir informativligini miqdoriy baholash algoritmining blok-sxemasi.

III. NATIJALAR.

Dataset bo‘yicha umumiy natijalar. Taklif etilgan algoritm 3050 ta ultratovush tasvirida sinovdan o‘tkazildi. Har bir tasvir uchun C, H, T, G va N qiymatlari hisoblanib, so‘ngra normallashtirilgan va uch xil vaznlash strategiyasi yordamida integral informativlik qiymati hosil qilingan. Eksperiment natijalarida yuqori informativlikka ega tasvirlarda odatda kontrast va gradient ko‘rsatkichlari yetarlicha yuqori, shovqin darajasi esa nisbatan past bo‘lishi kuzatildi. Aksincha, xira yoki shovqinli tasvirlarda integral informativlik qiymati pasaygan.

(cc) BY

Tadqiqot ma’lumotlarida ayrim tasvirlarning C qiymati 255 gacha yetgani, entropiya taxminan 4–7, tekstura ko‘rsatkichi esa turli tasvirlarda sezilarli farq qilgani ko‘rinadi. Masalan, alohida namunalar uchun I_CRITIC_new_norm qiymatlari 0,32–0,83 atrofida o‘zgarib, yuqori qiymatlar “Informativ”, past qiymatlar esa “Informativ emas” holatiga mos kelgan. Shu bilan birga, uchta vaznlash usulining bir xil tasvir bo‘yicha qarori hamma hollarda bir xil bo‘lmagan. Bu holat vazn tanlash usulining yakuniy qarorga ta’sirini ko‘rsatadi.

CRITIC natijalari. CRITIC usulida Accuracy 82,33%, Precision 80,95%, Recall 100,00% va Specificity 28,99% natijalar qayd etildi. Ushbu natijada Recall juda yuqori bo‘lib, haqiqiy informativ tasvirlarning deyarli barchasi aniqlangan. Biroq Specificity ning 28,99% bo‘lishi informativ bo‘lmagan tasvirlarni ajratish qobiliyati past ekanini bildiradi. Demak, CRITIC yondashuvi “informativ tasvirni o‘tkazib yubormaslik” nuqtai nazaridan kuchli, ammo ortiqcha qabul qilishlar sonini kamaytirish nuqtai nazaridan yetarli emas.

EWM natijalari. EWM usulida Accuracy 97,77%, Precision 97,85%, Recall 99,21% va Specificity 93,41% qiymatlar olindi. CRITIC bilan taqqoslaganda barcha asosiy mezonlarda, ayniqsa Specificity bo‘yicha katta yaxshilanish kuzatildi. Bu EWM vaznlari tasvirlar orasidagi axborot farqlanishini yaxshiroq aks ettirganini ko‘rsatadi. Shuningdek, Recall 99,21% bo‘lgani sababli informativ tasvirlarni aniqlash qobiliyati ham yuqori saqlanib qolgan.

W* taklif etilgan kombinatsiyalangan yondashuv. Taklif etilgan W* yondashuvi CRITIC va EWM ning obyektiv vaznlash xususiyatlarini birlashtirish maqsadida qo‘llanildi. Shifokor etaloni bilan qiyoslashda W* uchun Accuracy 98,89%, Precision 98,22%, Recall 99,67% va Specificity 96,08% natijalar qayd etildi. Bu to‘rtta mezon bo‘yicha eng muvozanatli natijani ko‘rsatadi.

1-jadval.

Informativlikni baholash usullarining qiyosiy natijalari.

Usul	Accuracy, %	Precision, %	Recall, %	Specificity, %
CRITIC	82,33	80,95	100,00	28,99
EWM	97,77	97,85	99,21	93,41
W* (taklif etilgan)	98,89	98,22	99,67	96,08

2-jadval.

Tadqiqotdagi 3050 ta tasvir to‘plamining tarkibi.

Ko‘rsatkich	Qiymat
Jami tasvirlar	3050
Mioma mavjud	1525
Mioma mavjud emas	1525
Train	80%
Validation	10%
Test	10%

Algoritmning amaliy ishlashi. Taklif etilgan algoritmning muhim afzalligi shundaki, u klassifikatorni to‘g‘ridan-to‘g‘ri ishga tushirishdan oldin tasvirning o‘ziga xos xususiyatlarini tahlil qiladi. Bunda tasvir “yaxshi” yoki “yomon” degan subyektiv baho bilan emas, bir nechta o‘lchanadigan mezonlarning birgalikdagi qiymati bilan tavsiflanadi. Natijada keyingi bosqichga yuboriladigan tasvirlar sifat jihatidan saralangan bo‘ladi.

(cc) BY

Threshold masalasi. Informativlikni ikkita guruhga ajratish uchun threshold asosiy qaror parametridir. Tajriba ma’lumotlarida thresholdning juda past qiymati informativ bo‘lmagan tasvirlarning ham tizimga kirib kelishiga, juda yuqori qiymati esa foydali tasvirlarning chiqarib tashlanishiga olib kelishi mumkinligi kuzatildi. Shu sababli thresholdni faqat nazariy ravishda emas, balki validation to‘plamidagi Accuracy, Precision, Recall va Specificity muvozanati asosida tanlash maqsadga muvofiq.

Algoritmning keyingi AI bosqichlariga ta’siri. Informativlikni oldindan baholash keyingi klassifikatsiya va segmentatsiya jarayonlarini sifat nazorati bilan ta’minlaydi. Past informativlikka ega tasvirlarni alohida qayta ishlash, masalan, kontrastni yaxshilash yoki shovqinni kamaytirish mumkin. Yuqori informativlikka ega tasvirlar esa to‘g‘ridan-to‘g‘ri CNN modeli yoki segmentatsiya moduliga uzatilishi mumkin. Shu jihatdan taklif etilgan algoritm mustaqil klassifikator emas, balki avtomatlashtirilgan diagnostik pipeline ning sifatni nazorat qiluvchi oldingi moduli sifatida qaraladi**.**

IV. MUHOKAMA

Olingan natijalar shuni ko‘rsatadiki, ultratovush tasvirining diagnostik informativligini bitta parametr bilan ifodalash yetarli emas. Kontrast, entropiya, tekstura, chegara ravshanligi va shovqin turli fizik va statistik jihatlarni aks ettiradi. Kontrast patologik va sog‘lom to‘qima orasidagi intensivlik farqini ifodalasa, gradient chegara o‘tishining keskinligini tavsiflaydi. Entropiya tasvirdagi intensivlik xilma-xilligini, tekstura esa intensivliklarning tarqalish xususiyatini ifodalaydi. Shovqin esa foydali diagnostik tuzilmalarga xalaqit beruvchi omil sifatida kiritildi.

Mazkur ko‘rsatkichlarning birgalikda qo‘llanishi tasvir sifatini “vizual yoqimlilik” bilan cheklab qo‘ymaydi. Masalan, yuqori entropiyali tasvir shovqinli bo‘lishi mumkin; bunday tasvirda axborot miqdori matematik jihatdan yuqori bo‘lsa-da, diagnostik foydalilik pasayadi. Shu sababli entropiyani yolg‘iz ishlatish noto‘g‘ri xulosaga olib kelishi mumkin. Taklif etilgan integral formula aynan shunday holatlarni boshqa mezonlar yordamida muvozanatlashtiradi.

Shovqinni manfiy komponent sifatida kiritish ultratovush tasvirlari uchun muhim metodologik qarordir. Speckle shovqin oddiy oq shovqindan farq qiladi va to‘qima tuzilmasi bilan bog‘liq bo‘lishi mumkin. Shu sababli uni to‘liq olib tashlash ham har doim foydali emas. Bizning yondashuvda maqsad shovqinni yo‘qotish emas, uning tasvir informativligiga salbiy ta’sirini alohida o‘lchashdir. Bu keyingi qayta ishlash bosqichida qaysi tasvirlarga qo‘shimcha preprocessing kerakligini aniqlashga imkon beradi.

Natijalarning eng muhim qismi vaznlash usullarining qiyosidir. CRITIC natijasida Recall=100% bo‘lgani tasvirlarning deyarli hech biri informativ guruhdan tashqarida qolmaganini ko‘rsatadi. Biroq Specificity=28,99% bo‘lgani sababli informativ bo‘lmagan tasvirlarning katta qismi ham informativ deb qabul qilingan. Avtomatlashtirilgan tibbiy tizim uchun bunday nomutanosiblik amaliy jihatdan muhim kamchilik hisoblanadi, chunki keyingi AI moduliga ortiqcha va sifatsiz tasvirlarning uzatilishi hisoblash resurslarini sarflaydi va noto‘g‘ri qaror ehtimolini oshiradi.

EWM natijalari esa ancha muvozanatli bo‘ldi. Accuracy 97,77% va Specificity 93,41% qiymatlari informativ bo‘lmagan tasvirlarni ham yaxshi ajratish imkonini bergan. EWM ning yuqori natijasi uning mezonlar taqsimotidagi farqlanishni hisobga olishi bilan izohlanishi mumkin. Ayniqsa, tekstura, gradient va shovqin ko‘rsatkichlarining tasvirlar bo‘yicha o‘zgaruvchanligi ularning umumiy qarordagi hissasini shakllantirishga yordam beradi.

W* natijalari esa barcha mezonlarda eng yaxshi muvozanatni ko‘rsatdi. Accuracy 98,89% ga yetgan, Precision 98,22%, Recall 99,67% va Specificity 96,08% bo‘lgan. Bu holat taklif etilgan kombinatsiyalangan yondashuvning asosiy afzalligini ko‘rsatadi: u faqat informativ tasvirlarni maksimal darajada topishga emas, balki informativ bo‘lmagan tasvirlarni ham to‘g‘ri chiqarib tashlashga intiladi. Shu sababli W* keyingi klassifikatsiya yoki segmentatsiya bosqichiga

(cc) BY

yuboriladigan tasvirlar oqimini sifat jihatidan nazorat qilish uchun maqsadga muvofiq.

Natijalarni mavjud tadqiqotlar bilan qiyoslash ham muhim. Huo va hammualliflarning tadqiqotida DCNN modeli ultratovush mutaxassislariga yordam berib, diagnostik Accuracy ni 94% dan yuqori darajaga olib chiqqan. Shahzad va hammualliflar esa chuqur o‘qitish modellarining bachadon miomasini aniqlashdagi yuqori imkoniyatlarini ko‘rsatgan. Xi va Wang tomonidan EfficientNetB0 asosidagi attention modeli ham 0,99 Accuracy ga yaqin natija bergan. Ushbu ishlar modelning o‘zi qanchalik kuchli bo‘lishi mumkinligini ko‘rsatadi. Bizning ishimizning farqli jihati esa modelni yanada murakkablashtirishdan oldin kiruvchi tasvirning informativlik darajasini alohida baholashga qaratilgan.

Bu farq metodologik jihatdan muhim. Agar model barcha tasvirlarni bir xil sifatga ega deb qabul qilsa, past sifatli namunalar uning o‘rganish jarayoniga salbiy ta’sir qilishi mumkin. Informativlik moduli esa tasvirlarni sifat bo‘yicha ajratib, keyingi tahlilni shartli va moslashuvchan qilish imkonini beradi. Shu ma’noda taklif etilgan algoritm klassifikatorning o‘rnini bosmaydi; aksincha, klassifikatorga beriladigan ma’lumot oqimini sifat nazoratidan o‘tkazadi.

Tadqiqotning nazariy ahamiyati shundaki, “tasvir informativligi” tushunchasi bir nechta o‘lchanadigan tasvir xususiyatlarining vaznli funksiyasi sifatida formal ifodalandi. Bu yondashuv keyinchalik boshqa organlar yoki boshqa tibbiy tasvir modalitetlariga moslashtirilishi mumkin. Masalan, ultratovushning boshqa anatomik sohalarida ham kontrast, gradient, tekstura va shovqin birgalikda tahlil qilinishi mumkin. Bunda vaznlar va threshold yangi dataset asosida qayta kalibrlanishi kerak.

Amaliy ahamiyati shundaki, algoritm nisbatan sodda hisoblash amallariga asoslangan. C, H, T, G va N ko‘rsatkichlari OpenCV, NumPy kabi standart kutubxonalar yordamida hisoblanishi mumkin. Shuning uchun u yuqori hisoblash quvvatini talab qiladigan neyron tarmoqdan oldingi modul sifatida ishlatilishi mumkin. Bu, ayniqsa, klinik tizimda past sifatli tasvirlarni erta aniqlash uchun foydalidir.

Shuningdek, informativlik algoritmini dinamik klassifikatsiya tizimi bilan birlashtirish imkoniyati mavjud. Bunda I qiymati modelning bashorat ehtimoli, sinflararo ehtimollik farqi va modellararo kelishuv darajasi bilan birgalikda ishlatilishi mumkin. Masalan, yuqori informativlik va yuqori model ishonchliligi bir xil yo‘nalishda bo‘lsa, tizim avtomatik qarorga yuqori ishonch bilan kelishi mumkin. Aksincha, I past bo‘lsa, modelning yuqori probability qiymati ham ehtiyotkorlik bilan talqin qilinishi kerak.

Cheklovlar. Birinchidan, 3050 ta tasvirlik dataset nisbatan katta bo‘lsa-da, u ko‘p markazli klinik dataset o‘rnini bosa olmaydi. Turli ultratovush apparatlari, operatorlar, bemorlarning anatomik xususiyatlari va tasvir protokollari natijalarga ta’sir qilishi mumkin. Ikkinchidan, informativlik thresholdi bitta datasetga moslangan bo‘lishi ehtimoli mavjud; boshqa markaz yoki boshqa qurilmada qayta kalibrlash talab qilinadi. Uchinchidan, “shifokor etaloni” bilan baholash natijalarini mustaqil, ko‘p ekspertli va ko‘p markazli validatsiya bilan mustahkamlash zarur. To‘rtinchidan, yuqori Accuracy klinik foydalilikning yagona kafolati emas; klinik qaror uchun sensitivity, specificity, calibration, external validation va decision-curve kabi ko‘rsatkichlar ham o‘rganilishi kerak.

Kelajakdagi tadqiqotlarda informativlik qiymatini klinik metadata, model uncertainty va segmentation quality bilan birlashtirish maqsadga muvofiq. Bundan tashqari, thresholdni qo‘lda belgilash o‘rniga validation to‘plamidan optimal qiymatni avtomatik tanlaydigan mexanizm ishlab chiqish mumkin. Shuningdek, W* vaznlarini turli populyatsiyalar va turli ultratovush qurilmalarida tekshirish algoritmning umumlashtirish qobiliyatini aniqroq baholash imkonini beradi.

Umuman olganda, tadqiqot natijalari ultratovush tasvirini tahlil qilishda “model qanchalik kuchli?” degan savol bilan bir qatorda “modelga qanday sifatdagi tasvir berilyapti?” degan savol ham muhimligini ko‘rsatadi. Taklif etilgan

(cc) BY

informativlik algoritmi shu ikki masalani bog‘lovchi sifat nazorati qatlamini yaratadi.

V. XULOSA.

Mazkur tadqiqotda bachadon miomasining ultratovush tasvirlarini avtomatlashtirilgan tahlil qilishdan oldin ularning diagnostik va algoritmik informativligini miqdoriy baholovchi algoritm ishlab chiqildi. Algoritm kontrast, Shannon entropiyasi, tekstura, gradient asosidagi chegara ravshanligi va shovqin darajasini birgalikda hisobga oladi. Turli diapazon va birliklarga ega bo‘lgan ko‘rsatkichlar normallashtirilib, vaznli integral informativlik qiymatiga keltirildi.

3050 ta tasvirdan tashkil topgan balanslangan datasetdagi tajribalar CRITIC, EWM va W* yondashuvlari orasida sezilarli farq mavjudligini ko‘rsatdi. CRITIC usuli Recall bo‘yicha 100% natija bergan bo‘lsa-da, Specificity 28,99% bo‘lib qoldi. EWM yondashuvi 97,77% Accuracy va 93,41% Specificity bilan ancha muvozanatli natija berdi. Taklif etilgan W* yondashuvi esa Accuracy=98,89%, Precision=98,22%, Recall=99,67% va Specificity=96,08% natijalarni ko‘rsatib, barcha asosiy mezonlar bo‘yicha eng muvozanatli ko‘rsatkichni ta’minladi.

Olingan natijalar tasvir informativligini klassifikatsiya yoki segmentatsiyadan oldingi sifat nazorati moduli sifatida qo‘llash mumkinligini ko‘rsatadi. Algoritmning amaliy qiymati shundaki, u past sifatli tasvirlarni erta aniqlash, zarur bo‘lsa qayta preprocessing qilish va keyingi sun’iy intellekt modullariga mos tasvirlarni saralash imkonini beradi. Kelgusida algoritmni ko‘p markazli klinik datasetlarda, turli ultratovush qurilmalarida va mustaqil shifokorlar bahosi bilan tashqi validatsiya qilish zarur. Shuningdek, informativlikni model uncertainty va segmentatsiya sifat ko‘rsatkichlari bilan birlashtirish yanada ishonchli avtomatlashtirilgan diagnostik tizim yaratishga xizmat qilishi mumkin.

FOYDALANILGAN ADABIYOTLAR

1. Stewart, E. A., Cookson, C. L., Gandolfo, R. A., & Schulze-Rath, R. (2016). Epidemiology of uterine fibroids: a systematic review. BJOG, 124(10), 1501–1512. https://doi.org/10.1111/1471-0528.14640
2. Baird, D. D., Dunson, D. B., Hill, M. C., Cousins, D., & Schectman, J. M. (2003). High cumulative incidence of uterine leiomyoma in black and white women: ultrasound evidence. American Journal of Obstetrics and Gynecology, 188(1), 100–107.
3. Stewart, E. A. (2016). Uterine fibroids. New England Journal of Medicine, 372, 1646–1655. https://doi.org/10.1056/NEJMra1209993
4. Awiwi, M. O., Badawy, M., Shaaban, A. M., et al. (2022). Review of uterine fibroids: imaging of typical and atypical features, variants, and mimics with emphasis on workup and FIGO classification. Abdominal Radiology, 47(7), 2468–2485. https://doi.org/10.1007/s00261-022-03545-x
5. Bajaj, S., Gopal, N., Clingan, M. J., & Bhatt, S. (2022). A pictorial review of ultrasonography of the FIGO classification for uterine leiomyomas. Abdominal Radiology, 47(1), 341–351. https://doi.org/10.1007/s00261-021-03283-6
6. Huo, T., Li, L., Chen, X., et al. (2023). Artificial intelligence-aided method to detect uterine fibroids in ultrasound images: a retrospective study. Scientific Reports, 13, 3714. https://doi.org/10.1038/s41598-023-30717-0
7. Shahzad, A., Mushtaq, A., Sabeeh, A. Q., et al. (2023). Automated uterine fibroids detection in ultrasound images using deep convolutional neural networks. Healthcare, 11(10), 1493. https://doi.org/10.3390/healthcare11101493
8. Yang, T., Yuan, L., Li, P., & Liu, P. (2023). Real-time automatic assisted detection of uterine fibroid in ultrasound images using a deep learning detector. Ultrasound in Medicine & Biology, 49(7), 1616–1626. https://doi.org/10.1016/j.ultrasmedbio.2023.03.013
9. Xi, H., & Wang, W. (2024). Deep learning based uterine fibroid detection in ultrasound images. BMC Medical Imaging, 24, 218. https://doi.org/10.1186/s12880-024-01389-z

(cc) BY *dtai.uz*

10. Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. In Medical Image Computing and Computer-Assisted Intervention (MICCAI), 234–241. https://doi.org/10.1007/978-3-319-24574-4_28
11. Oktay, O., Schlemper, J., Folgoc, L. L., et al. (2018). Attention U-Net: Learning where to look for the pancreas. arXiv:1804.03999.
12. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 770–778. https://doi.org/10.1109/CVPR.2016.90
13. Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 4700–4708. https://doi.org/10.1109/CVPR.2017.243
14. Tan, M., & Le, Q. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. Proceedings of the 36th International Conference on Machine Learning, 6105–6114.
15. Litjens, G., Kooi, T., Bejnordi, B. E., et al. (2017). A survey on deep learning in medical image analysis. Medical Image Analysis, 42, 60–88. https://doi.org/10.1016/j.media.2017.07.005
16. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. Nature, 521, 436–444. https://doi.org/10.1038/nature14539
17. Shannon, C. E. (1948). A mathematical theory of communication. Bell System Technical Journal, 27(3), 379–423; 27(4), 623–656. https://doi.org/10.1002/j.1538-7305.1948.tb01338.x
18. Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural features for image classification. IEEE Transactions on Systems, Man, and Cybernetics, SMC-3(6), 610–621. https://doi.org/10.1109/TSMC.1973.4309314
19. Wang, Z., Bovik, A. C., Sheikh, H. R., & Simoncelli, E. P. (2004). Image quality assessment: From error visibility to structural similarity. IEEE Transactions on Image Processing, 13(4), 600–612. https://doi.org/10.1109/TIP.2003.819861
20. Slabaugh, G., Unal, G., Wels, M., Fang, T., & Rao, B. (2009). Statistical region-based segmentation of ultrasound images. Ultrasound in Medicine & Biology, 35(5), 781–795. https://doi.org/10.1016/j.ultrasmedbio.2008.10.014
21. Diakoulaki, D., Mavrotas, G., & Papayannakis, L. (1995). Determining objective weights in multiple criteria problems: The CRITIC method. Computers & Operations Research, 22(7), 763–770. https://doi.org/10.1016/0305-0548(94)00059-H
22. Al-jaburi, A. A., & AL-sudani, A. H. (2022). Medical ultrasound image quality enhancement and regions segmentation. Iraqi Journal of Science, 63(10). https://doi.org/10.24996/ijs.2022.63.10.35
23. Jiang, Z., et al. (2025). Speckle2Self: Self-supervised ultrasound speckle reduction without clean data. Medical Image Analysis, 103755. https://doi.org/10.1016/j.media.2025.103755

(cc) BY