SUN’IY INTELLEKT VA KOMPYUTER KO‘RISH TEXNOLOGIYALARIGA ASOSLANGAN MIYA O‘SMALARINI AVTOMATIK DIAGNOSTIKA QILISH ALGORITMLARINI ISHLAB CHIQISH

Jumaniyazova Mashxura Azamatovna
Urganch RANCH texnologiylari Universiteti Kompyuter injineringi magistranti
E-mail: mashhurajumaniyazova2308@gmail.com
Urazmatov Tohir Quranboyevich
Urganch RANCH texnologiyalari universiteti

Annotatsiya. Mazkur maqolada miya o‘smalarini magnit-rezonans tomografiya (MRT) tasvirlari asosida avtomatik aniqlash, segmentatsiya qilish va tasniflash uchun sun’iy intellekt hamda kompyuter ko‘rish texnologiyalaridan foydalanish masalalari yoritilgan. Tasvirlarni dastlabki qayta ishlash, patologik hududlarni ajratish, chuqur o‘rganish asosida xususiyatlarni aniqlash va yakuniy diagnostik qarorni shakllantirish bosqichlari yagona algoritmik tizim sifatida ko‘rib chiqilgan. Konvolyutsion neyron tarmoqlar, U-Net oilasidagi segmentatsiya arxitekturalari va transfer learning yondashuvlarining imkoniyatlari tahlil qilingan. Model samaradorligini baholashda Dice, IoU, sezgirlik, spetsifiklik va F1-mezon kabi ko‘rsatkichlardan foydalanish zarurligi asoslangan. Taklif etilayotgan tizim shifokorni almashtirish emas, balki MRT tasvirlarini saralash, shubhali o‘choqlarni aniqlash va klinik qaror qabul qilishni qo‘llab-quvvatlashga mo‘ljallangan.

Kalit so‘zlar: sun’iy intellekt, kompyuter ko‘rish, miya o‘smasi, MRT, segmentatsiya, chuqur o‘rganish, konvolyutsion neyron tarmoq, avtomatik diagnostika.

Аннотация. В статье рассматриваются вопросы разработки алгоритмов автоматической диагностики опухолей головного мозга на основе изображений магнитно-резонансной томографии (МРТ) с применением искусственного интеллекта и технологий компьютерного зрения. Рассмотрены этапы предварительной обработки изображений, сегментации патологических областей, автоматического выделения признаков с использованием глубокого обучения и формирования итогового диагностического решения. Проанализированы возможности сверточных нейронных сетей, архитектур семейства U-Net и подходов transfer learning. Обоснована необходимость оценки качества моделей по показателям Dice, IoU, чувствительности, специфичности и F1-мере. Предлагаемая система рассматривается как инструмент поддержки принятия клинических решений, а не как замена врача.

ISSN 3030-3907

Ключевые слова: искусственный интеллект, компьютерное зрение, опухоль головного мозга, МРТ, сегментация, глубокое обучение, сверточная нейронная сеть, автоматическая диагностика.

Abstract. This paper examines the development of artificial intelligence and computer vision algorithms for the automatic diagnosis of brain tumors using magnetic resonance imaging (MRI). The study considers image preprocessing, pathological-region segmentation, automatic feature extraction through deep learning, and final diagnostic classification as an integrated algorithmic workflow. The practical potential of convolutional neural networks, U-Net-based segmentation architectures, and transfer learning is discussed. The importance of evaluating model performance using Dice, IoU, sensitivity, specificity, and F1-score is emphasized. The proposed system is intended to support clinical decision-making by assisting specialists in image screening, tumor localization, and quantitative assessment rather than replacing medical expertise.

Keywords: artificial intelligence, computer vision, brain tumor, MRI, segmentation, deep learning, convolutional neural network, automatic diagnosis.

KIRISH.

Miya o‘smalari markaziy asab tizimining murakkab va klinik jihatdan muhim patologiyalaridan biri hisoblanadi. Ularning joylashuvi, hajmi, infiltratsiya darajasi va to‘qimalar bilan o‘zaro munosabati bemorning hayot sifati hamda davolash taktikasiga bevosita ta’sir ko‘rsatadi. Shu sababli kasallikni imkon qadar erta aniqlash, o‘sma chegaralarini aniq belgilash va uning turini to‘g‘ri baholash zamonaviy neyrodiagnostikaning muhim vazifalaridan biridir. Amaliyotda bu jarayon ko‘pincha MRT tasvirlarini tahlil qilishga asoslanadi. Biroq tasvirlar sonining ko‘pligi, o‘sma shaklining xilma-xilligi va sog‘lom hamda patologik to‘qimalar orasidagi farqning ayrim hollarda juda kichik bo‘lishi mutaxassis uchun qo‘shimcha yuklama hosil qiladi.

So‘nggi yillarda sun’iy intellektning tibbiy tasvirlarni qayta ishlash sohasiga jadal kirib kelishi ushbu muammoni yangi nuqtayi nazardan ko‘rib chiqish imkonini berdi. Ayniqsa, kompyuter ko‘rish va chuqur o‘rganish algoritmlari tasvirdagi murakkab naqshlarni inson tomonidan qo‘lda berilgan qoidalarga kamroq bog‘liq holda o‘rganishi bilan ajralib turadi. Bunday tizimlar o‘sma mavjudligini aniqlash, uning konturini belgilash, patologik hudud hajmini baholash va ayrim hollarda o‘sma turini tasniflash vazifalarida qo‘llanmoqda.

Ushbu maqolaning maqsadi miya o‘smalarini MRT tasvirlari asosida avtomatik diagnostika qilishga mo‘ljallangan algoritmik yondashuvni ishlab chiqishning nazariy va amaliy asoslarini bayon etishdan iborat. Bunda

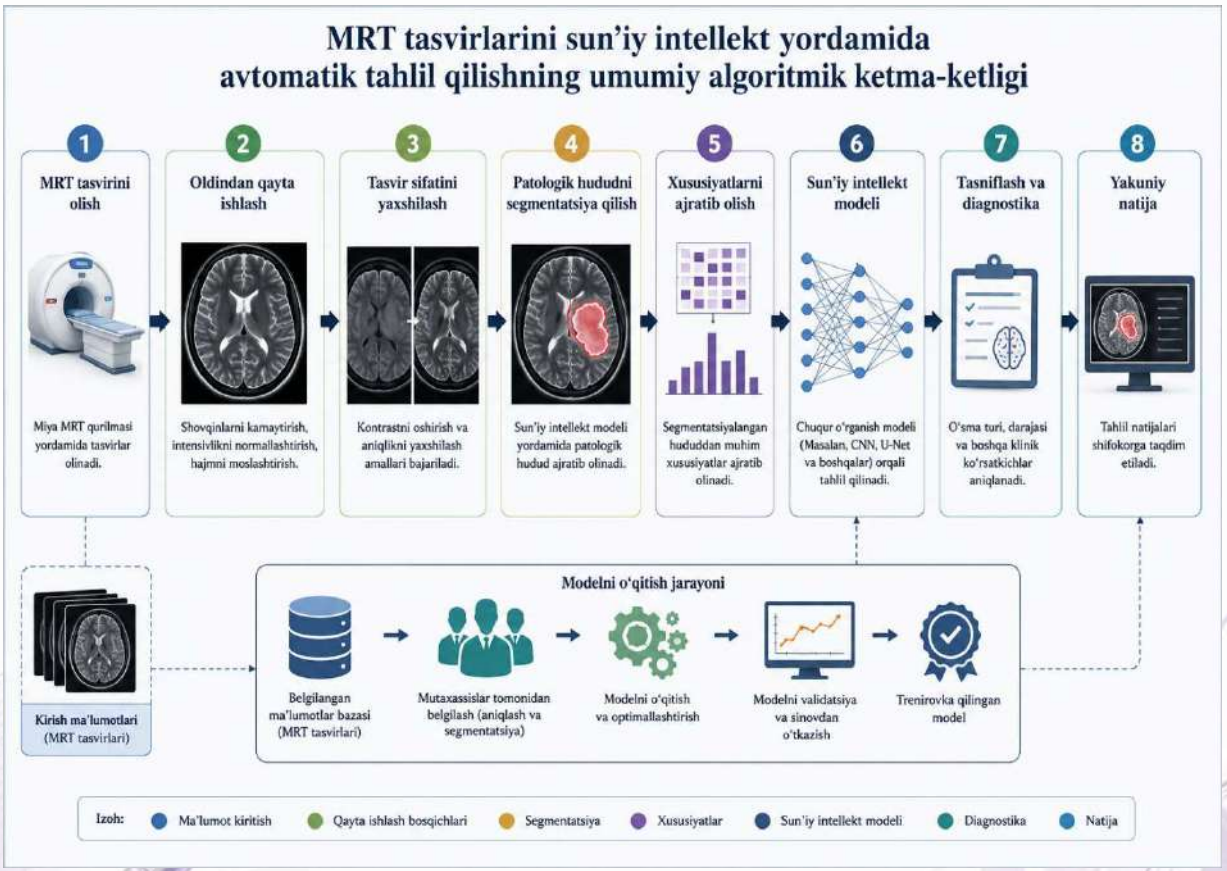
ISSN 3030-3907

ma’lumotlarni tayyorlashdan tortib modelni o‘qitish, baholash va klinik qo‘llashgacha bo‘lgan bosqichlar yagona tizim sifatida ko‘rib chiqiladi.

1. Miya o‘smalarini diagnostika qilishda MRT tasvirlarining o‘rni

MRT markaziy asab tizimi tuzilmalarini yuqori kontrast bilan tasvirlash imkonini beradigan noinvaziv diagnostika usulidir. T1, T2, FLAIR va kontrast bilan kuchaytirilgan T1 kabi ketma-ketliklar o‘smaning turli morfologik xususiyatlarini aks ettiradi. Bir tasvir turida yaxshi ko‘rinadigan patologik o‘zgarish boshqa ketma-ketlikda boshqacha ko‘rinishga ega bo‘lishi mumkin. Shuning uchun avtomatik tahlil tizimida multimodal tasvirlardan foydalanish modelga o‘sma va sog‘lom to‘qima o‘rtasidagi farqlarni yanada to‘liq o‘rganish imkonini beradi.

MRT tasvirlarining muhim xususiyati shundaki, ular turli qurilmalar, protokollar va parametrlar yordamida olinadi. Natijada bir xil kasallikka ega bemorlarda tasvirlarning intensivligi, o‘lchami va shovqin darajasi sezilarli farq qilishi mumkin. Algoritm faqat bitta markaz ma’lumotlariga moslashib qolsa, boshqa klinik muhitdagi tasvirlarda natijaning aniqligi pasayishi ehtimoli mavjud. Shu sababli avtomatik diagnostika tizimini ishlab chiqishda ma’lumotlarning xilma-xilligi va standartlashtirilishi alohida ahamiyat kasb etadi.



1-rasm. MRT tasvirlarini sun’iy intellekt yordamida avtomatik tahlil qilishning umumiy algoritmik ketma-ketligi.

ISSN 3030-3907

MRT tasvirlarini kompyuter orqali tahlil qilish odatda uchta asosiy vazifani qamrab oladi: patologik o‘choqni aniqlash, o‘sma hududini segmentatsiya qilish va o‘sma turini yoki darajasini tasniflash. Ushbu vazifalar bir-biridan mustaqil bo‘lishi mumkin, biroq amaliy tizimda ular ketma-ket yoki yagona ko‘p vazifali model tarkibida bajarilishi mumkin.

2. Ma’lumotlarni tayyorlash va dastlabki qayta ishlash

Har qanday mashinali o‘rganish tizimining sifati, avvalo, undan foydalaniladigan ma’lumotlar to‘plamining sifati bilan belgilanadi. Miya o‘smalarini aniqlash uchun MRT ma’lumotlari bemorning klinik holati, tasvir ketma-ketligi va ekspert tomonidan belgilangan haqiqiy javob bilan bog‘langan bo‘lishi lozim. Segmentatsiya masalasida esa har bir tasvir uchun o‘sma hududining konturi yoki piksel darajasidagi niqobi talab qilinadi. Bunday belgilashlar tajribali radiolog yoki neyroxirurg tomonidan tasdiqlanishi model uchun ishonchli o‘quv namunalarini shakllantiradi.

Dastlabki qayta ishlash bosqichida tasvir o‘lchamini standartlashtirish, intensivlikni normallashtirish, keraksiz fonni olib tashlash va shovqinni kamaytirish kabi amallar bajariladi. Intensivlikni normallashtirish turli skanerlardan olingan tasvirlar o‘rtasidagi texnik tafovutlarni kamaytiradi. Biroq ortiqcha filtrlash o‘smaning mayda chegaralarini yo‘qotishi mumkinligi sababli parametrlarni ehtiyotkorlik bilan tanlash talab etiladi.

1-jadval.

MRT tasvirlarini dastlabki qayta ishlash bosqichlari.

Bosqich	Asosiy amal	Maqsad	Natija
Formatlash	O‘lcham va voxel oralig‘ini standartlashtirish	Tasvirlarni bir xil ko‘rinishga keltirish	Barqaror kirish
Normalizatsiya	Intensivlikni me’yorlash	Skaner farqlarini kamaytirish	Umumlashtirish
Shovqinni kamaytirish	Yengil filtrlash	Keraksiz tebranishlarni kamaytirish	Sifat oshadi
Augmentation	Burish, masshtablash, intensivlik o‘zgarishi	Namuna xilma-xilligini oshirish	Overfitting kamayadi

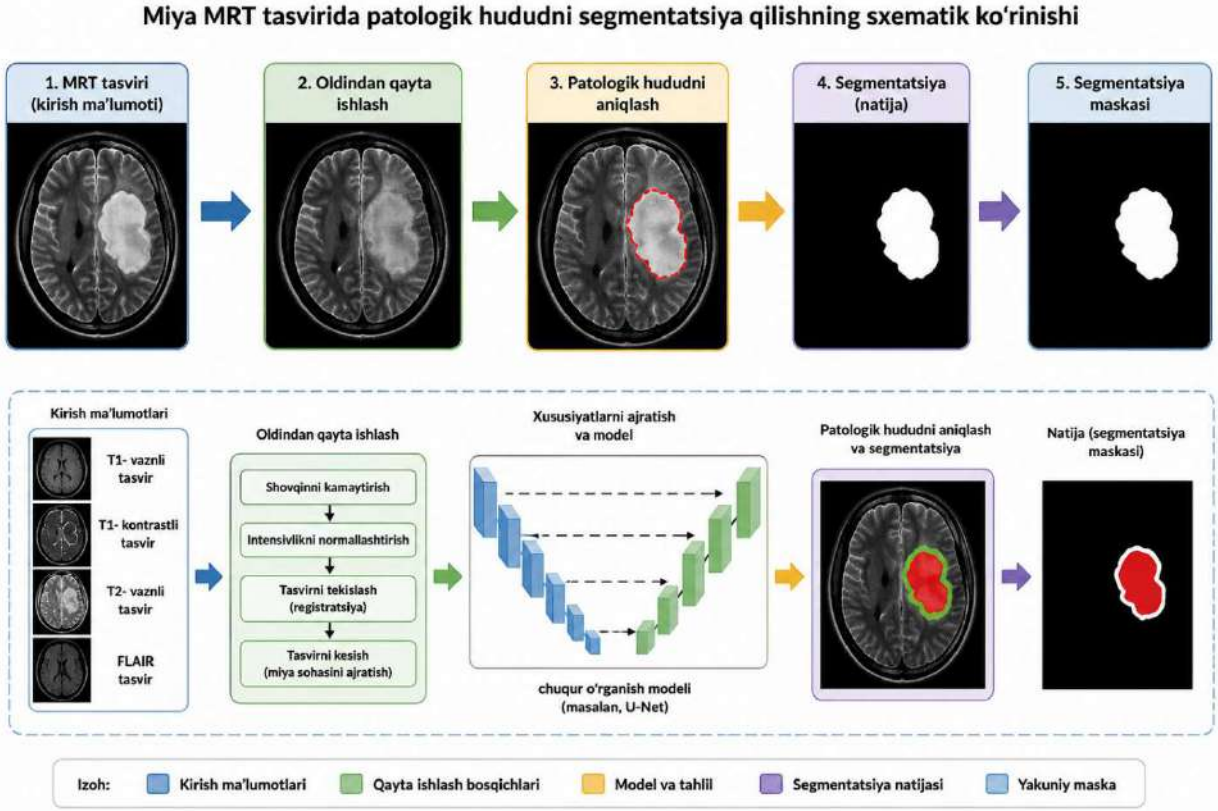
Ma’lumotlarni kengaytirish, ya’ni augmentation ham muhim bosqichdir. Tasvirni kichik burchakka burish, masshtabini o‘zgartirish, gorizontal yoki vertikal o‘zgartirish, yorqinlikni biroz almashtirish kabi usullar modelni turli tasvir

ISSN 3030-3907

sharoitlariga moslashishga yordam beradi. Biroq anatomik jihatdan mantiqsiz transformatsiyalar qo‘llansa, model real klinik holatga mos kelmaydigan belgilarni o‘rganib qolishi mumkin. Shu sababli augmentation tibbiy mazmunni saqlab qoladigan chegaralarda amalga oshirilishi kerak.

3. Kompyuter ko‘rish asosida o‘sma hududini aniqlash

Kompyuter ko‘rish tizimining birinchi vazifasi tasvirdagi shubhali hududni aniqlashdir. Klassik yondashuvlarda chegaraviy qiymatga asoslangan segmentatsiya, morfologik amallar, kontur aniqlash va tekstura belgilaridan foydalanilgan. Bunday usullar ayrim nazorat qilinadigan sharoitlarda samarali bo‘lsa-da, o‘smaning shakli va intensivligi turlicha bo‘lgan murakkab MRT tasvirlarida universal natija berishi qiyin.



2-rasm. Miya MRT tasvirida patologik hududni segmentatsiya qilishning sxematik ko‘rinishi.

Chuqur o‘rganish usullari bu muammoni tasvirdan belgilarni avtomatik ajratib olish orqali hal qilishga intiladi. Konvolyutsion neyron tarmoqlar tasvirning dastlabki qatlamlarida chegaralar va oddiy teksturalarni, keyingi qatlamlarda esa murakkab shakl va strukturaviy bog‘lanishlarni o‘rganadi. Natijada model o‘smani faqat bitta piksel intensivligi bilan emas, balki uning atrofidagi anatomik kontekst bilan birgalikda baholaydi.

Segmentatsiya uchun U-Net arxitekturasi amaliy jihatdan qulay yechimlardan biridir. Uning kodlovchi qismi tasvirdan yuqori darajadagi

ISSN 3030-3907

xususiyatlarni ajratadi, dekodlovchi qismi esa ushbu ma’lumotlarni fazoviy aniqlikni saqlagan holda tasvir o‘lchamiga qaytaradi. Skip-connection mexanizmi pastki qatlamlardagi mayda detallarni yuqori qatlamlardagi semantik ma’lumot bilan birlashtirish imkonini beradi. Shu sababli U-Net va uning modifikatsiyalari tibbiy tasvir segmentatsiyasida keng qo‘llanadi.

4. Taklif etilayotgan avtomatik diagnostika algoritmi

Miya o‘smalarini avtomatik diagnostika qilish uchun taklif etilayotgan algoritmni shartli ravishda besh bosqichga ajratish mumkin: ma’lumotni qabul qilish, oldindan qayta ishlash, o‘smani segmentatsiya qilish, xususiyatlarni aniqlash va yakuniy tasniflash. Tizimga MRT tasviri kiritilgandan so‘ng u yagona formatga keltiriladi va normalizatsiya qilinadi. Keyingi bosqichda segmentatsiya modeli o‘sma mavjud bo‘lgan hududni ajratadi. Ajratilgan hududdan geometrik, teksturaviy va chuqur o‘rganilgan xususiyatlar olinadi.

Algoritmning umumiy mantiqiy ketma-ketligi quyidagicha ifodalanadi: MRT → oldindan qayta ishlash → segmentatsiya → xususiyatlarni ajratish → tasniflash → diagnostik hisobot. Segmentatsiya natijasida o‘smaning taxminiy hajmi, yuzasi, shakli va joylashuvi aniqlanishi mumkin. Tasniflash bosqichida esa model o‘qitish ma’lumotlarida mavjud bo‘lgan sinflar bo‘yicha ehtimollik qiymatlarini shakllantiradi.

Modelni o‘qitishda ma’lumotlar odatda o‘quv, validatsiya va test qismlariga ajratiladi. Bunda bir bemorga tegishli tasvirlarning turli qismlarga aralashib ketishiga yo‘l qo‘ymaslik zarur. Aks holda model bir bemorning o‘ziga xos tasvir xususiyatlarini yodlab olishi va test natijalari sun’iy ravishda yuqori ko‘rinishi mumkin. Shu bois bo‘linish bemor darajasida amalga oshirilishi maqsadga muvofiq.

2-jadval.

Ma’lumotlar to‘plamini o‘qitish, validatsiya va test guruhlariga taqsimlash.

To‘plam	Vazifasi	Tavsiya etiladigan ulush
O‘quv	Model parametrlarini o‘rganish	70–80 %
Validatsiya	Giperparametrlarni tanlash	10–15 %
Test	Yakuniy mustaqil baholash	10–15 %

5. Chuqur o‘rganish va model arxitekturasini tanlash

Diagnostik modelni tanlashda aniqlik bilan bir qatorda hisoblash murakkabligi, o‘qitish uchun zarur ma’lumot hajmi va modelning klinik sharoitda

ISSN 3030-3907

ishlash tezligi ham hisobga olinadi. ResNet, DenseNet, EfficientNet kabi konvolyutsion arxitekturalar tasniflash vazifalarida qo‘llanishi mumkin. Segmentatsiya uchun U-Net, Attention U-Net yoki 3D U-Net kabi arxitekturalar mos keladi. Agar uch o‘lchamli hajmiy MRT ma’lumotlari mavjud bo‘lsa, 3D konvolyutsiyalar anatomik bog‘lanishlarni to‘liqroq ifodalashi mumkin.

Transfer learning ma’lumotlar hajmi cheklangan vaziyatlarda foydali bo‘lishi mumkin. Bunda avval katta hajmdagi tasvirlar ustida o‘qitilgan modelning dastlabki qatlamlari yangi vazifaga moslashtiriladi. Biroq tabiiy tasvirlar bilan tibbiy MRT tasvirlari o‘rtasidagi farqni hisobga olish kerak. Modelning barcha qatlamlarini o‘zgartirmasdan qo‘llash har doim ham optimal natija bermaydi; shu sababli fine-tuning bosqichi zarur bo‘lishi mumkin.

Segmentatsiya modelining yo‘qotish funksiyasi ham muhim. O‘sma hududi butun miya tasviriga nisbatan kichik bo‘lishi mumkinligi sababli oddiy piksel aniqligiga asoslangan yo‘qotish funksiyasi yetarli bo‘lmasligi mumkin. Dice loss, focal loss yoki ularning kombinatsiyasi kichik va nomutanosib hududlarni o‘rganishda ma’qul natija berishi mumkin. Tasniflashda esa cross-entropy asosidagi yo‘qotish funksiyasi keng tarqalgan.

3-jadval.

Avtomatik diagnostika modelini baholashning asosiy mezonlari.

Ko‘rsatkich	**Mazmuni**	**Qo‘llanish sohasi**
Dice	Prediksiya va haqiqiy niqob ustma-ust tushishi	Segmentatsiya
IoU	Kesishmaning birlashmaga nisbati	Segmentatsiya
Sezgirlik	Kasallikni to‘g‘ri aniqlash darajasi	Tasniflash
Spetsifiklik	Sog‘lom holatni to‘g‘ri ajratish	Tasniflash
F1-mezon	Precision va recall muvozanati	Tasniflash

6. Modelni baholash mezonlari

Avtomatik diagnostika tizimini baholashda faqat umumiy aniqlik ko‘rsatkichiga tayanish noto‘g‘ri xulosalarga olib kelishi mumkin. Tasniflash uchun aniqlik, sezgirlik, spetsifiklik, precision, F1-mezon va ROC-AUC kabi ko‘rsatkichlardan foydalaniladi. Sezgirlik kasallikka ega bemorlarni to‘g‘ri aniqlash qobiliyatini, spetsifiklik esa sog‘lom holatlarni noto‘g‘ri patologik deb belgilamaslik qobiliyatini tavsiflaydi.

ISSN 3030-3907

Segmentatsiya sifatini baholashda Dice Similarity Coefficient va Intersection over Union ko‘rsatkichlari keng qo‘llanadi. Dice ko‘rsatkichi model ajratgan hudud bilan ekspert belgilagan hudud o‘rtasidagi ustma-ust tushish darajasini ifodalaydi. Shu bilan birga, klinik nuqtayi nazardan o‘sma chegarasidagi kichik xatolar ham ahamiyatli bo‘lishi mumkin. Shuning uchun statistik ko‘rsatkichlardan tashqari chegaraviy xatolik, hajmni baholash xatosi va klinik ekspert xulosasi bilan moslik ham o‘rganilishi kerak.

Modelning ishonchliligini tekshirish uchun mustaqil test to‘plamidan foydalanish va imkon qadar boshqa tibbiy markazdan olingan tashqi ma’lumotlarda sinov o‘tkazish muhimdir. Tashqi validatsiya modelning real klinik muhitga qanchalik yaxshi ko‘chishini baholash imkonini beradi.

7. Algoritmning ishonchliligi va interpretatsiyasi

Tibbiy sun’iy intellekt tizimining asosiy talablaridan biri uning qarorini tushuntirish imkoniyatidir. Shifokor faqat yakuniy ehtimollik qiymatini emas, balki model qaysi hududga asoslanib qaror chiqarganini ham ko‘rishi maqsadga muvofiq. Shu nuqtayi nazardan Grad-CAM kabi vizualizatsiya usullari tasniflash modelining e’tibor qaratgan hududlarini ko‘rsatishga yordam beradi. Segmentatsiya modelida esa o‘sma niqobi bevosita MRT tasviri ustiga qo‘yilib, natija shifokor tomonidan tekshirilishi mumkin.

Interpretatsiya mexanizmi modelning xatolarini aniqlashda ham muhim. Agar tizim o‘sma mavjudligini anatomik jihatdan noto‘g‘ri hududga asoslanib bashorat qilsa, bunday natija klinik foydalanish uchun xavfli bo‘lishi mumkin. Shu sababli model ishlab chiqish jarayonida faqat yuqori metrikaga erishish emas, balki qaror qabul qilish mexanizmining mantiqiyligini tekshirish ham talab etiladi.

Bundan tashqari, ma’lumotlar to‘plamidagi yashirin og‘ishlar model natijasiga ta’sir qilishi mumkin. Skaner ishlab chiqaruvchisi, tasvir protokoli, bemorning yoshi yoki tasvirni olish markazi kabi omillar model tomonidan kasallik belgisi sifatida noto‘g‘ri o‘zlashtirilishi ehtimoldan xoli emas. Bunday holatlarni aniqlash uchun modelni turli guruhlar va turli sharoitlarda sinash zarur.

8. Amaliy tizimning dasturiy arxitekturasi

Amaliy avtomatik diagnostika tizimi bir nechta funksional modullardan tashkil topishi mumkin. Birinchi modul MRT ma’lumotlarini qabul qiladi va DICOM yoki boshqa standart formatdagi tasvirlarni qayta ishlashga tayyorlaydi. Ikkinchi modul oldindan qayta ishlash va normalizatsiyani amalga oshiradi. Uchinchi modul segmentatsiya neyron tarmog‘i yordamida patologik hududni aniqlaydi. To‘rtinchi modul tasniflash modelini ishga tushiradi va ehtimollik natijalarini shakllantiradi. Yakuniy modul natijalarni shifokor uchun tushunarli ko‘rinishda taqdim etadi.

ISSN 3030-3907

Dasturiy jihatdan Python ekotizimi, PyTorch yoki TensorFlow kabi chuqur o‘rganish kutubxonalari, OpenCV va tibbiy tasvirlarni qayta ishlash vositalari bilan integratsiya qilinishi mumkin. Modelni ishlab chiqish bosqichida GPU hisoblash resurslaridan foydalanish o‘qitish vaqtini sezilarli qisqartiradi. Klinik tizimga joriy etishda esa modelning inferensiya tezligi, xotira talabi va server infratuzilmasi bilan mosligi hisobga olinadi.

Tizim interfeysida original MRT tasviri, segmentatsiya niqobi, tasniflash natijasi va model ishonchlilik ko‘rsatkichlarini bir oynada ko‘rsatish qulaydir. Bunday yondashuv shifokorga avtomatik natijani mustaqil tasvir bilan taqqoslash imkonini beradi. Tizim yakuniy tashxisni mustaqil qo‘yuvchi vosita emas, balki klinik qarorni qo‘llab-quvvatlovchi axborot tizimi sifatida loyihalanishi lozim.

9. Tajriba metodologiyasi va kutilayotgan natijalar

Tadqiqotning tajriba qismida MRT ma’lumotlar to‘plami tanlanib, dastlab tasvirlarning texnik sifati va belgilashlar izchilligi tekshiriladi. Keyin ma’lumotlar bemorlar bo‘yicha o‘quv, validatsiya va test guruhlariga ajratiladi. Segmentatsiya modeli o‘qitilib, Dice va IoU ko‘rsatkichlari bo‘yicha baholanadi. Segmentatsiyadan olingan hududlar keyingi tasniflash bosqichiga uzatiladi.

Kutilayotgan natija sifatida avtomatik tizim MRT tasvirida miya o‘smasi mavjudligini yuqori sezgirlik bilan aniqlashi, o‘sma hududining chegaralarini ekspert belgilashlariga yaqin tarzda ajratishi va mavjud sinflar bo‘yicha barqaror tasniflash natijalarini berishi ko‘zda tutiladi. Bunda aniq sonli natijalar ma’lumotlar to‘plami, tasvir sifati, model arxitekturasi va o‘qitish parametrlariga bog‘liq bo‘ladi. Shu sababli tajriba o‘tkazmasdan turib ma’lum bir aniqlik foizini kafolatlash ilmiy jihatdan asosli emas.

Modelni takomillashtirishning istiqbolli yo‘nalishlaridan biri multimodal MRT ma’lumotlarini birgalikda tahlil qilishdir. T1, T2 va FLAIR kabi ketma-ketliklar bir-birini to‘ldiradi. Yana bir yo‘nalish — 3D modellar yordamida butun hajmiy tasvirni tahlil qilish. Bunday model ko‘proq hisoblash resurslarini talab qilsa-da, o‘smaning fazoviy tuzilishini yaxshiroq ifodalashi mumkin.

10. Klinik qo‘llash, cheklovlar va xavfsizlik masalalari

Sun’iy intellekt asosidagi diagnostika tizimini klinik amaliyotga joriy qilish faqat texnik jihatdan yaxshi ishlaydigan model yaratish bilan tugamaydi. Tizim mustaqil klinik validatsiyadan o‘tishi, turli bemor guruhlarida tekshirilishi va shifokor ish jarayoniga qanday ta’sir ko‘rsatishi baholanishi kerak. Ayniqsa, noto‘g‘ri manfiy natija o‘smani aniqlamay qolishga, noto‘g‘ri musbat natija esa keraksiz qo‘shimcha tekshiruvlarga olib kelishi mumkin.

Modelning asosiy cheklovlaridan biri ma’lumotlar hajmi va sifatiga bog‘liqligidir. Kam sonli yoki bir xil markazdan olingan tasvirlarda o‘qitilgan model boshqa klinik sharoitlarda kutilgan darajada ishlamasligi mumkin.

ISSN 3030-3907

Shuningdek, ayrim o‘sma turlari uchun yetarli miqdorda belgilangan ma’lumot mavjud emasligi sinflar nomutanosibligini yuzaga keltiradi. Bu muammoni qayta namunalash, og‘irliklarni moslashtirish yoki maxsus yo‘qotish funksiyalari orqali kamaytirish mumkin.

Bemor ma’lumotlarining maxfiyligi ham alohida ahamiyatga ega. MRT tasvirlari bilan ishlashda shaxsni aniqlovchi ma’lumotlarni himoyalash, ma’lumotlarni xavfsiz saqlash va ulardan foydalanish huquqini nazorat qilish talab etiladi. Klinik tizimga integratsiya qilinadigan modelning har bir qarori audit qilinishi va zarur holatda inson tomonidan tekshirilishi lozim.

11. Natijalarni muhokama qilish

Tahlil shuni ko‘rsatadiki, miya o‘smalarini avtomatik diagnostika qilishda eng maqbul strategiya tasvirni oddiy klassifikatsiya qilish bilan cheklanib qolmasdan, o‘sma hududini segmentatsiya qilish va keyin tasniflashni birlashtirishdan iborat. Segmentatsiya natijasi diagnostik model uchun qo‘shimcha fazoviy axborot beradi. Shu bilan birga, noto‘g‘ri segmentatsiya keyingi bosqichga xatoni uzatishi mumkin. Demak, butun tizimning ishlash sifati uning alohida modullaridan eng zaif bo‘lgan qismiga sezilarli darajada bog‘liq.

An’anaviy kompyuter ko‘rish usullari tushunarli va hisoblash jihatidan nisbatan sodda bo‘lsa-da, ular patologik o‘zgarishlarning xilma-xilligini to‘liq ifodalashda cheklanishi mumkin. Chuqur o‘rganish esa murakkab belgilarni avtomatik o‘zlashtirish imkonini beradi, biroq ko‘proq ma’lumot, hisoblash resurslari va ehtiyotkor validatsiyani talab qiladi. Shu sababli amaliy tizimda klassik tasvir qayta ishlash bosqichlari va chuqur neyron tarmoqlarni bir-birini to‘ldiruvchi usul sifatida qo‘llash maqsadga muvofiq.

Yana bir muhim masala — model natijasini klinik qaror bilan aralashtirib yubormaslikdir. Sun’iy intellekt tasvir asosida ehtimoliy natija beradi, yakuniy tashxis esa bemorning klinik holati, boshqa tekshiruvlar va mutaxassis xulosasi bilan birgalikda belgilanadi. Shu nuqtayi nazardan AI tizimining eng katta amaliy qiymati radiologga takroriy ishlarni kamaytirish, shubhali tasvirlarni ustuvorlashtirish va o‘sma chegaralarini baholashda yordam berishdan iborat.

XULOSA.

Miya o‘smalarini avtomatik diagnostika qilishda sun’iy intellekt va kompyuter ko‘rish texnologiyalaridan foydalanish tibbiy tasvirlarni tahlil qilish samaradorligini oshirish uchun istiqbolli yo‘nalish hisoblanadi. MRT tasvirlarini oldindan qayta ishlash, o‘sma hududini segmentatsiya qilish, chuqur xususiyatlarni ajratish va yakuniy tasniflashni yagona algoritmik zanjirga birlashtirish orqali shifokor ishini qo‘llab-quvvatlovchi tizim yaratish mumkin.

Tadqiqotda ko‘rib chiqilgan yondashuvning asosiy ustunligi o‘sma shakli va tuzilishidagi murakkab farqlarni avtomatik o‘rganish imkoniyatidir. Shu bilan

ISSN 3030-3907

birga, modelning haqiqiy klinik qiymatini aniqlash uchun mustaqil va tashqi validatsiya, ma'lumotlar sifati, interpretatsiya, maxfiylik va xavfsizlik masalalariga alohida e'tibor berish zarur. Kelgusida multimodal va 3D MRT ma'lumotlaridan foydalanish, ko'p vazifali modellarni ishlab chiqish, model izohlanishini kuchaytirish hamda turli klinik markazlarda sinovdan o'tkazish ushbu yo'nalishning samaradorligini yanada oshirishi mumkin.

Shunday qilib, sun'iy intellekt asosidagi avtomatik diagnostika tizimi shifokorni almashtirish vositasi sifatida emas, balki klinik qaror qabul qilishni qo'llab-quvvatlovchi texnologik vosita sifatida qaralishi kerak. To'g'ri tashkil etilgan ma'lumotlar bazasi, ilmiy asoslangan model tanlovi va qat'iy validatsiya bilan bunday tizimlar miya o'smalarini aniqlash va baholash jarayonida amaliy ahamiyatga ega bo'lishi mumkin.

FOYDALANILGAN ADABIYOTLAR

1. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. Medical Image Computing and Computer-Assisted Intervention (MICCAI), 2015.
2. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016.
3. Litjens G., Kooi T., Bejnordi B.E. et al. A Survey on Deep Learning in Medical Image Analysis. Medical Image Analysis, 2017.
4. Menze B.H., Jakab A., Bauer S. et al. The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS). IEEE Transactions on Medical Imaging, 2015.
5. Isensee F., Jaeger P.F., Kohl S.A.A., Petersen J., Maier-Hein K.H. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. Nature Methods, 2021.
6. LeCun Y., Bengio Y., Hinton G. Deep learning. Nature, 2015.
7. Esteva A., Robicquet A., Ramsundar B. et al. A guide to deep learning in healthcare. Nature Medicine, 2019.
8. Goodfellow I., Bengio Y., Courville A. Deep Learning. MIT Press, 2016.
9. Litjens G. et al. Deep learning as a tool for increased accuracy and efficiency of histopathological diagnosis. Scientific Reports, 2016.
10. Lundervold A.S., Lundervold A. An overview of deep learning in medical imaging focusing on MRI. Zeitschrift für Medizinische Physik, 2019.

ISSN 3030-3907