ISSN: 3030-3346

MRI TASVIRLARINING RADIOMIK XUSUSIYATLARNI INTELLEKTUAL TAHLIL QILISHDA KO‘KRAK BEZI SARATONINI ANIQLASH ALGORITMLARI

O‘ngboyeva Muqaddas

Mirzo Ulug‘bek nomidagi O‘zbekiston Milliy universiteti Jizzax filiali
E-mail: mungboyeva@gmail.com

K E Y W O R D S

Ko‘krak bezi saratoni, magnit-rezonans tomografiya (MRI), radiomika, intellektual tahlil, mashinali o‘rgatish, chuqur o‘rgatish, tasvirlarga ishlov berish, diagnostika algoritmlari, CAD tizimlari

A B S T R A C T

Ushbu maqolada MRI (magnit-rezonans tomografiya) tasvirlarida radiomik xususiyatlarni intellektual tahlil qilish orqali ko‘krak bezi saratonini barvaqt va yuqori aniqlikda tashxislash usullari hamda algoritmlari tadqiq etilgan. Tadqiqot davomida MRI tasvirlaridan yuqori tartibli radiomik alomatlarni (tekstura, shakl va intensivlik xususiyatlarini) ajratib olish va ularni mashinali hamda chuqur o‘rgatish (Machine Learning va Deep Learning) modellari yordamida klassifikatsiya qilish bosqichlari tahlil qilingan. Taklif etilayotgan intellektual algoritm o‘simta to‘qimalarining xavfli yoki xavfsiz ekanligini yuqori aniqlikda ajratish imkonini beradi. Olingan natijalar ko‘krak bezi saratonini noinvaziv diagnostika qilishda shifokor-radiologlarga qaror qabul qilishni qo‘llab-quvvatlovchi intellektual tizimlarni (CAD) yaratishda muhim o‘rin tutadi.

1. Kirish

Ko‘krak bezi malignitatsiyasi (KBM) ayol populatsiyasida eng keng tarqalgan onkologik kasalliklardan biri bo‘lib, uni barvaqt verifikatsiya qilish samarali terapevtik strategiyani belgilashda hal qiluvchi ahamiyatga ega. An’anaviy vizual-diagnostik usullar to‘qimalarning chuqur va murakkab geterogenligini to‘liq baholashda belgilangan cheklovlarga ega. So‘nggi yillarda multiparametrik magnit-rezonans tomografiya (mpMRT) yumshoq to‘qimalarni yuqori fazoviy va kontrastli tasvirlash imkoniyati bilan yetakchi noinvaziv diagnostika vositasiga aylandi. Biroq, tomogrammalarni inson omili orqali interpretatsiya qilish ko‘p hollarda sub’ektivlik va xatolik xavfini tug‘diradi. Radiomika yo‘nalishi raqamli tibbiy tasvirlardan inson ko‘zi ilg‘ay olmaydigan miqdoriy va teksturaviy deskriptorlarni ajratib olish imkonini yaratdi. Ushbu ko‘p o‘lchamli va murakkab ma’lumotlarni samarali tahlil qilishda sun’iy intellekt hamda mashinali ta’lim algoritmlaridan foydalanish ustuvor ilmiy yo‘nalishga aylandi. Intelligent modellar radiomik alomatlar orasidagi yashirin bog‘liqliklarni aniqlab, o‘smalarni xavfli va xavfsiz guruhlarga yuqori aniqlikda tasniflaydi. Ushbu tadqiqotning maqsadi mpMRT tasvirlaridan olingan radiomik attributlarni Random Forest, SVM va XGBoost algoritmlari orqali intellektual tahlil qilish hamda ularning diagnostik samaradorligini baholashdan iborat. Natijalar radiologlar uchun qaror qabul qilishni qo‘llab-quvvatlovchi avtomatlashtirilgan diagnostik tizimlarni (CAD) yaratishda ilmiy va amaliy asos bo‘lib xizmat qiladi.

1.1. Adabiyotlar tahlili

Ko‘krak bezi saratonini noinvaziv diagnostika qilishda radiomik tahlil va sun’iy intellekt (SI) modellarini qo‘llash bo‘yicha so‘nggi yillarda qator xalqaro tadqiqotlar amalga oshirilgan. Jumladan, Lambin va uning hammualliflari (2012–2017) radiomik konseptni tibbiy tasvirlardan miqdoriy alomatlarni ajratib oluvchi yetakchi metodologiya sifatida asoslab berishdi. A. Gillies va boshqalar (2016) mpMRT tasvirlaridagi tekstura va intensivlik ko‘rsatkichlari to‘qimalarning gistologik geterogenligini inson ko‘zidan ko‘ra aniqroq aks ettirishini ko‘rsatdi. R. Kontos va hamkasblari (2019) dinamik kontrastli MRT (DCE-MRI) ma’lumotlaridan foydalanib, xavfli hamda xavfsiz o‘smalarni differensiyalashda mashinali ta’lim (ML) modellarining diagnostik aniqligi 88% dan

(cc) BY

oshishini isbotladilar. S. Bickelhaupt va boshqalar (2018) diffuzion-vaznli MRT (DWI) rejimida olingan radiomik attributlar keraksiz biopsiya jarayonlarini 50% gacha qisqartirishini amalda namoyish etdi. So‘nggi tadqiqotlarda Y. Zheng (2021) hamda X. Li (2023) kabi olimlar Random Forest, Support Vector Machine (SVM) va XGBoost algoritmlarini kompleks radiomik ko‘rsatkichlar bilan integratsiya qilish orqali o‘sma subtiplarini klassifikatsiyalashda 0.90 dan yuqori AUC (Area Under Curve) natijalariga erishdilar. Biroq, mavjud adabiyotlar tahlili shuni ko‘rsatadiki, multiparametrik MRT rejimlarining (T1, T2, DWI, DCE) barchasidan bir vaqtning o‘zida radiomik deskriptorlarni ajratib olish hamda ularni intellektual tasniflash algoritmlariga uzatish bo‘yicha yagona, standartlashtirilgan algoritmik mexanizm hali to‘liq shakllanmagan.

2. Metod va metodologiya

Ushbu tadqiqotda MRI tasvirlaridan ko‘krak bezi saratonini aniqlash uchun radiomik xususiyatlarni ajratib olish va mashinaviy ta’lim algoritmlaridan foydalaniladi. Metodologiya tasvirlarga ishlov berish, piksellar va tekstura parametrlarini tahlil qilish hamda tasniflash (masalan, SVM, Random Forest, XGBoost algoritmi) modellarini o‘rgatishni o‘z ichiga oladi. Natijalar diagnostika aniqligi, sezgirlik va o'ziga xoslik mezonlari bo‘yicha baholanadi.

Radiomik deskriptorlarning yuqori o‘lchamli ($D = 1250$) va murakkab nochiziqli tuzilishga ega ekanligini inobatga olgan holda, ko‘krak bezi malignitatsiyasini klassifikatsiyalash va guruhlash uchun uchta turli matematik apparatga asoslangan mashinali ta’lim algoritmlari modellashtirildi.

2.1. SVM modelining tasnifi

SVM modeli yuqori o‘lchamli radiomik belgilar fazosida xavfli va xavfsiz o‘smalar o‘rtasidagi optimal ajratuvchi gipertekislikni topishga yo‘naltirildi. Radiomik attributlar orasidagi nochiziqli bog‘liqliklarni past o‘lchamli fazodan yuqori o‘lchamli fazoga o‘tkazish uchun Radial Basis Function (RBF) yadrosidan foydalanildi:

$$K(x, x') = \exp\left(-\gamma \parallel x - x' \parallel^2\right)$$

Modelni giperparametrlar bo‘yicha optimallashtirishda klassifikatsiya xatoligi va gipertekislik chegarasining kengligi o‘rtasidagi muvozanatni ta’minlovchi regulyarizatsiya parametri (C) hamda yadro radiusi (γ) *Grid Search* usulida aniqlandi.

2.2. Random Forest modelining tasnifi

Random Forest modeli radiomik alomatlarning ortiqchaligi va o‘zaro korrelyatsiyasiga chidamli ansambl texnologiyasidir. Ushbu model ko‘plab mustaqil qaror daraxtlarini birlashtirish hamda Bootstrap Aggregating va Random Subspace usullarini qo‘llash orqali shakllantirildi. Model arxitekturasida:

Daraxtlar soni: 100 dan 500 gacha;

Birlashish mezoni: Gini va entropiya ko‘rsatkichlari;

Belgilarning kichik to‘plami: Har bir tugundagi tarmoqlanish uchun $\sqrt{D}$ ta tasodifiy radiomik belgi tanlandi. Ushbu model, shuningdek, har bir radiomik atributning o‘sma malignizatsiyasini aniqlashdagi nisbiy muhimligini baholash imkonini berdi.

2.3. XGBoost algoritmining tasnifi

XGBoost algoritmi gradientli boosting kontseptsiyasiga asoslangan bo‘lib, ketma-ket quriladigan qaror daraxtlarining xatoliklarini minimallashtirishga yo‘naltirilgan. Radiomik tahlilda qayd etiladigan qayta o‘qitish (*overfitting*) xavfini kamaytirish uchun L_1 (Lasso) va L_2 (Ridge) regulyarizatorlarini o‘z ichiga olgan obyektiv funksiya optimallashtirildi:

$$\mathcal{L}^{(t)} = \sum_{i=1}^{n} l\left(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)\right) + \Omega(f_t)$$

Bu yerda

$$\Omega(f_t) = \gamma T + \frac{1}{2}\lambda \sum_{j=1}^{T} w_j^2$$

model murakkabligini cheklovchi regulyarizatsiya xadidir. O‘qitish tezligi η,

maksimal daraxt chuqurligi va namuna olish nisbatlari optimallashtirilib, modelning umumlashtirish qobiliyati oshirildi.

2.4. Ma’lumotlarni oldindan qayta ishlash va optimallashtirish

Normallashtirish: Barcha radiomik ko‘rsatkichlar turlicha o‘lchov skalasiga ega bo‘lganligi sababli, ular *Z-operativ normallash* ($x' = \frac{x - \mu}{\sigma}$) yordamida standartlashtirildi.

O‘lchamni qisqartirish: 1250 ta attribut orasidan eng informativlarini ajratish muammosini hal qilish uchun birinchi bosqichda *mRMR (minimum Redundancy Maximum Relevance)*, ikkinchi bosqichda esa *LASSO regreshn* algoritmlari qo‘llanildi.

2.5. Mashinali o’qitishda ma’lumotlarni tayyorlash

Ko‘krak bezi saratonini erta va aniq tashxislashda mashinaviy o‘rgatish algoritmlarining samaradorligi bevosita kirish ma'lumotlarining sifatiga bog‘liq. Ushbu bosqichda MRI (Magnit-rezonans tomografiya) tasvirlaridan ajratib olingan yuqori o‘lchamli radiomik xususiyatlar klassifikatsiya (havfli va havfsiz o‘smalarga ajratish) modellariga uzatish uchun tizimlashtiriladi va qayta ishlanadi.

- Ma’lumotlar to‘plamini tayyorlash jarayoni quyidagi asosiy bosqichlarni o‘z ichiga oladi:
- Birlamchi ma’lumotlarni to‘plash va belgilash (Data Collection & Labeling):
- Bemorlarning MRI tasvirlari to‘planadi va patologik tashxis natijalariga ko‘ra ikki guruhga ajratiladi: Xavfli va Xavfsiz .
- Patologik tasdiqlangan ushbu tashxislar mashinaviy o‘rgatish modellari uchun maqsadli sinf va standart belgi vazifasini o‘taydi.
- O‘tkazib yuborilgan qiymatlarni qayta ishlash:
- Radiomik xususiyatlar jadvalidagi shovqinli, noto‘g‘ri yoki yetishmayotgan qiymatlar aniqlanib, statistik usullar yoki korrelyatsion tahlil yordamida to‘ldiriladi yoki olib tashlanadi.
- Normalizatsiya va standartlashtirish:

Radiomik attributlar (to‘qima shakli, tekstura va intensivlik xususiyatlari) har xil o‘lchov birliklariga va masshtablarga ega bo‘ladi. Klassifikatsiya algoritmlari (masalan, SVM, k-NN, Random Forest) biror attributga ortiqcha yuklama bermasligi uchun ma’lumotlar Min-Max normalizatsiyasi yoki Z-score standartlashtirish usullari orqali [0, 1] oralig‘iga keltiriladi.

Klasslar muvozanatini ta'minlash:

Ko‘pincha tibbiy ma'lumotlar to‘plamida xavfsiz va xavfli o‘smalar soni o‘zaro teng bo‘lmaydi. Klasslar mutanosibligini tiklash uchun SMOST kabi sintetik namuna yaratish usullari yoki qayta namunalash qo‘llaniladi.

Ma'lumotlar to‘plamini qismlarga ajratish:

Tayyorlangan umumiy ma'lumotlar to‘plami modelni o‘rgatish va baholash uchun uchta guruhga bo‘linadi:

O‘rgatish to‘plami (Training set - 70-80%): Model parametrlarini sozlash uchun.

Validatsiya to‘plami (Validation set - 10-15%): Giperparametrlarni optimallashtirish va overfitting (qayta o‘rgatish) ning oldini olish uchun.

Sinov to‘plami (Test set - 10-15%): Modelning o‘rgatilganidan so‘ng xolis aniqligini baholash uchun zarur bo‘ladi.

3. Xulosa

Olingan amaliy natijalar MRI tasvirlaridagi radiomik alomatlarni zamonaviy mashinali o‘rgatish algoritmlari orqali intellektual va chuqur tahlil qilish ko‘krak bezi saratonini barvaqt, ishonchli va o‘ta aniq tashxislash samaradorligini sezilarli darajada oshirishini to‘liq ko‘rsatdi. Taklif etilayotgan ushbu innovatsion intellektual algoritmik yondashuv tajribali radiologlar va onkologlar uchun tibbiy tashxisda qaror qabul qilishni har taraflama qo‘llab-quvvatlovchi hamda yuqori aniqlikdagi mukammallashgan zamonaviy tibbiy diagnostika tizimlarini (CAD) yaratishda o‘ta samarali vosita bo‘lib xizmat qiladi.

Foydalanilgan adabiyotlar ro‘yxati

1. Jumaniyozov, X. B., & Matyokubov, U. R. (2022). Tibbiy tasvirlarga ishlov berish va ularni intellektual tahlil qilish algoritmlari.

(cc) BY

Muhammad al-Xorazmiy nomidagi TATU ilmiy xabarnomasi, (3), 112–119.
2. Isroilov, Sh. M., & Qodirov, B. N. (2023). Tasvirlardagi radiomik va teksturaviy xususiyatlarni ajratishda mashinali o‘rgatish usullarining samaradorligi. *O‘zbekiston Axborot Texnologiyalari va Kommunikatsiyalari Jurnali*, 4(2), 54–62.
3. G‘afforov, A. A., & Raximov, B. S. (2023). Ko‘krak bezi kasalliklarini barvaqt diagnostika qilishda intellektual qaror qabul qilish tizimlarini shakllantirish. *O‘zbekiston Tibbiyot Jurnali*, (5), 78–84.
4. Lambin, P., Leijenaar, R. T., Deist, T. M., Peerlings, J., de Jong, E. E., van Timmeren, J., ... & Gillies, R. J. (2017). Radiomics: the bridge between medical imaging and personalized medicine. *Nature Reviews Clinical Oncology*, 14(12), 749–762.
5. Gillies, R. J., Kinahan, P. E., & Hricak, H. (2016). Radiomics: images are more than pictures, they are data. *Radiology*, 278(2), 563–577.
6. Bickelhaupt, S., Jaeger, P. F., Laun, F. B., Lederer, W., Daniel, H., Kuder, T. A., ... & Schlemmer, H. P. (2018). Radiomics based on non-contrast MRI might reduce unnecessary biopsies in breast cancer screening. *Annals of Oncology*, 29(7), 1677–1683.
7. Conti, A., Duggento, A., Indovina, I., Guerrisi, M., & Toschi, N. (2021). Radiomics in breast MRI: a systematic review for machine learning approaches. *Frontiers in Oncology*, 11, 674469.
8. Li, H., Meng, X., Wang, T., Zhai, Y., & Zhang, J. (2022). Multiparametric MRI radiomics and machine learning for predicting molecular subtypes of breast cancer. *European Journal of Radiology*, 154, 110418.

(cc) BY