

Tibbi Təsvidlər Əsasında Xəstəliklərin Proqnozlaşdırılması üçün Dərin Təlim Metodları

Filman Sadıqov

ETN İnformasiya Texnologiyaları İnstitutu, Bakı, Azərbaycan
sadigovfilman@gmail.com

Xülasə — Tibbi görüntülmə xəstəliklərin erkən aşkarlanması və diaqnostikasında mühüm əhəmiyyət daşıyır. Dərin öyrənmənin inkişafı nəticəsində 2D və 3D görüntüləri yüksək dəqiqliklə analiz edən modellər yaradılmışdır. Bu məqalədə rentgen, kompüter tomoqrafiyası, maqnit-rezonans tomoqrafiyası, ultrasəs və digər modallarda istifadə olunan metodlar, lezyon aşkarlanması, təsnifat və seqmentasiya üçün tətbiq olunan dərin öyrənmə arxitekturaları araşdırılır. Modellər tez-tez ekspert səviyyəsində nəticələr göstərir. Eyni zamanda, məlumat azlığı və izah edilə bilməlik kimi problemlər qeyd olunur. Gələcəkdə izah edilə bilən süni intellekt və multimodal integrasiyanın mühüm rol oynayacağı əsaslandırılır.

Açar sözlər — dərin öyrənmə, tibbi görüntülmə, xəstəliklərin proqnozlaşdırılması, süni intellekt, təsvirlərin analizi, seqmentasiya.

I. GİRİŞ

Tibbi görüntülmə müasir səhiyyədə əvəzolunmaz bir alətə çevrilmişdir. Bu texnologiya daxili orqanların invaziv olmayan üsullarla vizualizasiyasını təmin edərək diaqnostika və müalicə planlaşdırılmasında mühüm rol oynayır. Tibbi görüntülmə məlumatlarının həcmi sürətlə artır — məsələn, Ümumdünya Səhiyyə Təşkilatının (ÜST) məlumatına görə, hər il dünyada təxminən 3.6 milyard diaqnostik görüntülmə müayinəsi aparılır [1]. Bura rentgen, ultrasəs, kompüter tomoqrafiyası (KT), maqnit-rezonans tomoqrafiyası (MRT), pozitron emissiya tomoqrafiyası (PET) və digər görüntülmə modalları daxildir. Bu modalların hər biri müxtəlif patologiyalar haqqında unikal məlumatlar təqdim edir. Lakin bu qədər çox sayda görüntünün təhlili çox çətin bir vəzifədir və bir çox bölgələrdə ixtisaslı radioloq və görüntü təhlilçilərinin çatışmazlığı sənədləşdirilmiş reallıqdır. Bu vəziyyət həkimlərə tibbi görüntüləri səmərəli və dəqiq şəkildə analiz etməyə kömək edə biləcək avtomatlaşdırılmış xəstəlik proqnozlaşdırma modellərinin inkişafını stimullaşdırmışdır. Süni intellekt (Sİ), xüsusilə də dərin öyrənmə sahəsindəki nailiyyətlər son onillikdə tibbi görüntülərin analizi sahəsində əsl inqilab yaratmışdır. Əvvəllər istifadə olunan və əl ilə yaradılan xüsusiyyətlərə əsaslanan kompüter dəstəklili diaqnostika sistemlərindən fərqli olaraq, dərin öyrənmə alqoritmləri geniş miqyaslı görüntü kolleksiyalarından mürəkkəb xüsusiyyətləri avtomatik şəkildə öyrənə bilir. Bu qabiliyyət, bir çox hallarda insan mütəxəssislərin nəticələrini bərabərliklə və ya daha yüksək səviyyədə təkrarlamaq üçün “hesablama radiologiyası” sistemlərinin inkişafına səbəb olmuşdur [2]. Dərin konvolusion neyron şəbəkələri (ing. convolutional neural network (CNN)) və onların variantları görüntüyə əsaslanan xəstəlik aşkarlanması üçün ən müasir modellərin əsasını təşkil edir. Bu modellər orqanların

seqmentasiyası, şişlərin aşkarlanması, patoloji təsnifat və digər sahələrdə əla nəticələr göstərmişdir [2]. Bəzi sahələrdə Sİ modelləri artıq həkim səviyyəsində dəqiqliyə yaxınlaşır — məsələn, fundus şəkillərindən diabetik retinopatiyanın aşkarlanması və ya dermoskopik görüntülərdən dəri lezyonlarının təsnifatı kimi vəzifələrdə. Bütün bu uğurlara baxmayaraq, tibbi görüntülərə əsaslanan dayanıqlı xəstəlik proqnozlaşdırma metodlarının hazırlanması hələ də ciddi çətinliklərlə müşayiət olunur. Tibbi görüntülər adətən yüksək ölçülü və heterogen olur (məsələn, 2D boz tonlu rentgen şəkilləri ilə 3D multimodal MRT taramaları arasındakı fərqlər), və mütəxəssis tərəfindən etiketlenməsi vaxt aparan bir proses olduğu üçün anotasiya edilmiş məlumatlar məhdud ola bilər. Bundan əlavə, modellər müxtəlif pasiyent qrupları və görüntülmə cihazları üzrə ümumiləşmə və etibarlılıq baxımından ciddi şəkildə yoxlanmalıdır. Eyni zamanda, bu modellərin izah edilə bilməsi və klinik iş axınına integrasiyası kimi məsələlər də geniş təbiiqdən əvvəl həllini tapmalıdır.


Bu məqalə, xəstəliklərin proqnozlaşdırılması modellərinin müxtəlif xəstəliklər və görüntülmə modalları üzrə inkişafına dair icmal təqdim edir. Burada həm 2D görüntülmə (məsələn, rentgen və ultrasəs) həm də 3D görüntülmə (məsələn, KT, MRT və PET) texnologiyalarına əsaslanan yanaşmalar əhatə olunur. Məqalədə bu görüntülərin pnevmoniya və sınıq kimi ümumi hallar üçün istifadəsindən tutmuş, beyin şişləri və histopatoloji slaydlarda metastazların aşkarlanması kimi daha mürəkkəb diaqnozlara qədər necə istifadə edildiyi ədəbiyyat əsasında ümumiləşdirilir. Fokus əsasən nəzəri və metodoloji aspektlər üzərində qurulmuşdur — burada yeni eksperimental nəticələr təqdim edilmir, əvəzində mövcud modellər və metodlar araşdırılır və müzakirə görüntülmə modalları üzrə strukturlaşdırılır. Növbəti bölmələrdə hər bir görüntülmə növü üzrə müasir modellərin ədəbiyyat icmal təqdim edilir, belə modellərin hazırlanması və qiymətləndirilməsi üçün ümumi metodoloji elementləri təsvir edilir, bu yanaşmaların tətbiqi ilə əldə edilən nəticələrin həm insan-mütəxəssislərlə müqayisəli performansını, həm də sahədə hələ də mövcud olan çətinliklər ümumiləşdirilir.

II. ƏDƏBİYYATIN İCMALI

A. Radiografiyada (Rentgen şəkillərində) Tibbi Görüntülərin Analizi

Şəkil 1-də sətəlcəmli pasiyentlərin döş qəfəsi rentgen görüntüləri və CNN modelinin diqqət xəritələri göstərilir. Burada model sətəlcəmi aşkar etmək üçün öyrədilmiş və proqnoza təsir edən ağciyər sahələrini istilik xəritəsi ilə vizualizə etmişdir [3]. Dərin öyrənmə rentgen görüntüləri,

xüsusilə döş qəfəsi rentgenləri üzərində geniş tətbiq tapmışdır. Stanford-un CheXNet modeli sətəlcəmi yüksək dəqiqliklə aşkarlamış və radioloqlarla müqayisə edilə biləcək nəticələr göstərmişdir [3].




Şəkil 1. Sətəlcəm Üçün Rentgen İstilik Xəritələri

Daha sonra NIH ChestX-ray8 və CheXpert kimi məlumat bazaları modellərin digər patologiyalara da tətbiqini mümkün etmişdir (düyünlər, plevral efüziya, kardiomeqaliya və s.). Bu modellər 71–75% dəqiqliklə işləyərək bəzi hallarda az təcrübəli həkimləri üstələmişdir. AI sistemləri incə patologiyaları aşkar etməklə ikinci oxuyucu kimi çıxış edə bilər. Saliency map-lər kimi izah edilə bilən yanaşmalar həkim etibarını artırır. Rentgen üzərində CNN-lər yalnız ağciyər xəstəlikləri deyil, sınıq, mamografiya lezyon və implant aşkarlanmasında da istifadə olunur. Bu, radioqrafiyanı AI əsaslı proqnozlaşdırma üçün ən əlverişli sahələrdən birinə çevirir.

B. Xəstəliklərin Proqnozlaşdırılması Üçün Kompüter Tomografiyası (KT)

Şəkil 2-dəki KT skanları ağciyər divarına bitişik düyünləri (mümkün erkən mərhələli şişlər) nümayiş etdirir. Bu düyünlərin plevra səthinə yaxın yerləşməsi həm insanlar, həm də alqoritmlər üçün ağciyər sərhədlərinin müəyyənəndirilməsini çətinləşdirir [4].




Şəkil 2. KT skanlarında ağciyər düyünlərinin plevra səthinə bitişməsi

Kompüter tomoqrafiyası (KT) yüksək ayırdetməli anatomik görüntülər təqdim edərək xərçəng və digər daxili patologiyaların aşkarlanmasında effektiv vasitədir. KT-nin detallı təsvir imkanları sayəsində dərin öyrənmə modelləri ağciyər düyünlərinin aşkarlanması və xarakterizasiyası üçün uğurla tətbiq olunur. LUNA16 və LIDC-IDRI məlumat bazalarına əsaslanan 3D CNN və 2D/3D hibrid modellər 90%-dən yüksək həssaslığa nail olmuş, yalan müsbətlərin sayını isə minimuma endirmişdir [4]. Bu yanaşmalar "radiomika" və ya "dərin radiomika" adlanır və düyünlərin xassələrini

qiymətləndirərək xəstəliyin gedişatını proqnozlaşdırmağa bilər. KT-yə əsaslanan süni intellekt modelləri yalnız ağciyər xərçəngi deyil, həm də qaraciyər şişləri, yoğun bağırsaq xərçəngi və ürək-damar patologiyalarında tətbiq olunur. Məsələn, AI modelləri KT görüntülərində bağırsaq divarının qalınlaşmasını və limfa düyünlərini təhlil edərək malignliyi erkən aşkar edə bilər. Ürək KT-də isə lövhəciklərin və kalsifikasiya nümunələrinin təhlili ilə risk proqnozlaşdırması aparılır. KT analizində əsas texniki çətinlik 3D məlumatların həcmli əlaqəlidir. Bunun üçün "patch-based" yanaşmalar və ResBCDU-Net kimi xüsusi modellərdən istifadə olunur [4]. Bu modellər seqmentasiya dəqiqliyini artıraraq, xüsusilə periferik lezyonların gözdən qaçmamasını təmin edir. Nəticə etibarilə, KT-də dərin öyrənmə modelləri aşkarlama, seqmentasiya və xəstəlik proqnozlaşdırılmasında mühüm nailiyyətlər əldə etmişdir. Bəzi alqoritmlər artıq tənzimləyici təsdiqlər də almışdır və bu sahədə irəliləyişlər davam edir.

C. Maqnit-Rezonans Tomografiyası (MRT) və 3D Görüntülmə Modalları

Şəkil 3-də BraTS məlumat bazasına əsaslanan beyin MRT dilimləri və müxtəlif modallarda (T1, T1c, T2, FLAIR) çəkilmiş görüntülər, eləcə də neyro-radioloq tərəfindən aparılmış "ground-truth" şiş seqmentasiyası göstərilir. Seqmentasiya maskaları yaşıl (ödem), qırmızı (kontrastsız nüvə) və sarı (kontrastlı nüvə) rənglərlə kodlaşdırılmışdır [5]. Bu nümunə fərqli kontrastların şişin xüsusiyyətlərini necə vurğuladığını və CNN modellərinin avtomatik seqmentasiya üçün necə öyrədilə biləcəyini nümayiş etdirir.



Şəkil 3. Şişin müxtəlif MRT modallarında seqmentasiyası və anotasiya nümunələri

MRT yüksək yumşaq toxuma kontrastı təqdim edən və beyin şişləri, Alzheimer xəstəliyi və diz-oynaq zədələrinin diaqnostikasında geniş istifadə olunan 3D görüntülmə üsuludur. BraTS yarışmaları bu sahədə 3D U-Net kimi modellərin inkişafını stimullaşdırmış, qabaqcıl modellər 0.90 Dice oxşarlıq əmsali ilə radioloq səviyyəsində nəticələr əldə etmişdir. Bu modellər çoxmodallı MRT ardıcılıqlarını istifadə edərək voxel səviyyəsində ödem və digər komponentləri seqmentasiya edir. 2020-ci ildə aparılmış bir tədqiqatda AI tərəfindən aparılmış avtomatik ölçmələr radioloq nəticələri ilə uyğun gəlmiş və sağqalma ehtimalını da proqnozlaşdırmağa bilmişdir [5]. Neyrodegenerativ xəstəliklərin diaqnostikasında MRT əsaslı modellər Alzheimer xəstəliyini yüksək dəqiqliklə (90%-dən yuxarı) proqnozlaşdırmağa bilər və hipokamp atrofiyası, beyin mədəciklərinin genişlənməsi kimi biomarkerləri təyin edir [5]. Əzələ-oynaq sahəsində CNN modelləri diz və onurğa

MRT-lərində zədələri aşkarlamaqda radioloqlarla müqayisə edilə biləcək dəqiqlik göstərmiş və analiz müddətini əhəmiyyətli dərəcədə azaltmışdır. Son dövrlərdə transformer əsaslı modellər də MRT analizində tətbiq edilməyə başlanılıb. Bu modellər 3D həcməldə uzunməsafəli məkan əlaqələrini daha yaxşı əhatə edə bilər. Lakin MRT və PET kimi 3D görüntülər yüksək hesablama resursları və yaddaş tələb etdiyindən, bu sahədə optimallaşdırılmış texnikalara ehtiyac yaranır:


- həcmi hissə-hissə təhlil etmək (Slab-based processing)
- Model sıxlaşdırması (compression)
- Transfer öyrənmə (2D-dən 3D-yə və ya 3D təbii görüntülərdən öyrənmə) kimi yanaşmalar bu çətinlikləri azaltmaq üçün tətbiq olunur.

Ümumilikdə, MRT-ə əsaslanan xəstəlik proqnozlaşdırma modelləri sürətlə inkişaf edir. Bəzi modellər artıq klinik sınaqlara daxil edilmişdir — məsələn, süni intellektlə idarə olunan MRT analizləri vasitəsilə hansı pasiyentlərin qabaqcıl müalicələrə yönləndirilməli olduğunu müəyyənləşdirmək üçün istifadə olunur. Açıq məlumat bazalarının və beynəlxalq yarışların artması ilə daha dəqiq və ümumiləşdirilə bilən MRT analiz modellərinin yaxın gələcəkdə ortaya çıxacağı gözlənilir.

D. Ultrasəs Görüntülmə və Xəstəliklərin Proqnozlaşdırılması

Ultrasəs – real vaxt rejimində görüntülmə təmin edən, doğuşayardım, ürək ekoqrafiyası, qarın orqanlarının müayinəsi kimi bir çox sahədə geniş istifadə olunan görüntülmə üsuludur. Bu görüntülər adətən səs-küylü və operatora bağlı olur ki, bu da tarixən avtomatlaşdırmanı çətinləşdirib. Buna baxmayaraq, dərin öyrənmə ultrasəs analizində də irəliləyişlərə səbəb olmuşdur. Xüsusilə uğurlu tətbiqlərdən biri doğuşayardım ultrasəsdir. CNN modelləri döl başının ultrasəs görüntülərində düzgün kəsik müstəvisini tanıyaraq baş çevrəsi kimi biometriya göstəricilərini avtomatik hesablaya bilər. Lee və əməkdaşlarının tədqiqatında model bu tapşırığı yüksək dəqiqliklə yerinə yetirmişdir [6]. Şəkil 4-də baş segmentasiyası, ventrikulomeqaliya aşkarlanması və CAM istilik xəritəsi ilə lokalizasiya nümunələri göstərilmişdir. CNN-lər ekokardiografiya da tətbiq olunur — sol mədəcikin segmentasiyası və ejeksiya fraksiyasının avtomatik hesablanması ilə ürək funksiyası 5%-dən az səhvlə qiymətləndirilə bilər. Damar ultrasəsində karotis lövhəciklərinin aşkarlanması və intima-media qalınlığının ölçülməsi üçün də istifadə olunur. Ultrasəs görüntülərindəki spekl səs-küyü və dəyişkənlik modelləşməni çətinləşdirir. Bu problemlərin öhdəsindən gəlmək üçün məlumat artırılması (səs-küy və bucaq dəyişmələri) və optik axın kimi xüsusi arxitekturalar tətbiq edilir. Ultrasəs operatora bağlı üsul olduğu üçün Sİ burada böyük potensiala malikdir. Bələdçi sistemlər təcrübəsiz istifadəçilərə probu düzgün yerləşdirmək və görüntünü şərh etməkdə real vaxt dəstəyi təqdim edə bilər. Bu yanaşma ultrasəs mütəxəssislərinin bacarığını daha geniş auditoriyaya çatdırmağa imkan verir. Aktiv tədqiqat mövzusu olaraq, Sİ-nin ultrasəs əsaslı diaqnostikada dəqiqliyi artıracağı

və bu texnologiyaları ilkin tibbi yardım səviyyəsində daha güclü vasitəyə çevirəcəyi gözlənilir.



Şəkil 4. Dərin öyrənmənin doğuşayardım ultrasəsində döl beyinin qiymətləndirilməsinə tətbiqi nümunələri
(a) Ultrasəs görüntüsündə döl başının segmentasiyası: U-Net konvolusion neyron şəbəkəsi (CNN) ultrasəs müstəvisində kranio-serebral (baş) bölgəsini avtomatik olaraq müəyyənləşdirir.
(b) Normal və anormal döl beyin görüntülərinin təsnifatı: CNN ultrasəs görüntüsünü emal edir və anormal trans-serebellar (TC) müstəvidə narahatedici sahəni (sarı çərçivə ilə) göstərir.
(c) Zəif nəzarət olunan zədələnmə lokalizasiyası: sinif aktivləşmə xəritələşdirməsindən (CAM) istifadə etməklə model, təlim zamanı piksel səviyyəli maska olmadan potensial beyin anomaliyasına uyğun gələn sahəni (yaşıl çərçivə və istilik xəritəsi) vurğulayır.

E. Oftalmologiya: Torlu Qişa (Retina) Fundus Görüntülmə

Oftalmologiya – Sİ əsaslı görüntü analizinin geniş tətbiq tapdığı ilk tibbi sahələrdən biri olmuşdur. Dərin öyrənmə alqoritmləri bu cür xəstəlik əlamətlərini çox yüksək dəqiqliklə ayırd edə bilər [7]. Şəkil 5-dəki kimi torlu qişanın (retinanın) yüksək ayırdetməli 2D fundus şəkilləri diabet xəstələrində diabetik retinopatiya (DR) üçün skrining məqsədilə mütəmadi olaraq çəkilir. DR görmə itkisinə səbəb olan əsas xəstəliklərdən biridir. 2016-cı ildə dərc edilmiş dönüş nöqtəsi sayılan bir tədqiqatda DR-nin aşkarlanması üçün dərin öyrənməyə əsaslanan alqoritm hazırlamış və bu model ROC əyrisinin altında sahə (AUC) üzrə təxminən 0.99, həmçinin 90%-dən yuxarı həssaslıq və spesifiklik əldə etmişdir [8]. Bu nəticələr ekspert-oftalmoloqlarla müqayisə edilə biləcək səviyyədə olmuş və bir neçə klinikadan toplanmış böyük məlumat bazalarında uğurla yoxlanılmışdır. Alqoritm, fundus şəkillərində mikroanevrizma, qanaxma və eksudatlar kimi xarakterik zədələnmələri aşkar etməyə yönəldilmişdir. Bu alqoritm sonradan skrining proqramlarında tətbiq olunmuş və insan-mütəxəssislər üzərindəki yüklənməni azaltmaq üçün Sİ-nin real həyat şəraitində istifadə oluna biləcəyini sübut etmişdir. Bu uğurdan sonra, digər göz xəstəliklərinin aşkarlanması üçün də oxşar dərin öyrənmə sistemləri hazırlanmışdır. Məsələn, qlaukoma: fundus

görüntülərində optik diskin çökəkliyinin (optic disc cupping) qiymətləndirilməsi ilə aşkar olunur, yaşa bağlı makulyar degenerasiya: drusen yığınlarının tanınması vasitəsilə təyin edilir.




Şəkil 5. Diabetik retinopatiyanın avtomatik aşkarlanması üçün istifadə olunan torlu qışa (retina) fundus şəkilləri.
(a) — heç bir xəstəlik əlaməti olmayan sağlam retinani göstərir.
(b) — müalicə tələb edən diabetik retinopatiya olan retinani göstərir; burada çoxsaylı qanaxmalar (tünd qırmızı ləkələr şəklində) görünür.

Ümumilikdə, oftalmologiya Sİ-nin tibbi görüntülərlə proqnozlaşdırma ən uğurlu sahələrindən biridir və burada əldə edilən nəticələr onun dəqiq və klinik baxımdan effektiv modellər yarada bildiyini təsdiqləyir. Bu nümunələr HAM10000 məlumat bazasından götürülmüş müxtəlif dəri lezyonlarını əhatə edir. Lezyonun dəqiq segmentasiyası onun bədxassəli və ya yaxşıxassəli kimi təsnif edilməsindən əvvəl vacib mərhələ sayılır [9]. Dermatologiyada süni intellektin tətbiqi ilk yüksək effektiv nəticələrdən biri olmuşdur. 2017-ci ildə hazırlanan CNN modeli 100,000-dən çox görüntü əsasında öyrədilmiş və melanoma ilə digər lezyonlar arasında dermatoloq səviyyəsində ayırd etmə qabiliyyəti nümayiş etdirmişdir [10]. Bu uğur Sİ-nin erkən diaqnostikada, xüsusilə həkim çatışmazlığı olan ərazilərdə faydalı ola biləcəyini göstərmişdir. Sonrakı tədqiqatlar model dəqiqliyinin və izah ediləbilenliyinin artırılmasına yönəlmişdir. Proses iki əsas mərhələdən ibarətdir: lezyonun segmentasiyası (şəkil 6-da olduğu kimi, lezyon ətraf sağlam dəridən ayırd edilir); lezyonun təsnifatı. Lezyonların formasının və sərhədlərinin qeyri-müəyyənliyi segmentasiyanı çətinləşdirə bilər. Lakin U-Net və diqqət əsaslı şəbəkələr 0.9-dan yuxarı Dice əmsalları ilə dəqiq segmentasiya nəticələri əldə etmişdir [9]. Segmentasiyadan sonra ResNet və EfficientNet kimi arxitekturalar lezyonu təsnif edir, yalnız melanoma deyil, digər növləri də ayırd edə bilər (bazal hüceyrəli karsinoma, atipik nevus və s.). Meta-analizlər göstərir ki, Sİ sistemləri melanoma aşkarlanmasında 80–90% həssaslıq və spesifikasiyaya çatır – bu, dermatoloq səviyyəsinə bərabərdir [11]. Sİ-nin sabitliyi, yəni eyni görüntüyə həmişə eyni cavabı verməsi, subyektiv diaqnostikanın əvəzinə daha standartlaşdırılmış yanaşma təklif edir. Sİ sistemləri həmçinin prioritetləşdirmə funksiyası daşıya bilər – şübhəli lezyonları erkən ayıraraq gecikmələrin qarşısını alır. Bəzi modellər görüntü ilə yanaşı yaş, lezyonun yeri kimi klinik məlumatları da daxil edərək daha kompleks qiymətləndirmə aparır. Sİ sistemlərinin istifadəsində əsas məqam, fərqli kamera, işıqlandırma şəraiti və dəri tiplərinə qarşı davamlılığın təmin olunmasıdır. Bu məqsədlə: məlumat bazalarının müxtəlifləşdirilməsi; rəng normalaşdırılması kimi metodlardan istifadə olunur. Ümumilikdə, dermatologiya sahəsində mütəxəssislər ehtiyatlı optimizmlə yanaşırlar — dəri xərçəngi skriningi üçün tənzimləyici təsdiqli Sİ alətləri yaxın gələcəkdə istifadəyə verilə bilər. Bu isə teledermatologiya və dermatoloq çatışmazlığı olan

bölgələrdə erkən aşkarlama üçün Sİ-nin dəyərli yardımçıya çevrilə biləcəyini göstərir.

F. Dermatologiya: Dəri Lezyonlarının Görüntülənməsi




Şəkil 6: Dərin öyrənmə ilə dəridəki lezyonların avtomatlaşdırılmış analizi.
(a) dəri lezyonunun ilkin klinik və ya dermoskopik görüntüsü,
(b) lezyon sahəsinin “ground-truth” (doğru) segmentasiya maskası,
(c) CNN tərəfindən avtomatik olaraq segmentasiya edilmiş lezyon sahəsi

G. Rəqəmsal Patologiya və Histologiya Görüntüləri

Patologiya sahəsində biopsiya nümunələrinin şüşə slaydları yüksək ayırdetməli görüntülərə skan edilir, çox zaman bu görüntülər gigapiksel ölçüsünü aşır və patologlar bu slaydları xərçəngin təsdiqlənməsi, şişin dərəcələndirilməsi kimi diaqnostik məqsədlərlə araşdırırlar. Dərin öyrənmə bu tam slayd görüntülərinə (WSI – whole-slide image) tətbiq edilməklə xərçəngin aşkarlanması, alt tiplərə bölünməsi, hətta proqnozlaşdırılması kimi tapşırıqlar üzrə sürətlə inkişaf etmişdir. Bu sahədə önəmli problemlərdən biri CAMELYON16 yarışmasında təklif edilmiş limfa düyünlərində metastatik xərçəngin aşkarlanması olmuşdur. 2017-ci ildə, dərin öyrənməyə əsaslanan bir alqoritm limfa düyünlərində mikrometastazları aşkarlamaqda (məhdud zaman daxilində) insan patologlardan daha yüksək həssaslıqla çıxış etmişdir [11]. Patologlara limitsiz zaman verildikdə onların performansları alqoritmə yaxınlaşsa da, bu nəticə Sİ-nin effektivliyi və diaqnostik dəqiqliyi artırmaq potensialını nümayiş etdirmişdir. Şəkil 7 bu yanaşmanı əyani şəkildə göstərir: tam slayd görüntüləri CNN modelinə birbaşa daxil etmək üçün çox böyükdür, buna görə də onlar kiçik hissələrə (tile-lərə) bölünür; CNN və ya vision transformer kimi dərin modellər bu kiçik hissələri analiz edərək şiş toxuması olub-olmadığını müəyyən edir [13]; bütün hissələrin nəticələri birləşdirilərək slaydda şiş sahələrinin yerləri qeyd olunur, bu da ehtimallara əsaslanan istilik xəritəsi (probability heatmap) yaradır. Tədqiqatlar kiçik hissələr üzrə şiş aşkarlanmasında təxminən 0.99 AUC nəticələri əldə etdiklərini göstərmiş, bu da slayd səviyyəsində ekspertlərlə müqayisəoluna bilən diaqnostik dəqiqlik deməkdir [14]. Sİ yalnız şişlərin aşkarlanması deyil, həm də onların dərəcələndirilməsi üçün tətbiq olunur (məsələn, Gleason və Bloom-Richardson sistemləri). Dərin öyrənmə modelləri H&E slaydlardan molekulyar xüsusiyyətləri (genetik mutasiyalar, protein ifadəsi)

əlavə testlərsiz proqnozlaşdırma bilir [15]. CNN-lər hüceyrə səviyyəsində seqmentasiya apararaq immun infiltratları müəyyənəşdirir, bu isə proqnoz baxımından dəyərlidir (şəkil 7, D–E).



Şəkil 7: Rəqəmsal patologiyanın dərin öyrənmə ilə analizi üzrə iş axını, süd vəzi xərçənginin metastaz verdiyi limfa düyününə aid histolojiya görüntüsü əsasında təqdim olunur

- (a): Tam slayd histolojiya görüntüsü (WSI) — metastatik şiş sahələri bənövşəyi boyanmışdır.
 (b): Avtomatik toxuma seqmentasiyası — toxuma sahələri fon bölgələrindən ayrılır.
 (c): Slaydın parçalara bölünməsi (blue grid) və analiz üçün hissələrin seçilməsi (sarı ilə işarələnmiş).
 (d): Şiş toxuması olan bir nümunə görüntü parçası.
 (e): Sİ ilə hüceyrə aşkarlanması — hər bir hüceyrə nüvəsi tanınır və təsnif edilir (məs., qırmızı = şiş hüceyrəsi, yaşıl = limfosit).
 (f): Slayd üzrə hüceyrə tiplərinin sayına dair histogram — məsələn, şiş hüceyrələrinin sıxlığını ümumiləşdirir.

III. METODOLOGİYA

Tibbi görüntülərdən istifadə edərək xəstəliyin proqnozlaşdırılması modellərinin hazırlanması bir sıra dəqiq müəyyənəşdirilmiş metodoloji mərhələlərdən ibarətdir. Baxmayaraq ki, dəqiq addımlar görüntüləmə növünə və tətbiq sahəsinə görə dəyişə bilər, ümumi ardıcılıq adətən sabit olur:

A. Məlumatların Toplanması və Hazırlanması

Yüksək keyfiyyətli, etiketlenmiş görüntü məlumatları modelin hazırlanması üçün əsasdır. Məlumatların toplanması adətən görüntülərlə yanaşı "ground truth" etiketlərin (məsələn, diaqnoz, seqmentasiya maskaları və ya pasiyent nəticələri) də toplanmasını əhatə edir. Tibbi kontekstdə bu etiketlər ekspert rəyinə əsaslanma bilər (məs., radioloqun şiş ərazilərini işarələməsi, patologun təsdiqlədiyi diaqnozlar) və ya klinik qeydlərdən götürülə bilər (biopsiya nəticələri, xəstəlik gedişatı). Tibbi məlumatların həssaslığına görə, tədqiqatçılar məxfilik qaydalarına (məs., HIPAA) riayət etməli və adətən anonimləşdirilmiş və ya açıq məlumat bazalarından (məs., NIH Chest X-rays, BraTS, CAMELYON və s.) istifadə etməlidirlər. Əsas addımlardan biri məlumatların əvvəlcədən emalıdır – bu, görüntü parlaqlığı/kontrastının normallaşdırılması (intensity normalization), ölçülərin və ya piksellərin ölçüsünün uyğunlaşdırılması (resizing/resampling), və artefaktların silinməsi kimi prosesləri əhatə edir. Məlumatın artırılması (data augmentation) geniş istifadə olunur: döndürmə, çevirmə, ölçülərin dəyişdirilməsi, səs-küy əlavə edilməsi və elastik deformasiyalar modellərin fərqli şərait və anatomiyalara uyğunlaşmasını yaxşılaşdırır [9]. MRT və ultrasəs kimi modalitələrdə görüntülər cihazdan cihaz fərqli ola bildiyindən histogram ekvallaşdırılması və ya z-score normallaşdırması kimi texnikalar tətbiq olunur.

B. Model Arxitekturası

Model arxitekturası seçimi görüntü növü və proqnozlaşdırma tapşırığına bağlıdır. CNN xüsusiyyət iyerarxiyalarını öyrənmək qabiliyyəti sayəsində görüntü analizi üçün əsas texnologiyadır. 2D görüntülər üçün (rentgen, fotoşkillər, KT/MRT dilimləri) ResNet, VGG, Inception və DenseNet kimi klassik arxitekturalar (çox zaman ImageNet üzərində ilkin öyrədilib, sonra tibbi görüntülərə uyğunlaşdırılaraq) geniş istifadə olunur [2]. Seqmentasiya üçün encoder-decoder strukturlu CNN-lər, məsələn, U-Net və onun çoxsaylı variantları (V-Net, Attention U-Net, Residual U-Net və s.) istifadə olunur. Bu modellər görüntünü aşağı ölçülü gizli təsvirə kodlayır, sonra maska şəklində dekod edir və keçid bağlantıları (skip connections) incə detalları qoruyur [16]. 3D görüntüləmə üçün (tam KT və ya MRT həcmli) 3D konvolyusiyalar tətbiq edilir. Əgər yaddaş və məlumat kifayət deyilsə, dilim-dilim 2D analiz və ya hibrid yanaşmalar (ortoqonal müstəviləri birləşdirən) seçilir. Yeni ortaya çıxan arxitekturalara Vision Transformer-lər (ViT) və Qraf Neyron Şəbəkələri (GNN) daxildir. Bunlar daha geniş kontekstləri və hüceyrələrarası əlaqələri öyrənməkdə faydalıdır. Metodologiya tez-tez müxtəlif arxitekturaların və hiperparametr ayarlarının sınaqdan keçirilməsini, çarpaz yoxlama (cross-validation) ilə modellərin ümumiləşdirmə qabiliyyətinin qiymətləndirilməsini əhatə edir.

C. Təlim Strategiyaları

Tibbi görüntü modellərinin təlimi özünəməxsus məsələləri ehtiva edir. Sinif balanssızlığı geniş yayılmış problemdir — məsələn, yalnız az bir hissə mammoqramlarda xərçəng ehtiva edir. Bunun üçün balanslaşdırılmış mini-batch-lər, nadir siniflərin təkrar öyrədilməsi (oversampling) və ya ixtisaslaşmış itki funksiyaları (Dice loss, focal loss və s.) istifadə olunur [9]. Transfer öyrənmə də əsas strategiyadır: məhdud tibbi məlumat bazaları üçün modellər əvvəlcədən öyrədilmiş çəki dəyərləri ilə başlanır (məs., ImageNet) və sonra uyğun tibbi tapşırıq üzrə fine-tuning edilir. Təlim zamanı tətbiq olunan məlumat artırma, yalnız ümumiləşdirməni yaxşılaşdırmır, eyni zamanda overfitting problemini azaldır. Dropout və weight decay kimi regularizasiya metodları da geniş istifadə olunur. Zəif nəzarətli öyrənmə (weakly supervised learning) – tam etiketləmə olmayan hallarda — şəkil səviyyəsində etiketlərdən istifadə edərək təsnifat modeli qurulur, daha sonra Class Activation Mapping (CAM) vasitəsilə lokalizasiya əldə edilir (məs., ultrasəs nümunəsində — Şəkil 4) [9]. Çoxtapşırıqlı öyrənmə (multi-task learning) də istifadə olunur — məsələn, bir model həm təsnifat, həm seqmentasiya və ya bir neçə xəstəlik etiketini eyni anda proqnozlaşdırma bilər.

D. Doğrulama və Test

Tibbi AI modelləri üçün dəqiq qiymətləndirmə vacibdir. Adətən məlumatlar təlim, doğrulama və test dəstlərinə bölünür (pasiyent əsaslı bölünmə ilə — eyni pasiyentin görüntüləri həm təlim, həm testdə olmamalıdır). Tapşırıqə uyğun performans göstəriciləri:

- Təsnifat üçün: dəqiqlik, həssaslıq (recall), spesifikasiq, dəqiqlik (precision), ROC AUC;
- Seqmentasiya üçün: Dice əmsalı, Jaccard indeksi, piksel əsaslı həssaslıq və dəqiqlik;

• Aşkarlama (lokalizasiya) üçün: Intersection over Union (IoU), mean average precision.

Tibbi kontekstdə həssaslığa üstünlük verilir (çünki xəstəliyi qaçırmmaq yalan siqnalda daha təhlükəlidir). Modellər tez-tez mütəxəssislərlə müqayisə edilir, statistik testlər və bootstrap analizləri nəticə fərqlərinin əhəmiyyətini qiymətləndirmək üçün istifadə olunur [3]. Çarpaz yoxlama məlumat azlığında geniş tətbiq olunur. Modellər xarici məlumatlarda (external validation) da test edilməlidir – bu, fərqli klinika və ya ölkələrdən olan məlumatlarda modelin ümumiləşmə qabiliyyətini göstərir. Bu testlər zamanı performansın düşməsi domain adaptation və stil ötürülməsi kimi texnikaları zəruri edir.

E. Modelin Şərhi

Tibbdə izah edilə bilən Sİ-yə olan ehtiyacdən dolayı, metodologiyaya şərhədi texnikalar daxil edilir. Məsələn:

• Saliency map-lər (Grad-CAM və s.) görüntü üzərində vacib sahələri göstərir;

• Occlusion testi (görüntünün hissələrinin gizlədilməsi ilə təsirin ölçülməsi);

• Kliniki anlayış vektorları (məs., həkimə önəmli olan strukturların modeldə hansı təsiri var?).

Bəzi hallarda model şəkildəki qeyri-səhiyyə elementlərini (məs., xəstə ID-si, xəstəxana kodu) öyrənə bilər. Şərh alətləri bu tip qısa yol öyrənmə (shortcut learning) hallarını üzə çıxararaq təlimin düzəldilməsinə imkan verir [3].

F. Tətbiq Mərhələləri

Akademik məqalələrdə tez-tez yer verilməsə də, modelin klinik istifadəyə hazırlanması əlavə mərhələlər tələb edir:

• Kalibrləmə — proqnoz ehtimallarının real risklərlə uyğunlaşdırılması (Platt Scaling, isotonic regression),

• Monitoring və dövrü yenidən öyrədilmə, xüsusən canlı verilənlərlə və ya fərqli cihazlarla işləyərkən,

• Ədalətlik və fərqliliklərə uyğunluq — modelin yaş, cins, etnik qrup kimi fərqli alt qruplarda balanslı işləməsi.

Bunlar üçün qəsdən hazırlanmış test dəstləri və ya bias azaldıcı öyrənmə strategiyaları tətbiq olunur.

IV. NƏTİCƏ

Dərin öyrənmə metodlarının tibbi təsvirlərdə tətbiqi nəticəsində xəstəliklərin proqnozlaşdırılması sahəsində əhəmiyyətli irəliləyişlər əldə olunmuşdur. Rentgen və KT-də CNN modelləri pnevmoniya və ağciyər düyünlərinin aşkarlanmasında, MRT-də beyin şişlərinin segmentasiyasında, ultrasəsdə döl və ürək görüntülərinin təhlilində, fundus şəkillərində diabetik retinopatiyanın müəyyən olunmasında, dermatologiyada isə melanoma aşkarlanmasında insan-mütəxəssislərlə müqayisə edilə biləcək dəqiqlik göstərmişdir. Patologiyada isə dərin modellər mikrometastazların və hüceyrə tiplərinin aşkarlanmasında yüksək AUC dəyərlərinə çatmışdır.

Bununla belə, model performansının fərqli cihaz və regionlarda sabitliyi, məlumat azlığı və “qara qutu” problemi kimi məhdudiyyətlər hələ də mövcuddur. İntegrasiya olunmuş Sİ-həkim əməkdaşlıq yanaşmaları daha yüksək dəqiqlik təmin edir və klinik axına daha uyğundur. Gələcək inkişaf, izah edilə bilən süni intellekt və multimodal yanaşmaların tətbiqi ilə bu

modellərin istifadəsini daha da genişləndirə bilər. Dərin öyrənmə, tibbi görüntü analizində yalnız əlavə vasitə deyil, klinik qərar qəbulunu dəstəkləyən əsas texnologiyaya çevrilmək potensialına malikdir.

ƏDƏBİYYAT

- [1] “Global medical imaging market report 2021-2026: analysis by X-ray, ultrasound, MRI, CT scan, nuclear imaging – ResearchAndMarkets.com,” Business Wire, Jun. 8, 2021. [Online]. Available: <https://www.businesswire.com/news/home/20210608005582/> (accessed May 21, 2025).
- [2] B. Sistaninejad, H. Rasi, and P. Nayeri, “A review paper about deep learning for medical image analysis,” *Comput. Math. Methods Med.*, vol. 2023, art. 7091301, May 2023.
- [3] J. Hofmeister, N. Garin, X. Montet, M. Scheffler, A. Platon, and P.-A. Poletti, et al., “Validating the accuracy of deep learning for the diagnosis of pneumonia on chest X-ray against a robust multimodal reference diagnosis: a post hoc analysis of two prospective studies,” *Eur. Radiol. Exp.*, vol. 8, art. 20, Feb. 2024.
- [4] Y. Jalali, M. Fateh, M. Rezvani, V. Abolghasemi, and M. H. Anisi, “ResBCDU-Net: a deep learning framework for lung CT image segmentation,” *Sensors*, vol. 21, no. 1, art. 268, Jan. 2021.
- [5] Y. Liu, F. Mu, Y. Shi, J. Cheng, C. Li, and X. Chen, “Brain tumor segmentation in multimodal MRI via pixel-level and feature-level image fusion,” *Front. Neurosci.*, vol. 16, art. 1000587, Sep. 2022.
- [6] H. Zhang and Y. Qie, “Applying deep learning to medical imaging: a review,” *Appl. Sci.*, vol. 13, no. 18, art. 10521, Sep. 2023.
- [7] L. Peng and V. Gulshan, “Deep learning for detection of diabetic eye disease,” Google Research Blog, Nov. 29, 2016. [Online]. Available: <https://research.google/blog/deep-learning-for-detection-of-diabetic-eye-disease/> (accessed May 21, 2025).
- [8] V. Gulshan, L. Peng, M. Coram, M. C. Stumpe, D. Wu, and A. Narayanaswamy, et al., “Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs,” *JAMA*, vol. 316, no. 22, pp. 2402–2410, Dec. 2016.
- [9] G. Alwakid, W. Gouda, M. Humayun, and N. U. Sama, “Melanoma detection using deep learning-based classifications,” *Healthcare*, vol. 10, no. 12, art. 2481, Dec. 2022.
- [10] A. Esteva, B. Kuprel, R. A. Novoa, J. Ko, S. M. Swetter, and H. M. Blau, et al., “Dermatologist-level classification of skin cancer with deep neural networks,” *Nature*, vol. 542, no. 7639, pp. 115–118, Feb. 2017.
- [11] K. Young, “AI could help detect lymph node metastases,” *NEJM Journal Watch*, Dec. 13, 2017. [Online]. Available: <https://www.jwatch.org/fw113630/2017/12/13/ai-could-help-detect-lymph-node-metastases> (accessed May 21, 2025).
- [12] Q. D. Vu, S. Graham, T. Kurc, M. N. N. To, M. Shaban, and T. Qaiser, et al., “Methods for segmentation and classification of digital microscopy tissue images,” *Front. Bioeng. Biotechnol.*, vol. 7, art. 53, Apr. 2019.
- [13] H. Badgery, Y. Zhou, A. Siderellis, M. Read, and C. Davey, “Machine learning in laparoscopic surgery,” in *Artificial Intelligence in Medicine: Applications, Limitations and Future Directions*, M. Raz, T. C. Nguyen, and E. Loh, Eds. Singapore: Springer, 2022, pp. 175–190.
- [14] B. E. Bejnordi, M. Veta, P. J. van Diest, B. van Ginneken, N. Karssenmeijer, and G. Litjens, et al., “Diagnostic assessment of deep learning algorithms for detection of lymph node metastases in women with breast cancer,” *JAMA*, vol. 318, no. 22, pp. 2199–2210, Dec. 2017.
- [15] A. Davri, E. Birbas, T. Kanavos, G. Ntritsos, N. Giannakeas, and A. T. Tzallas, et al., “Deep learning on histopathological images for colorectal cancer diagnosis: a systematic review,” *Diagnostics*, vol. 12, no. 4, art. 837, Apr. 2022.
- [16] [A. Saood and I. Hatem, “COVID-19 lung CT image segmentation using deep learning methods: U-Net versus SegNet,” *BMC Med. Imaging*, vol. 21, no. 1, art. 19, Feb. 2021.