

https://doi.org/10.51885/3134-8025_IJCS_2026_2_9

XFTAP 28.23.37

ОСТЕОПОРОЗДЫ ДИАГНОСТИКАЛАУДА ТЕРЕҢ НЕЙРОНДЫҚ ЖЕЛІЛЕРДІ ЖӘНЕ ИЕРАРХИЯЛЫҚ ТӘСІЛДІ САЛЫСТЫРМАЛЫ ТАЛДАУ

СРАВНИТЕЛЬНЫЙ АНАЛИЗ ГЛУБОКИХ НЕЙРОННЫХ СЕТЕЙ И ИЕРАРХИЧЕСКОГО ПОДХОДА ДЛЯ ДИАГНОСТИКИ ОСТЕОПОРОЗА

COMPARATIVE ANALYSIS OF DEEP NEURAL NETWORKS AND HIERARCHICAL APPROACH FOR DIAGNOSIS OF OSTEOPOROSIS

А.С. Нурекенова ^{1*}, С.С. Смаилова ¹, С.К. Кумаргажанова ¹,Róża Dzierżak ², Р.К. Нурсадыкова ¹¹Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен қ., Қазақстан²Люблин техникалық университеті, Люблин қ., Польша

*Жауапты автор: Нурекенова Арайлым Солтахановна, e-mail: soltahanovna@gmail.com

Түйінді сөздер:

жасанды интеллект,
машиналық оқыту,
тереңдетіп оқыту,
остеопороз,
иерархиялық модель,
медициналық
бейнелерді талдау.

ТҮЙІНДЕМЕ

Бұл жұмыста терең оқыту әдістерін қолдана отырып, тізе буынының рентгенографиясы бойынша остеопорозды диагностикалау міндеті ұсынылған. Бұл зерттеудің мақсаты медициналық кескіндерді үш негізгі классқа жіктеу үшін әртүрлі конволюциялық нейрондық желілердің тиімділігін талдау болып табылады: норма, остеопения және остеопороз.

Сыналған модельдер ретінде VGG16, ResNet50, EfficientNet-B0, YOLOv8-cls архитектуралары пайдаланылды. Кезеңдік жіктеуге негізделген иерархиялық тәсіл де қолданылады. Бұл модельдер 293 сынақ кескіні бар бірыңғай деректер жиынтығында оқытылды және бағаланды. Бұл осы салыстырмалы талдаудың дұрыстығын қамтамасыз етті. Accuracy, precision, recall және F1-score көрсеткіштері жіктеу сапасын бағалау үшін қолданылды және қате матрицаларын талдау жүргізілді.

Осы эксперименттердің нәтижелері ResNet50 моделі дәлдік пен тұрақтылықтың ең жақсы арақатынасын көрсетіп, 82.3% дәлдікке қол жеткізгенін көрсетті. Бірақ белгілері бойынша ұқсас екі сынып арасында шатасулар болды. Иерархиялық тәсіл остеопения мен остеопороз арасындағы кластар арасындағы шатасуды азайтуға мүмкіндік берді. Бірақ жіктеудің жалпы дәлдігінің төмендеуіне әкелді. Эксперименттердің нәтижесі остеопорозды диагностикалау үшін конволюциялық нейрондық желілерді қолданудың тиімділігін растайды.

Ключевые слова:

искусственный
интеллект, машинное
обучение, глубокое
обучение, остеопороз,
иерархическая
модель,

АННОТАЦИЯ

В данной работе представлена задача диагностики остеопороза по рентген изображениям коленного сустава с использованием методов глубокого обучения. Целью данного исследования является анализ эффективности различных сверточных нейронных сетей для классификации медицинских изображений на три главных класса: норма, остеопения и остеопороз.



анализ медицинских
изображений.

Архитектуры VGG16, ResNet50, EfficientNet-B0, YOLOv8-clс были использованы в качестве тестируемых моделей. Так же применен иерархический подход, основанный на поэтапной классификации. Данные модели обучались и оценивались на едином наборе данных, в котором 293 тестовых изображения. Это обеспечило корректность данного сравнительного анализа. Метрики accuracy, precision, recall и F1-score применялись для оценки качества классификации и проведен анализ матриц ошибок.

Результаты данных экспериментов показали, что модель ResNet50 показала наилучшее соотношение точности и устойчивости, достигнув точности 82.3%. В то же время наблюдалась повышенная степень ошибочной классификации между двумя классами с близкими по характеристикам признаками. Иерархический подход позволил снизить межклассовую путаницу между остеопенией и остеопорозом. Однако привёл к снижению общей точности классификации. Результат экспериментов подтверждают эффективность применения сверточных нейронных сетей для диагностики остеопороза.

keywords:

artificial intelligence,
machine learning, in-
depth learning,
osteoporosis,
hierarchical model,
medical imaging
analysis.

ABSTRACT

This work provides the task of diagnosing osteoporosis using X-ray images of the knee joint using deep learning methods. The purpose of this study is to analyze the effectiveness of various convolutional neural networks for classifying medical images into three main classes.: norm, osteopenia and osteoporosis.

The VGG16, ResNet50, EfficientNet-B0, and YOLOv8-clс architectures were used as test models. A hierarchical approach based on step-by-step classification is also applied. These models were trained and evaluated on a single dataset containing 293 test images. This ensured the correctness of this comparative analysis. The accuracy, precision, recall, and F1-score metrics were used to evaluate classification quality and error matrices were analyzed.

The results of these experiments showed that the ResNet50 model showed the best ratio of accuracy and stability, reaching an accuracy of 82.3%. But there was confusion between the two classes with similar characteristics. The hierarchical approach has reduced the inter-class confusion between osteopenia and osteoporosis. But it led to a decrease in the overall classification accuracy. The experimental results confirm the effectiveness of using convolutional neural networks for the diagnosis of osteoporosis.

КІРІСПЕ

Қазіргі заманда денсаулық сақтаудың маңызды міндеттерінің бірі – остеопороз сияқты созылмалы ауруларды ерте диагностикалаудың тиімді және қол жетімді әдістерін жасау. Остеопороз – сүйек тығыздығының жүйелі төмендеуі сыну қаупін арттырады. Дүниежүзілік денсаулық сақтау ұйымының бағалауы бойынша, остеопороз жыл сайын мүгедектікке әкелетін миллиондаған сынықтарды тудырады. Халықтың, әсіресе 50 жастан асқан әйелдер мен егде жастағы адамдардың осал санаттары арасында остеопороздың таралуы бұл мәселенің демографиялық және әлеуметтік маңыздылығын арттырады.

Қазіргі уақытта остеопорозды диагностикалауда екі энергиялы рентгендік абсорбциометрия (DXA), рентгенография және компьютерлік томография (КТ) сияқты классикалық әдістер кеңінен қолданылады. Бұл әдістер жоғары сезімталдыққа ие болғанымен, нәтижелерді маман дәрігердің интерпретациялауын талап етеді. Мұндай талдау субъективті сипатқа ие болып, әсіресе аурудың ерте кезеңдерінде адам факторының әсеріне тәуелді болуы мүмкін. Тағы басқа, Қазақстанның бірқатар өңірлерінде және басқа

елдерде мамандандырылған жабдықтар мен тәжірибелі мамандардың қолжетімділігі шектеулі. Осыған байланысты медициналық кескіндерді автоматты түрде талдауға негізделген интеллектуалды диагностикалық жүйелерді әзірлеу өзекті ғылыми бағыттардың біріне айналууда.

Машиналық оқыту және компьютерлік көру технологияларының қарқынды дамуы медициналық кескіндерді талдау процестерін автоматтандыруға мүмкіндік берді. Конволюциялық нейрондық желілер (CNN), трансформерлік архитектуралар, сегменттеу әдістері және supervised learning алгоритмдері сүйек кескіндерін өңдеуде жоғары нәтижелер көрсетуде. Мұндай тәсілдер остеопорозды анықтап қана қоймай, оның сатыларын жіктеуге және сыну қаупін болжауға мүмкіндік береді.

Алайда қолданыстағы зерттеулердің бірқатар шектеулері бар. Біріншіден, жұмыстардың басым бөлігі омыртқа мен жамбас аймағына бағытталған, ал тізе буынына арналған зерттеулер саны салыстырмалы түрде аз. Екіншіден, көптеген зерттеулер шағын немесе бір орталықты деректер жиынтығында жүргізілген, бұл модельдердің жалпылану қабілетін төмендетуі мүмкін. Үшіншіден, көптеген жұмыстарда бір сатылы көпкласты жіктеу қолданылып, остеопения мен остеопороз арасында айтарлықтай класаралық шатасу сақталады. Сонымен қатар, бірқатар зерттеулерде сыртқы валидация жүргізілмеген, бұл модельдердің нақты клиникалық жағдайда қолданылуын шектеуі ықтимал.

Осы мәселелерді ескере отырып, бұл жұмыстың мақсаты — тізе буынының рентгенографиялық кескіндері негізінде остеопорозды диагностикалауға арналған терең оқыту модельдеріне салыстырмалы талдау жүргізу және остеопения мен остеопороз арасындағы класаралық шатасуды азайтуға бағытталған иерархиялық тәсілдің тиімділігін бағалау болып табылады.

ӘДЕБИЕТКЕ ШОЛУ

Әдеби шолу барысында остеопорозды диагностикалау саласындағы машиналық оқыту және терең оқыту әдістеріне арналған ғылыми жұмыстар талданды. Зерттеудің шамамен 84 %-ы сынықтарды жіктеу саласына жатады. Бұл жұмыстарда зерттеулер рентгенография немесе компьютерлік томография (КТ) қолдана отырып, конволюциялық нейрондық желілерді қолдану арқылы жүзеге асырылады. Екінші бағыт остеопорозға байланысты сынықтарды болжауға арналған. Сыну ықтималдығын бағалау үшін жұмыс радиомикалық және клиникалық белгілерді қолданды. Сондай-ақ, жұмыстың шамамен 77 %-ы КТ және рентген суреттеріне негізделген қалыпты, остепения, остеопороз сияқты аурудың кезеңдері бойынша жіктеу көрсетілген.

Бұларды талдау кезінде басылымдардың айтарлықтай бөлігі компьютерлік томографияны қолдана отырып зерттеуге арналғанын көрсетеді. Бұл шамамен 54 % құрайды, бұл әдіс остеопорозды диагностикалауда және сүйектің минералды тығыздығын бағалауда тиімді екенін көрсетеді. Талданған зерттеулердің шамамен 33 %-ында рентгендік кескіндер қолданылған, бұл аталған әдістің қолжетімділігі мен диагностикалық тиімділігіне байланысты оған деген ғылыми қызығушылықтың жоғары екенін көрсетеді. Магнитті-резонанстық томографияға (МРТ) негізделген зерттеулер шамамен 12 % аз. Бұл әдіс болжаудың жоғары дәлдігін көрсетсе де, МРТ кескінінің қол жетімділігі төмен болып табылады.

Зерттеулерде қарастырылған дене аймақтарын талдау барысында ең көп назар омыртқа мен жамбас аймақтарына аударылғаны анықталды, себебі бұл аймақтар остеопорозға байланысты сынуларға жиі ұшырайды. Көптеген зерттеулерде омыртқа аймағы, әсіресе T12 және L1–L4 сегменттері қарастырылған. Park және басқ. (2024), Pan және басқ. (2024), Pickhardt және басқ. (2022) зерттеулерінде CNN, ResNet және U-Net архитектуралары қолданылып, AUC көрсеткіші 0.93–0.99 аралығында болған. Бұл зерттеулерде сүйектердің құрылымы, сондай-ақ остеопороздың жіктелуін бағалау үшін КТ және рентген

суреттерін қолданды. Сондай-ақ, барлық жұмыстардың төрттен бірін құрайтын басылымдарда жамбас сүйегін, жамбас буынын зерттеді. Мысалы, Yuan және басқ. (2025), Du және басқ. (2025), Lim және басқ. (2021), Jang және басқ. (2021) авторларының жұмыстарында жамбас остеопорозы және сүйек минералды тығыздығының жіктелуі болжанған. Random Forest, Logistic Regression, CNN сияқты машиналық оқыту әдістері 85 %-дан 94 %-ға дейінгі дәлдікті көрсетті. Зерттеулердің шамамен 10%-ында тізе буыны қарастырылған. Siddharth және басқ. (2025), Naguib және басқ. (2024) жұмыстарында тізе буынының рентгенографиялық кескіндерін автоматты талдау және остеопорозды жіктеу үшін CNN архитектуралары пайдаланылған. Сонымен қатар, бірқатар зерттеулерде білек және жақ сүйектері аймақтары да қарастырылған. Sebro және Garza-Ramos (2022) білек сүйегінің КТ кескіндері негізінде остеопорозды анықтап, AUC = 0,81 нәтижесін көрсеткен. Ал жақ аймағының кескіндерін талдау үшін K-means, Decision Tree және CNN архитектураларына негізделген машиналық оқыту тәсілдері пайдаланылған.

Талданған зерттеулер көрсеткендей, остеопорозды диагностикалауда негізгі назар омыртқа мен жамбас сүйектеріне аударылған. Бұл аталған аймақтардың остеопорозға байланысты сынуларға жиі ұшырауымен түсіндіріледі. Сонымен қатар, кейбір зерттеулерде білек сүйектері де қарастырылған. Sebro және Garza-Ramos (2022) машиналық оқытуға негізделген білек сүйектерінің КТ талдауы 50 жастан асқан пациенттерде остеопороз бен остеопенияны анықтауда дәстүрлі бір сүйекті бағалаумен салыстырғанда жоғары нәтиже көрсеткенін хабарлаған. Ең жоғары нәтиже rbf ядросы бар SVM моделінде байқалып, AUC = 0.818 көрсеткішіне қол жеткізілген ($p = 0.020$). Antonio Adarve-Castro және басқ. (2025) диагностикалық дәлдікті арттыру мақсатында текстуралық белгілерді пайдаланған. Зерттеу нәтижелері бойынша Naïve Bayes ансамбльдік моделі мен нейрондық желі AUC = 0.916 нәтижесін көрсеткен. Алайда, зерттеуде шағын деректер жиынтығы қолданылғандықтан, нәтижелердің жалпылану қабілеті шектеулі болуы мүмкін. Jinglei Yuan және басқ. (2025) радиомикалық талдау арқылы остеопения белгілерін дәстүрлі КТ кескіндерінен ертерек анықтау мүмкіндігін көрсеткен. Авторлар оқыту кезеңінде AUC = 0.934, бірінші тестте 0.893 және екінші тестте 0.851 нәтижелерін алған. Деректер жиынтығы салыстырмалы түрде үлкен болғанымен, авторлар басқа популяцияларда сыртқы валидация жүргізу қажеттігін атап өткен. Liu және басқ. (2025) сыртқы валидацияны қамтитын көпорталықты зерттеу ұсынып, нәтижелердің жалпылану қабілетін арттыруға бағытталған тәсілді қолданған. Жұмыста радиомикалық белгілер мен машиналық оқытудың бірнеше модельдері пайдаланылып, Logistic Regression моделі ішкі валидацияда AUC = 0.96, ал сыртқы валидацияда 0.79–0.84 нәтижелерін көрсеткен. Park және басқ. (2024) жұмысында машиналық оқыту моделі AUC = 0.983 дейін жоғары нәтиже көрсеткенімен, модель архитектурасы толық сипатталмаған. Pan және басқ. (2024) көпфункционалды терең конволюциялық нейрондық желіні қолданып, AUC = 0.99 нәтижесіне қол жеткізген. Changyu Du және басқ. (2025) остеопорозды анықтауда AUC > 0.95 нәтижесін көрсеткен, алайда зерттеу бір орталықты деректерге негізделіп, сыртқы валидация жүргізілмеген. Pan Y. және басқ. (2020) U-Net архитектурасын пайдаланып, AUC > 0.94 нәтижесіне қол жеткізген, бірақ авторлар көпорталықты тестілеу қажеттігін атап өткен. Liu L. және басқ. (2022) КТ кескіндерімен қатар клиникалық және зертханалық деректерді пайдаланып, AUC = 0.962 нәтижесін көрсеткен. Алайда, зерттеуде КТ кескіндерінің көлемі шектеулі болған. Zhang K. және басқ. (2023) көпдеңгейлі терең оқыту алгоритмін пайдаланып, 93.3% диагностикалық дәлдікке қол жеткізген.

Талданған зерттеулерді қорытындылай отырып, қазіргі тәсілдердің бірнеше шектеулері анықталды. Біріншіден, жұмыстардың басым бөлігі омыртқа мен жамбас аймағына бағытталған, ал тізе буынына арналған зерттеулер саны салыстырмалы түрде аз. Клиникалық тәжірибеде остеопорозды диагностикалау үшін көбінесе омыртқа мен

жамбас сүйектерінің кескіндері қолданылғанымен, тізе буынының рентгенографиялық суреттері де перспективалы бағыт ретінде қарастырылуда. Бұл, бір жағынан, тізе буыны рентгенографиясының күнделікті клиникалық тәжірибеде кең қолжетімді және жиі орындалатын зерттеу әдісі болуымен түсіндіріледі. Сонымен қатар, тізе аймағындағы сүйек құрылымының өзгерістері сүйек минералды тығыздығының төмендеуімен байланысты болуы мүмкін. Тізе буынының рентгенографиясы көбінесе артроз, жарақат және жасқа байланысты өзгерістер кезінде орындалатындықтан, мұндай кескіндерді қосымша скринингтік мақсатта пайдалану пациентке қосымша сәулелік жүктеме түсірмей остеопороз белгілерін ерте анықтауға мүмкіндік береді.

Екіншіден, көптеген зерттеулер шағын немесе бір орталықты деректер жиынтығында жүргізілген, бұл модельдердің жалпылану қабілетін төмендетуі мүмкін. Үшіншіден, көптеген жұмыстарда бір сатылы көпкласты жіктеу қолданылып, остеопения мен остеопороз арасында айтарлықтай класаралық шатасу сақталады. Сонымен қатар, бірқатар зерттеулерде сыртқы валидация жүргізілмеген, бұл модельдердің нақты клиникалық жағдайда қолданылуын шектеуі ықтимал.

Осы мәселелерді ескере отырып, бұл жұмыста тізе буынының рентгенографиялық суреттері негізінде остеопорозды диагностикалау үшін терең оқыту модельдерінің салыстырмалы талдауы жүргізілді. Сонымен қатар, остеопения мен остеопороз арасындағы класаралық шатасуды азайту мақсатында ResNet-50 архитектурасына негізделген иерархиялық тәсіл ұсынылды. Аталған тәсіл алдымен «норма» және «патология» кластарын ажыратып, кейін патологиялық жағдайларды остеопения және остеопороз сатылары бойынша нақтылайды. Мұндай құрылым модельдің клиникалық интерпретациясын жақсартып, диагностикалық шешімдердің тұрақтылығын арттыруға мүмкіндік береді.

ЗЕРТТЕУ МАТЕРИАЛДАРЫ МЕН ӘДІСТЕРІ

Эксперименттік зерттеу үшін Kaggle ашық платформасынан алынған тізе буынының рентгенографиялық кескіндер жиынтығы пайдаланылды. Деректер жиынтығы үш класстан тұрды: Healthy (780 кескін), Osteopenia (374 кескін) және Osteoporosis (793 кескін). Жалпы деректер көлемі 1947 кескінді құрады. Деректер 70% оқыту (train), 15% валидация (validation) және 15% тестілеу (test) жиынтықтарына бөлінді. Барлық кескіндер модельдерді оқыту алдында 224×224 пиксель өлшеміне келтірілді.

Деректер жиынтығында класстар арасындағы теңгерімсіздік байқалды, әсіресе остеопения класының көлемі басқа класстармен салыстырғанда аз болды. Бұл мәселенің әсерін азайту мақсатында кескіндерді аугментациялау әдістері қолданылды.

Деректер ашық көзден алынғандықтан, пациент деңгейіндегі толық тәуелсіздікті тексеру мүмкін болмады. Осыған байланысты бір пациентке тиесілі бірнеше кескіндердің әртүрлі ішкі жиынтықтарға түсу ықтималдығы толық жоққа шығарылмайды. Дегенмен, барлық модельдер бірдей train/validation/test бөлінісінде бағаланды, бұл салыстырмалы талдаудың бірізділігін қамтамасыз етеді.

Деректер жиынтығы әртүрлі көздерден қалыптастырылғандықтан, рентгенографиялық кескіндер жарықтық, контраст, масштаб, шу деңгейі және бағдар бойынша ерекшеленді. Мұндай айырмашылықтар терең нейрондық желілердің тұрақты оқытылуына әсер етіп, жіктеу дәлдігінің төмендеуіне себеп болуы мүмкін. Осыған байланысты кескіндердің сапасын біріздендіру және ақпараттық белгілердің айқындылығын арттыру мақсатында алдын ала өңдеу әдістері қолданылды. Кескіндерді алдын ала өңдеу барысында пайдаланылған негізгі әдістер 1-суретте көрсетілген.



1-сурет. Кескінді алдын ала өңдеу әдістері

Ескерту – авторлар құрастырған

Бір өлшемді кескіндер пропорцияларды сақтай отырып масштабталды, бұл анатомиялық құрылымдардың геометриялық бұрмалануын төмендетуге мүмкіндік берді. Оқыту процесін тұрақтандыру үшін пиксель жарықтығының мәндері 0–1 аралығында қалыпқа келтірілді. Сонымен қатар, оқыту жиынтығының орташа мәні мен стандартты ауытқуына қатысты стандарттау жүргізілді. Кескіндердегі сандық шумды азайту үшін Гаусс сүзгісі қолданылды (1):

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (1)$$

мұндағы: x, y – орталық пиксельден көлденең және тік бағыттағы қашықтық;

σ – бұлыңғырлық дәрежесін анықтайтын орташа квадраттық ауытқу;

e – Эйлер саны.

Бұл сүзгі жарықтық шуларын азайтып, сүйек құрылымдарының негізгі контурларын сақтауға мүмкіндік береді.

Сүйек құрылымдарының локальды контрастын күшейту үшін CLAHE (Contrast Limited Adaptive Histogram Equalization) әдісі қолданылды. Бұл тәсіл трабекулярлық құрылымдардың айқындылығын арттырып, модельдің ұсақ морфологиялық ерекшеліктерді тиімдірек анықтауына мүмкіндік береді.

Сонымен қатар, модельдердің жалпылану қабілетін арттыру және қайта оқытылу қаупін азайту мақсатында кескіндерді аугментациялау әдістері пайдаланылды:

– ауытқуды модельдеу үшін $\pm 15^\circ$ шегінде кескінді бұру;

– 0.9-1.1 ауқымында масштабтау;

– көлденең және тігінен ауытқуы 10 % дейін ығыстыру;

– анатомиялық құрылымдардың симметриясын есепке алу үшін көлденең шағылысу.

Кескін пішінін өзгерткеннен кейін олардың жарықтығы мен контрастын реттейді, осылайша нейрондық желі патологияларды тануды үйренеді. Кескіндердің алдын ала өңдеуге дейінгі және кейінгі мысалдары 2-суретте көрсетілген.




2-сурет. Тізе буынының рентгендік кескіндерін өңдеу және күшейту мысалдары
Ескерту – авторлар құрастырған

Тізе буынының рентгендік кескіндерін, атап айтқанда конволюциялық нейрондық желілерді жіктеу үшін бірнеше терең оқыту архитектураларына салыстырмалы талдау жүргізілді. Бұл жұмыста классикалық архитектуралар VGG16, ResNet50 және Efficientnet, YOLOv8-cls заманауи модельдері қолданылды. Бұл модельдер үш классқа бейімделген: сау сүйек, остеопения және остеопороз.

VGG16 архитектурасы

VGG16 – 13 конволюциялық және 3 толық байланысқан қабаттан тұратын классикалық терең конволюциялық нейрондық желі. Архитектурада 3x3 өлшемді ядролар мен MaxPooling қабаттары қолданылып, белгілердің кеңістіктік өлшемдері біртіндеп азайтылады.

VGG16 архитектурасы медициналық кескіндердің текстуралық және морфологиялық ерекшеліктерін тиімді бөліп алу қабілетіне байланысты салыстырмалы талдау үшін пайдаланылды. VGG16 архитектурасы 3-суретте көрсетілген.




3-сурет. Үш классты жіктеуге бейімделген VGG16 архитектурасы
Ескерту – авторлар құрастырған

VGG16 архитектурасы қарапайым және тұрақты оқытуды қамтамасыз етеді. VGG16 медициналық кескіндердің текстуралық және құрылымдық белгілерін алу қабілетіне ие. Бұл жұмыста модельдерді салыстыру үшін VGG16 таңдалу себебі сүйек тілігінің морфологиялық өзгерістерін талдауға мүмкіндік беруі.

ResNet-50 архитектурасы

ResNet-50 терең конволюциялық нейрондық желіге жатады және құрамында 50 қабат бар. Кескіннің бастапқы сипаттамаларын сақтайтын талдаудың терең кезеңдерінде қалдық оқыту принципін қолданады, бұл әсіресе медициналық кескіндер үшін өте маңызды. ResNet-50 архитектурасы 4-суретте көрсетілген.




4-сурет. Көпкласты модельге арналған ResNet-50 архитектурасы

Ескерту – авторлар құрастырған

Бұл жұмыста ImageNet көрсеткіші бар алдын-ала дайындалған ResNet-50 моделі қолданылды. 1000 сыныпты жіктеуге арналған бастапқы толық байланысқан қабат Softmax белсендірілген үш нейроннан тұратын жаңа үш класты қабатпен өзгертілді. Қайта оқытудың алдын алу үшін жіктеу қабатының алдында жаһандық орташа мән (Global Average Pooling) қолданылды.

EfficientNet-B0 / B1 архитектурасы

Қабат тереңдігі ұлғайған сайын қуат өсетін дәстүрлі әдістерден айырмашылығы, EfficientNet B0/B1 инновациялық теңдестірілген масштабтау әдісін пайдаланады. Архитектурасы 5-суретте көрсетілген.




5-сурет. Көпкласты модельге арналған EfficientNet B0/B1 архитектурасы

Ескерту – авторлар құрастырған

EfficientNet-B0/B1 есептеу күрделілігі төмен болған кезде белгілерді тиімді шығаруды қамтамасыз ететін блоктарды пайдаланады және ақпараттық белгілерді күшейтетін механизмді қолданады. Бұл модельде артық оқу қаупін көбейтетін артық қабаттар жоқ.

YOLOv8cls архитектурасы

YOLOv8-cls — классификация міндеттеріне бейімделген заманауи терең оқыту архитектурасы. Модель жоғары есептеу жылдамдығымен қатар күрделі белгілерді тиімді тану қабілетіне ие. YOLOv8-cls архитектурасы жеңілдетілген классификациялық head қолдану арқылы real-time жіктеу міндеттерінде перспективалы тәсілдердің бірі болып табылады. Архитектура 6-суретте көрсетілген.



6-сурет. Көпкласты модельге арналған YOLOv8 архитектурасы

Ескерту – авторлар құрастырған

Иерархиялық тәсіл

Әдеби шолуда көптеген модельдер жақын класстарда тану қателіктерін көрсетеді. Мысалы, остеопения мен остеопороз өте тығыз текстуралық белгілерге ие. Бір сатылы көпкласты жіктеу кезінде остеопения мен остеопороз арасындағы визуалды ұқсастық класаралық шатасудың негізгі себептерінің бірі болып табылады. Осы мәселені азайту мақсатында ResNet-50 архитектурасына негізделген екі сатылы иерархиялық тәсіл ұсынылды.

Бірінші кезеңде модель кескіндерді екі негізгі класқа бөледі: «Healthy» және «Disease». Екінші кезеңде патологиялық кескіндер қосымша түрде Osteopenia және Osteoporosis кластарына жіктеледі. Мұндай тәсіл диагностикалық процесті кезең-кезеңімен ұйымдастырып, жақын класстар арасындағы қателіктер ықтималдығын азайтуға мүмкіндік береді.

Иерархиялық тәсіл клиникалық тұрғыдан ұқсас рентгенологиялық белгілерге ие остеопения мен остеопороз арасындағы класаралық шатасуды төмендетуге бағытталған.

Барлық модельдерді оқыту кезінде batch size = 8 параметрі қолданылды. Модельдер архитектура ерекшеліктеріне байланысты 7-30 эпоха аралығында оқытылды. Оқыту барысында Adam оптимизаторы және categorical cross-entropy шығын функциясы

пайдаланылды. Бастапқы learning rate мәні 1×10^{-4} ретінде орнатылды. Қайта оқытудың алдын алу және оқыту процесін тұрақтандыру мақсатында EarlyStopping және ReduceLROnPlateau callback әдістері қолданылды.

Бағалау көрсеткіштері

Құрылған жіктеуіштердің сапасын бағалау маңызды. Жіктеу сапасын бағалау үшін Accuracy (дұрыстығы), Precision (дәлдігі) және Recall (толықтығы) және басқа көрсеткіштер қолданылады. Accuracy-класс дұрыс анықталған объектілердің үлесі. Accuracy келесі формула бойынша есептеледі (2):

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

мұндағы: TP (True Positive) – модель дұрыс жіктеген белгілі бір класқа тиесілі кескіндер саны;

TN (True Negative) – модель дұрыс түрде басқа кластарға жатқызған кескіндер саны;

FP (False Positive) – басқа класқа тиесілі болғанымен, қате түрде қарастырылып отырған класқа жатқызылған кескіндер саны;

FN (False Negative) – қарастырылып отырған класқа тиесілі болғанымен, модель тарапынан басқа класқа қате жатқызылған кескіндер саны.

Модельдің тиімділігін бағалау үшін қолданылатын көрсеткіштер (3)–(5) теңдеулерінде келтірілген.

$$\text{Precision}(P) = \frac{TP}{TP + FP} \quad (3)$$

$$\text{Recall}(R) = \frac{TP}{TP + FN} \quad (4)$$


$$F1 = 2 \frac{P \cdot R}{P + R} \quad (5)$$

Жіктеу сапасын талдау үшін precision, recall және F1-score көрсеткіштері де қолданылды, олар әр сынып үшін бөлек есептеледі. Precision белгілі бір класқа жатқызылғандардың барлығында дұрыс танылған суреттердің пайызын көрсетеді. Жіктеу нәтижелерін көрнекі түсіндіру үшін қате матрицасы қолданылды.

НӘТИЖЕЛЕР ЖӘНЕ ОЛАРДЫ ТАЛҚЫЛАУ

Эксперименттер Python бағдарламалау тілі мен TensorFlow кітапханалары (Keras) арқылы жүзеге асырылды. YOLOv8 модельдерін жүзеге асыру үшін ultralytics кітапханасы пайдаланылды. Оқыту Intel Core i5 (12th Gen) процессоры және 16 Гбайт жедел жады бар дербес компьютерде, сондай-ақ есептеулерді жеделдету үшін GPU қолдайтын Google colab ортасында жүргізілді.

7-11 суреттерде жиналған деректер жиынында көпкласты жіктеу үшін оқытылған модельдердің жұмыс нәтижелерін ұсынады. Суреттерде тізе рентгенографиясын жіктеу үшін әртүрлі терең оқыту модельдерінің өнімділігі көрсетілген. Бұл VGG-16, ResNet50, EfficientNet-B0/B1, YOLOv8cls модельдері, сонымен қатар екі кезеңнен тұратын иерархиялық тәсіл. VGG16 моделінің оқыту нәтижелері 7-суретте көрсетілген.




7-сурет. Оқыту қисықтары: жоғалту және дәлдік функциялары

Ескерту – авторлар құрастырған

VGG-16 оқыту барысында оқыту және валидация дәлдігінің біртіндеп өсуі байқалды. Дәлдік қисықтары жақын орналасқан, бұл қайта оқытудың жоқтығын айқын көрсетеді. Сонымен қатар, жоғалту функциясының төмендеуі модельдің деректердегі негізгі құрылымдық белгілерді тиімді үйренгенін дәлелдейді. Бірақ модель остеопения мен остеопороз арасындағы ұқсас рентгенологиялық белгілерді ажыратуда шектеулі нәтижелер көрсетті.

ResNet50 моделінің оқыту нәтижелері 8-суретте көрсетілген.




8-сурет. Оқыту қисықтары: жоғалту және дәлдік функциялары

Ескерту – авторлар құрастырған

ResNet50 моделін оқыту кезінде оқу дәлдігінің біртіндеп өсуін байқауға болады. Валидация дәлдігі 0.56-0.68 диапазонында өзгереді, бірақ жекелеген дәуірлерде жергілікті күрт төмендеулер бар. Шығындар функциясы жаттығу шығындарының 1.25-тен 0.83-ке дейін және валидациялық шығындардың 1.01-ден 0.76-ға дейін тұрақты төмендеуін көрсетеді, бұл оқу процесінің конвергенциясын растайды. Бұл жағдайда шығын қисықтары арасында алшақтық жоқ, бұл қайта оқытудың жоқтығын көрсетеді. ResNet-50 архитектурасы барлық модельдер арасында ең жоғары дәлдік пен F1-score көрсеткіштеріне

қол жеткізді. Residual байланыстарды пайдалану модельдің күрделі морфологиялық белгілерді тұрақты түрде үйренуіне мүмкіндік берді.

9-суретте EfficientNet-B0 жоғалту және дәлдік функцияларының қисықтары көрсетілген.




Сурет 9. Оқыту қисықтары: жоғалту және дәлдік функциялары

Ескерту – авторлар құрастырған

EfficientNet-B0 теңдестірілген жаттығулар мен валидация қисықтарымен тұрақты конвергенцияны көрсетеді, бұл айқын шамадан тыс сәйкестіксіз жақсы жалпылауды көрсетеді. Дегенмен, Osteopenia класы үшін кейбір жіктеу қателіктері сақталды, бұл остеопения мен остеопороз арасындағы визуалды ұқсастықпен түсіндіріледі.

10-суретте YOLOv8 жоғалту және дәлдік функцияларының қисықтары көрсетілген.



10-сурет. Оқыту қисықтары: жоғалту және дәлдік функциялары

Ескерту – авторлар құрастырған

Жаттығу және валидация YOLOv8 моделінде жоғалту функциялары жақын, бұл модельдің жақсы жалпылау қабілетін көрсетеді. Яғни, қайта даярлау жоқ, 75% валидация дәлдігі қолайлы, бірақ одан әрі жетілдіруді қажет етеді. YOLOv8-clс архитектурасы жоғары жылдамдықты классификацияға бейімделгенімен, медициналық кескіндердегі ұсақ құрылымдық айырмашылықтарды ажыратуда ResNet-50 және EfficientNet-B0 модельдерінен төмен нәтиже көрсетті.


Иерархиялық тәсіл нәтижелері

Тізе буынының рентгендік бейнелерін жіктеу сапасын жақсарту үшін кезең-кезеңмен шешім қабылдауға негізделген иерархиялық тәсіл жүзеге асырылды. Бұл тәсіл клиникалық

жақын жағдайлар, атап айтқанда остеопения мен остеопороз арасындағы класс аралық шатасуды азайтуға бағытталған, олар көбінесе рентгендік суреттерде ұқсас визуалды белгілерді көрсетеді.

Бірінші кезеңде модель кескіндерді «Normal» және «Disease» кластарына екілік жіктеуді үйренді. Бұл кезеңнің негізгі мақсаты қалыпты жағдайларды ерте кезеңде бөліп, кейінгі талдауды тек патологиялық өзгерістері бар кескіндерге бағыттау болды. Оқыту қисықтарын талдау барысында модельдің тұрақты конвергенциясы және айқын қайта оқытудың болмауы байқалды.

Екінші кезеңде тек «Disease» класына жатқызылған кескіндер Osteopenia және Osteoporosis кластарына жіктелді. Бұл кезеңде ResNet-50 архитектурасы қолданылды. Оқыту қисықтары 11 суретте көрсетілген.



11Сурет. Оқыту қисықтары: дәлдік функциялары

Ескерту – авторлар құрастырған


Екінші кезеңдегі дәлдік көрсеткіштері модельдің сүйек тінінің нәзік құрылымдық ерекшеліктеріне көбірек назар аударғанын көрсетті. Жалпы, иерархиялық тәсіл күрделі көпкласты тапсырманы бірнеше қарапайым ішкі міндеттерге бөлу арқылы диагностикалық интерпретацияны жақсартуға мүмкіндік берді.

Иерархиялық тәсілдің жалпы дәлдігі ең жақсы бірсатылы модельден төмен болғанымен, бұл әдіс остеопения мен остеопороз арасындағы шатасуды азайтуда тиімді нәтиже көрсетті. Бұл иерархиялық тәсілдің жалпы дәлдікті арттырудан гөрі клиникалық тұрғыдан маңызды класстар арасындағы қателіктерді төмендетуге бағытталғанын көрсетеді.

Қате матрицаларын талдау

Модельдердің жіктеу сапасын тереңірек бағалау мақсатында тәуелсіз тестілік жиынтықта ($n = 293$) қате матрицалары құрылды. Бұл деректер жиынтығы оқыту және валидация кезеңдерінде пайдаланылған жоқ. Көпкласты модельдердің қате матрицалары 12-суретте көрсетілген.

VGG16 моделі Osteoporosis класы үшін жоғары жіктеу дәлдігін көрсетті. Алайда негізгі қателіктер Osteopenia және Osteoporosis арасында байқалды, бұл олардың ұқсас рентгенологиялық белгілерімен түсіндіріледі. ResNet-50 моделінде Healthy және Osteopenia кластары арасындағы қателіктер байқалмады. Негізгі шатасу Osteopenia және Osteoporosis арасында орын алды. Бұл модель жалпы тұрақтылық пен класстар арасындағы тепе-теңдік бойынша ең жақсы нәтижелерді көрсетті.




12-сурет. Модельдердің қате матрицасы

Ескерту – авторлар құрастырған

EfficientNet-B0 моделі де тұрақты нәтижелер көрсетті, алайда Osteopenia класы үшін жіктеу қателіктері сақталды. YOLOv8-clс архитектурасы жоғары жылдамдықпен ерекшеленгенімен, дәлдік көрсеткіштері бойынша басқа модельдерден төмен нәтиже көрсетті.

Иерархиялық алгоритм остеопения мен остеопороз арасындағы шатасуды азайтты, остеопорозды анықтау үшін recall көрсеткішін 0.83-ке дейін арттырды. Иерархиялық моделінің қате матрицасы 13-суретте көрсетілген.



13-сурет. Иерархиялық моделінің қате матрицасы

Ескерту – авторлар құрастырған

Бұл нәтиже иерархиялық стратегияның клиникалық скрининг жағдайларында, әсіресе ауыр патологиялық жағдайларды өткізіп алмау маңызды болған кезде, перспективалы тәсіл бола алатынын көрсетеді.

1-кестеде патологияны анықтау модельдерін жан-жақты салыстырмалы бағалау жүргізілді. Барлық модельдер бір сынақ жиынтығында бағаланды (N = 293), бұл салыстырмалы талдаудың дұрыстығын қамтамасыз етеді.

1-кесте. Модельдерді салыстырмалы бағалау

Модельдер	Accuracy, %	Precision, %	Recall, %	F1-score, %	Ерекшеліктері
VGG16	75.4	78.3	75.4	75.7	Негізгі CNN, аралық класстарды ажыратуда шектелген
ResNet50	82.3	83.5	82.3	82.5	Ең жақсы метрикалық тепе-теңдік, жоғары тұрақтылық
EfficientNet-B0	77.1	79.0	77.1	77.4	Шағын архитектура, теңгерімсіздікке сезімтал
YOLOv8-cls	75.1	78.6	75.1	75.2	Жылдамдық үшін оңтайландырылған, төмен дәлдік
Hierarchical	75.0	77.0	75.0	75.0	Классаралық шатасуын азайтады, бірақ жалпы дәлдікті төмендетеді
<i>Ескерту – авторлар құрастырған</i>					

Салыстырмалы талдау нәтижелері бойынша ResNet-50 моделі ең жоғары нәтижелерді көрсетті. Модель 82.3 % ассигасу және 82.5 % F1-score көрсеткіштеріне қол жеткізіп, барлық архитектуралар арасында ең тұрақты нәтиже берді. EfficientNet-B0 моделі есептеу күрделілігі мен дәлдік арасындағы тиімді тепе-теңдікті көрсетті. YOLOv8-cls жоғары жылдамдықты қамтамасыз еткенімен, медициналық кескіндердегі күрделі белгілерді ажыратуда төменірек нәтижелер көрсетті. VGG16 архитектурасы салыстырмалы түрде тұрақты болғанымен, жақын кластар арасындағы шатасуды толық жоя алмады.

Иерархиялық тәсіл остеопения мен остеопороз арасындағы класаралық шатасуды азайтуға мүмкіндік берді. Бірақ жалпы дәлдік көрсеткішінің төмендеуі шешім қабылдау шектерін әрі қарай оңтайландыру қажеттігін көрсетеді. Мұндай тәсіл клиникалық скрининг жағдайларында маңызды болуы мүмкін, себебі ауыр патологиялық жағдайларды өткізіп алмау жалпы ассигасу көрсеткішінен маңыздырақ болып саналады. Бұл нәтиже иерархиялық модельдердің диагностикалық интерпретацияны жақсартуға және клиникалық шешім қабылдау логикасын кезең-кезеңмен ұйымдастыруға мүмкіндік беретінін көрсетеді.

Зерттеудің шектеулері

Зерттеудің бірқатар шектеулері бар. Біріншіден, пайдаланылған деректер жиынтығының көлемі (1947 кескін) терең нейрондық желілер үшін салыстырмалы түрде шектеулі болып табылады. Бұл модельдердің жалпылану қабілетіне әсер етуі мүмкін. Сонымен қатар, алынған нәтижелер кейбір әдебиеттерде келтірілген көрсеткіштерден төмен болды. Бұл, бір жағынан, көптеген зерттеулерде омыртқа немесе жамбас сүйектерінің КТ кескіндері пайдаланылса, осы жұмыста құрылымдық ерекшеліктері

күрделірек тізе буынының рентгенографиялық кескіндерінің қолданылуымен түсіндіріледі.

Екіншіден, деректер жиынтығында класстар арасындағы теңгерімсіздік байқалды, әсіресе остеопения класының көлемі басқа класстармен салыстырғанда аз болды. Мұндай теңгерімсіздік модельдің жиі кездесетін класстарға бейімделуіне себеп болуы мүмкін.

Сонымен қатар, зерттеуде сыртқы валидация жүргізілмеген, бұл нәтижелердің басқа популяциялар үшін жалпылануын шектеуі ықтимал. Болашақ зерттеулердің негізгі бағыттарының бірі ретінде авторлық КТ кескіндер деректер жиынтығын қалыптастыру және терең оқыту модельдерін көпорталықты клиникалық деректерде валидациялау қарастырылады. Бұл тәсіл модельдердің жалпылану қабілетін арттырып, олардың клиникалық практикада қолданылу мүмкіндігін кеңейтуге мүмкіндік береді.

ҚОРЫТЫНДЫ

Осы зерттеу аясында тізе буынының рентгенографиялық кескіндерін жіктеу міндеті үшін әртүрлі терең оқыту архитектураларына салыстырмалы талдау жүргізілді. Эксперименттік нәтижелер барлық қарастырылған модельдердің сүйек тініндегі құрылымдық өзгерістерге байланысты ақпараттық белгілерді тиімді бөліп алуға қабілетті екенін көрсетті. Алайда модельдер жіктеу дәлдігі, тұрақтылығы және класаралық шатасу деңгейі бойынша әртүрлі нәтижелер көрсетті.

Зерттеу нәтижелері бойынша ResNet-50 моделі ең жоғары сапа көрсеткіштеріне қол жеткізді және барлық класстар үшін precision, recall және F1-score метрикаларының ең теңгерімді мәндерін қамтамасыз етті. VGG16 және EfficientNet-B0 архитектуралары да қанағаттанарлық нәтижелер көрсетті, алайда Osteopenia класы үшін жіктеу тұрақтылығы төменірек болды. YOLOv8-cls моделі жоғары есептеу жылдамдығын қамтамасыз еткенімен, күрделі медициналық белгілерді ажыратуда басқа архитектуралардан төмен нәтиже көрсетті.

ResNet-50 архитектурасына негізделген иерархиялық тәсіл остеопения мен остеопороз арасындағы класаралық шатасуды азайтуға мүмкіндік берді. Дегенмен, бұл тәсіл жалпы ассигасу көрсеткішінің төмендеуімен қатар жүрді. Бұл нәтиже иерархиялық модельдердің клиникалық тұрғыдан маңызды қателіктерді азайтуда перспективалы екенін, бірақ шешім қабылдау шектерін әрі қарай оңтайландыру қажеттігін көрсетеді.

Жалпы алғанда, алынған нәтижелер остеопороз диагностикасын компьютерлік қолдау жүйелерінде терең конволюциялық нейрондық желілерді қолданудың тиімділігін растады. Болашақ зерттеулерде деректер жиынтығын кеңейту, көпорталықты сыртқы валидация жүргізу, клиникалық параметрлерді интеграциялау, сондай-ақ авторлық КТ кескіндер жиынтығын пайдалану жоспарлануда. Сонымен қатар, ансамбльдік және көпдеңгейлі модельдерді зерттеу диагностикалық дәлдікті әрі қарай арттыруға мүмкіндік беруі мүмкін.

МҮДДЕЛЕР ҚАЙШЫЛЫҒЫ: Автор(лар) мүдделер қайшылығы жоқ екенін мәлімдейді.

ҚАРЖЫЛАНДЫРУ: Бұл зерттеу сыртқы гранттық қаржыландырусыз орындалды.

ИНСТИТУЦИОНАЛДЫҚ ЭТИКА КОМИТЕТІНІҢ ҚОРЫТЫНДЫСЫ: Зерттеу ашық қолжетімді деректер жиынтығын пайдалану негізінде жүргізілді және адам қатысушылары мен жануарларға тікелей эксперименттік араласуды қамтымады. Осыған байланысты Институционалдық этика комитетінің (IRB) арнайы мақұлдауы талап етілмеді.

ЕРІКТІ КЕЛІСІМ ТУРАЛЫ МӘЛІМДЕМЕ: Бұл зерттеуде адам қатысушылары тікелей тартылмағандықтан, ерікті келісім алу талап етілмеді.

ДЕРЕКТЕРДІҢ ҚОЛЖЕТІМДІЛІГІ ТУРАЛЫ МӘЛІМДЕМЕ: Осы зерттеуде пайдаланылған деректер ашық қолжетімді Kaggle платформасынан алынды. Зерттеу нәтижелерін растайтын өңделген деректер мен эксперименттік нәтижелер тиісті сұраныс бойынша жауапты автордан алынуы мүмкін.

АЛҒЫС БІЛДІРУ: Авторлар мақаланы дайындау барысында құнды ұсыныстар мен сын-пікірлер берген рецензенттерге алғыс білдіреді. Сондай-ақ, зерттеу жұмысының ғылыми және әдістемелік сапасын арттыруға қолдау көрсеткен әріптестерге ризашылықтарын білдіреді.

ЖАСАНДЫ ИНТЕЛЛЕКТ ТЕХНОЛОГИЯЛАРЫН ПАЙДАЛАНУ ТУРАЛЫ ХАБАРЛАМА: Авторлар қолжазбаны дайындау барысында генеративті жасанды интеллект құралдарын әдебиеттер тізімін APA 7 стандартына сәйкес форматтау мақсатында пайдаланды. Жасанды интеллект ғылыми нәтижелерді интерпретациялау, қорытынды жасау немесе зерттеу нәтижелерін қалыптастыру үшін қолданылған жоқ.

ӘДЕБИЕТТЕР ТІЗІМІ

- Adarve-Castro, A., Soria-Utrilla, V., Castro-García, J. M., Domínguez-Pinos, M. D., Sendra-Portero, F., Ruiz-Gómez, M. J., & Algarra-García, J. (2025). Advanced radiomic prediction of osteoporosis in primary hyperparathyroidism: A machine learning-based analysis of CT images. *Radiologia Medica*. <https://doi.org/10.1007/s11547-025-02004-z>
- Du, C., He, J., Zhang, J., Wang, J., & Li, G. (2025). Automated opportunistic screening for osteoporosis using deep learning-based automatic segmentation and radiomics on proximal femur images from low-dose abdominal CT. *BMC Musculoskeletal Disorders*, 26(1), 378. <https://doi.org/10.1186/s12891-025-08631-x>
- Dzierżak, R., & Omiotek, Z. (2022). Application of deep convolutional neural networks in the diagnosis of osteoporosis. *Sensors*, 22(21), 8189. <https://doi.org/10.3390/s22218189>
- Jang, R., Choi, J. H., Kim, N., Chang, J. S., Yoon, P. W., & Kim, C.-H. (2021). Prediction of osteoporosis from simple hip radiography using deep learning algorithm. *Scientific Reports*, 11, 19997. <https://doi.org/10.1038/s41598-021-99549-6>
- Kaggle. (2024). Knee osteoporosis dataset. <https://www.kaggle.com/datasets/-/866059b7930a5c49cd77d94c1761840a19d88074cad74e8f0e0cfa2b236a6904>
- Lim, H.K., Ha, H.I., Park, S.-Y., & Han, J. (2021). Prediction of femoral osteoporosis using machine-learning analysis with radiomics features and abdomen-pelvic CT: A retrospective single center preliminary study. *PLoS ONE*, 16, e0247330. <https://doi.org/10.1371/journal.pone.0247330>
- Liu, L., Si, M., Ma, H., Cong, M., Xu, Q., Sun, Q., Wu, W., Wang, C., Fagan, M. J., Mur, L. A. J., et al. (2022). A hierarchical opportunistic screening model for osteoporosis using machine learning applied to clinical data and CT images. *BMC Bioinformatics*, 23, 63. <https://doi.org/10.1186/s12859-022-04596-z>
- Liu, Z., Li, Y., Zhang, C., Xu, H., Zhao, J., Huang, C., Chen, X., & Ren, Q. (2025). Radiomics and machine learning for osteoporosis detection using abdominal computed tomography: A retrospective multicenter study. *BMC Medical Imaging*, 25(1), 235. <https://doi.org/10.1186/s12880-025-01743-9>
- Madiyeva, M., Rymbayeva, T., Kaskabayeva, A., Bersimbekova, G., Kanapiyanova, G., Prilutskaya, M., Akhmetzhanova, D., Alimbayeva, A., & Omarov, N. (2024). The prevalence and risk factors of low bone mineral density in the population of the Abay region of Kazakhstan. *International Journal of Environmental Research and Public Health*, 21, 681. <https://doi.org/10.3390/ijerph21060681>
- Naguib, S. M., Saleh, M. K., Hamza, H. M., Hosny, K. M., & Kassem, M. A. (2024). A new superfluity deep learning model for detecting knee osteoporosis and osteopenia in X-ray images. *Scientific Reports*, 14, 25434. <https://doi.org/10.1038/s41598-024-75549-0>

- Pan, J., Lin, P. C., Gong, S. C., Wang, Z., Cao, R., Lv, Y., Zhang, K., & Wang, L. (2024). Feasibility study of opportunistic osteoporosis screening on chest CT using a multi-feature fusion DCNN model. *Archives of Osteoporosis*, 19(1), 98. <https://doi.org/10.1007/s11657-024-01455-7>
- Pan, Y., Shi, D., Wang, H., Chen, T., Cui, D., Cheng, X., & Lu, Y. (2020). Automatic opportunistic osteoporosis screening using low-dose chest computed tomography scans obtained for lung cancer screening. *European Radiology*, 30(7), 4107–4116. <https://doi.org/10.1007/s00330-020-06679-y>
- Park, H., Kang, W. Y., Woo, O. H., Lee, J., Yang, Z., & Oh, S. (2024). Automated deep learning-based bone mineral density assessment for opportunistic osteoporosis screening using various CT protocols with multi-vendor scanners. *Scientific Reports*, 14, 18712. <https://doi.org/10.1038/s41598-024-73709-w>
- Pickhardt, P. J., Nguyen, T., Perez, A. A., Graffy, P. M., Jang, S., Summers, R. M., & Garrett, J. W. (2022). Improved CT-based osteoporosis assessment with a fully automated deep learning tool. *Radiology: Artificial Intelligence*, 4(5), e220042. <https://doi.org/10.1148/ryai.220042>
- Salari, N., Ghasemi, H., Mohammadi, L., Behzadi, M. H., Rabieenia, E., Shohaimi, S., & Mohammadi, M. (2021). The global prevalence of osteoporosis in the world: A comprehensive systematic review and meta-analysis. *Journal of Orthopaedic Surgery and Research*, 16, 609. <https://doi.org/10.1186/s13018-021-02772-0>
- Saravi, B., Zink, A., Tabukashvili, E., Güzel, H. E., Ülkümen, S., Couillard-Despres, S., Lang, G. M., & Hassel, F. (2024). Integrating radiomics with clinical data for enhanced prediction of vertebral fracture risk. *Frontiers in Bioengineering and Biotechnology*, 12, 1485364. <https://doi.org/10.3389/fbioe.2024.1485364>
- Sebro, R., & De la Garza-Ramos, C. (2022). Machine learning for opportunistic screening for osteoporosis from CT scans of the wrist and forearm. *Diagnostics*, 12, 691. <https://doi.org/10.3390/diagnostics12030691>
- Siddharth, M., Arora, G., & Vani, M. P. (2025). Predictive modelling of knee osteoporosis. *BMC Research Notes*, 18, 114. <https://doi.org/10.1186/s13104-025-07125-2>
- Wang, J., He, Y., Yan, L., Chen, S., & Zhang, K. (2024). Predicting osteoporosis and osteopenia by fusing deep transfer learning features and classical radiomics features based on single-source dual-energy CT imaging. *Academic Radiology*. <https://doi.org/10.1016/j.acra.2024.04.022>
- Yuan, J., Li, B., Zhang, C., Wang, J., Huang, B., & Ma, L. (2025). Machine learning-based CT radiomics model to predict the risk of hip fragility fracture. *Academic Radiology*, 32(5), 2854–2862. <https://doi.org/10.1016/j.acra.2025.01.023>
- Zhang, K., Lin, P., Pan, J., Xu, P., Qiu, X., Crookes, D., Hua, L., & Wang, L. (2023). End-to-end multitask joint learning model for osteoporosis classification in CT images. *Computational Intelligence and Neuroscience*, 3018320. <https://doi.org/10.1155/2023/3018320>
- Шарманов, Т.Ш., Шакиева, Р.А., & Сулейменова, Д.С. (2012). Распространенность остеопороза среди населения старших возрастных групп по данным сонографических скрининговых исследований в Республике Казахстан. *Медицина*, 3, 2–5. // Sharmanov, T. Sh., Shakiyeva, R. A., & Suleymenova, D. S. (2012). Rasprostranennost osteoporoza sredi naseleniya starshikh vozrastnykh grupp po dannym sonograficheskikh skринingovykh issledovaniy v Respublike Kazakhstan [Prevalence of osteoporosis among older population groups according to sonographic screening studies in the Republic of Kazakhstan]. *Meditsina*, 3, 2–5. (In Russ.)
- Турекулова, А. А. (2008). Медико-социальные аспекты остеопороза у городского населения [Автореферат диссертации]. Алматы. // Turekulova, A. A. (2008). Mediko-sotsialnye aspekty osteoporoza u gorodskogo naseleniya [Medical and social aspects of osteoporosis among urban population] [Dissertation abstract]. Almaty. (In Russ.)

Google. (2026). Ғылыми әдебиеттер тізімін APA 7 стандартына сәйкес форматтау бойынша көмек [Үлкен тілдік үлгі]. Gemini. <https://gemini.google.com/>

Авторлар туралы мәліметтер
Информация об авторах
Information about authors



Нурекенова Арайлым Солтахановна – «Ақпараттық жүйелер» мамандығының докторанты, Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен қ., Қазақстан
Нурекенова Арайлым Солтахановна – докторант по специальности

«Информационные системы», Восточно-Казахстанский технический университет им. Д. Серикбаева, г. Усть-Каменогорск, Казахстан

Nurekenova Arailym Soltahanovna – PhD student in Information Systems, East Kazakhstan Technical University named after D. Serikbaev, Ust-Kamenogorsk, Kazakhstan,
e-mail: soltahanovna@gmail.com,
ORCID: <https://orcid.org/0009-0003-9873-2911>



Құмарғажанова Сәуле Құмарғажанқызы – т.ғ.к., профессор, Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен қ., Қазақстан

Кумаргажанова Сауле Кумаргажановна – кандидат технических наук, профессор, Восточно-Казахстанский технический университет им. Д. Серикбаева, г. Усть-Каменогорск, Казахстан

Kumargazhanova Saule – Candidate of Technical Sciences, Professor, East Kazakhstan Technical University named after D. Serikbaev, Ust-Kamenogorsk, Kazakhstan
e-mail: skumargazhanova@gmail.com,
ORCID: <https://orcid.org/0000-0002-6744-4023>



Смаилова Сауле Сансызбаевна – PhD, қауымдастырылған профессор, Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен қ., Қазақстан

Смаилова Сауле Сансызбаевна – PhD, ассоциированный профессор, Восточно-Казахстанский технический университет им. Д. Серикбаева, г. Усть-Каменогорск, Казахстан

Smailova Saule – PhD, Associate Professor, East Kazakhstan Technical University named after D. Serikbaev, Ust-Kamenogorsk, Kazakhstan
e-mail: ssmailova@edu.ektu.kz,
ORCID: <https://orcid.org/0000-0002-8411-3584>



Dzierżak Róża – PhD, доцент,
Люблин техникалық университеті, Люблин қ., Польша
Dzierżak Róża – PhD, доцент,
Люблинский технический университет, г. Люблин, Польша
Dzierżak Róża – PhD, Associate Professor,
Lublin University of Technology, Lublin, Poland
e-mail: r.dzierzak@pollub.pl,
ORCID: <https://orcid.org/0000-0001-5640-0204>



Нурсадыкова Роза Канашевна – аға оқытушы, Д. Серікбаев
атындағы Шығыс Қазақстан техникалық университеті, Өскемен қ.,
Қазақстан
Нурсадыкова Роза Канашевна – старший преподаватель,
Восточно-Казakhstanский технический университет имени
Д. Серикбаева, г. Усть-Каменогорск
Nursadykova Roza – Senior Lecturer, East Kazakhstan
Technical University named after D. Serikbaev, Ust-Kamenogorsk,
Kazakhstan
e-mail: RNursadykova@ektu.kz,
ORCID: <https://orcid.org/0009-0005-9595-6826>