

Б.С. Омаров¹, И.Е. Базаркулова^{1*}

¹Әл-Фараби атындағы Қазақ Ұлттық университеті, Алматы қ., Қазақстан
*e-mail: inkarbaza@gmail.com

ТЕРЕҢ ОҚЫТУ КӨМЕГІМЕН ПНЕВМОНИЯНЫ АНЫҚТАУ МОДЕЛІН ҚҰРУ

Аңдатпа

Дүниежүзілік денсаулық сақтау ұйымының бағалауы бойынша жыл сайын төрт миллионнан астам өлім пневмония мен ауаның ластануымен байланысты басқа аурулардың салдарынан болады және соңғы Covid-19 вирусы пневмония ауруының таралу пайызын күрт өсірді. Сондай-ақ, дамушы елдерде де, дамыған елдерде де радиологтардың жетіспеушілігі байқалады. Қазіргі уақытта жасанды интеллект және машиналық оқыту технологияларын дамыту, сондай-ақ медициналық кескіндердің үлкен көлемін жинақтау медициналық кескіндерді автоматты талдау жүйелерін құруға мүмкіндік береді. Мақалада терең оқыту әдістеріне (конволюциялық нейрондық желілер) негізделген, пневмонияны анықтауға көмектесетін қарапайым модель ұсынылған. Модель үшін Гуанчжоудағы әйелдер мен балалар медициналық орталығының рентгендік суреттері пайдаланылды. Нейрондық желіні оқыту 26 мин уақытты қажет етті. Тесттік деректерде алынған нәтижелер: recall – 96%, precision – 92%, accuracy – 92%, f1 – 94%. Бұл көптеген танымал жұмыстардағы көрсеткіштерден кем емес. Модель рентгенологтарға жүктемені едәуір азайтады, шешім қабылдауға және уақыт үнемдеуге көмектеседі, олардың жұмысының сапасын бағалауға және медициналық қателіктердің ықтималдығын азайтуға мүмкіндік береді.

Түйін сөздер: нейрондық желі, терең оқыту, пневмония, медицина, рентгендік суреттер, машиналық оқыту.

Аннотация

Б.С. Омаров¹, И.Е. Базаркулова¹

¹Казахский национальный университет им. аль-Фараби, г. Алматы, Казахстан

ПОСТРОЕНИЕ МОДЕЛИ ДЛЯ ВЫЯВЛЕНИЯ ПНЕВМОНИИ С ПОМОЩЬЮ ГЛУБОКОГО ОБУЧЕНИЯ

По оценкам Всемирной Организации Здравоохранения, более четырех миллионов смертей ежегодно происходят из-за пневмонии и других заболеваний, связанных с загрязнением воздуха, и последний вирус Covid-19 резко увеличил процент распространения пневмонии. Также отмечается нехватка радиологов как в развивающихся, так и в развитых странах. В настоящее время развитие технологий искусственного интеллекта и машинного обучения, а также накопление большого объема медицинских изображений позволяют создавать системы автоматического анализа медицинских изображений. В статье представлена простая модель, основанная на методах глубокого обучения (сверточные нейронные сети), помогающая выявить пневмонию. Для модели были использованы рентгеновские снимки женского и детского медицинского центра в Гуанчжоу. Обучение нейронной сети заняло 26 минут. Результаты, полученные в тестовых данных: recall – 96%, precision – 92%, accuracy – 92%, f1 – 94%. Модель значительно снижает нагрузку на рентгенологов, помогает принимать решения и экономить время, позволяет оценить качество их работы и снизить вероятность врачебных ошибок.

Ключевые слова: нейронная сеть, глубокое обучение, пневмония, медицина, рентгеновские снимки.

Abstract

BUILDING A MODEL FOR DETECTING PNEUMONIA USING DEEP LEARNING

Omarov B.S.¹, Bazarkulova I.E.¹

¹al-Farabi Kazakh National University, Almaty, Kazakhstan

The World Health Organization estimates that more than four million deaths occur annually due to pneumonia and other diseases associated with air pollution, and the latest Covid-19 virus has dramatically increased the percentage of pneumonia cases. There's also a global shortage of radiologists. Currently, the development of artificial intelligence and machine learning technologies, as well as the accumulation of large volumes of medical images, make it possible to create automated systems for analyzing medical images. The article presents a simple model based on deep learning methods (convolutional neural networks) that helps detect pneumonia. X-ray images of the women's and children's Medical Center in Guangzhou were used for the model. Training the neural network took 26 minutes. The results obtained in the test data are: recall – 96%, precision – 92%, accuracy – 92%, f1 – 94%. This is no less than the results in many popular works.

The model significantly reduces the burden on radiologists, helps them make decisions and save time, allows to evaluate the quality of their work and reduce the likelihood of medical errors.


Keywords: neural network, deep learning, pneumonia, medicine, X-ray images.

Кіріспе

Пневмония – төменгі тыныс жолдарының өткір инфекциялы ауруы, өкпенің қабынуы. Дүниежүзілік денсаулық сақтау ұйымының (WHO) бағалауы бойынша жыл сайын төрт миллионнан астам өлім пневмония мен ауаның ластануымен байланысты басқа аурулардың салдарынан болады Ошибка! Источник ссылки не найден.. Дәл диагноз қою үшін немесе ерте кезеңдерде аурулардың барын тексеру үшін науқасқа рентген суреті, компьютерлік томография, т.б. сәулелік және функционалдық сынақтар тағайындалады.

Жылына бір рентгенологқа мыңдаған рентгендік суреттен келеді. Халық аз қоныстанған жерлерде (дамушы елдерде де, дамыған елдерде де) радиолог мамандардың тапшылығы байқалады. 2015 жылы Руандада 12 миллион адамға бар болғаны 11 радиолог қызмет көрсетті, ал төрт миллион халқы бар Либерия елінде тек екі радиолог болды Ошибка! Источник ссылки не найден.. Сонымен қатар, пневмония - бұл жоғары қауіпті ауру, әсіресе дамушы елдерде миллиондаған адамдар кедейленіп, медициналық мекемелерге қол жеткізе алмайды. Ірі қалалардағы ауруханаларда дәрігерлерге үлкен жүктеме түседі, соның салдарынан кездейсоқ қателіктер талдау сапасын төмендетуі мүмкін. Тіпті өте кәсіби және тәжірибелі дәрігерлер үшін де, рентгендік суреттер арқылы пневмонияны диагностикалау әлі де үлкен міндет болып табылады, өйткені рентгендік кескіндер әртүрлі аурулар, мысалы, өкпе обыры үшін ұқсас аймақ ақпаратына ие. Сондықтан пневмонияны дәстүрлі әдістер арқылы диагностикалау өте көп уақытты және энергияны қажет етеді және стандартталған процесс арқылы пациенттің пневмониямен ауыратынын анықтау мүмкін емес.

Пневмония қарт адамдарға, стационардағы вентиляторға жатқызылған науқастарға және астмамен ауыратын науқастардың өміріне үлкен қауіп төндіреді. Пневмониямен ауырғандардың көп бөлігін (45%) бес жасқа дейінгі балалар құрайды. Пневмониядан жылына бес жасқа дейінгі 800 000-нан астам баланы өлтіреді, күн сайын 2200-ге жуық бала қайтыс болады. 100 000 балаға шаққанда пневмониямен ауыратын 1400-ден астам бала бар. Жалпы әлем бойынша өлім санын көрсетілген статистика [3] (1-суретте берілген).



Сурет 1. 1990-2019 жылдар аралығында әлем бойынша пневмония салдарынан өлім саны динамикасы және жас топтары бойынша қатынасы [3].

Сондай-ақ негізгі белгісі өкпе пневмониясы болып табылатын COVID-19 ауруының кенеттен өршуі және бақылаусыз таралуы бүгінгі күннің ең маңызды жаһандық проблемаларының бірі болған еді. COVID-19 – бұл коронавирус тобындағы SARS-CoV-2 вирусы тудыратын өте жұқпалы сипаттағы тез таралатын ауру. 2020 жылдың қаңтар айының соңында Дүниежүзілік денсаулық сақтау ұйымы (WHO) жаһандық денсаулық сақтау саласындағы төтенше жағдайды және бір жарым айдан кейін пандемия деп жариялады. 2020 жылдың 25 қыркүйегіне дейін 32 110 656 расталған жағдай және 980 031 өлім құжатталды. Қоғамдық денсаулық сақтау тұрғысынан, тиісті дәрі-дәрмектердің болмауына

байланысты COVID-19-ны ерте анықтау және пациенттерді оқшаулау өте маңызды болды. Қол жетімді ресурстар шектеулі болғандықтан, ауруханалар пациенттердің экспоненциалды түрде өсуі байқалған болатын. Жұмыста ұсынылған 22 қабатты конволюциялық нейронды желілерге негізделген модель кіріске кеуде қуысының рентгендік суретін алып, аз уақытта өкпеде пневмония бар-жоғын анықтап береді. Тестілік деректерде жіктеу дәлдігі – 92,3%, recall – 96% болды. Бұл берілген зерттеу облысында ұсынған басқа авторлардың дәстүрлі машиналық оқыту әдістерімен алған нәтижелерінен анағұрлым жоғары. Болашақта осы модель арқылы пневмонияны медициналық кескіндерден автоматты түрде анықтау радиологтарға шешім қабылдауға және уақыт үнемдеуге көмектесетін болады, қызмет көрсету сапасын анағұрлым арттырады. Сондай-ақ диагностикалық бейнелеу мамандарына қол жетімділігі төмен халыққа медициналық көмек көрсету үшін баға жетпес маңызға ие.

1 Материал және Әдістер

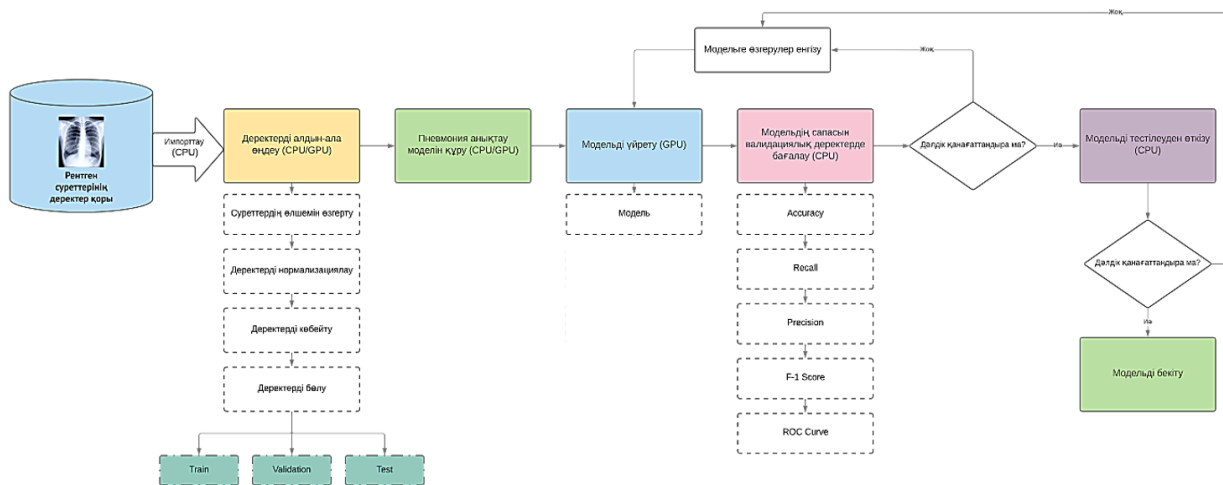
Жасанды интеллект және машиналық оқыту технологияларын дамыту, сондай-ақ медициналық кескіндердің үлкен көлемін жинақтау медицина саласында автоматты талдау жүйелерін құруға мүмкіндік береді. CNN (конволюциялық нейрондық желілерге) негізделген терең оқыту алгоритмдері медициналық кескіндерді жіктеу үшін стандартты таңдау болып табылады, дегенмен заманауи әдістер сынақ және қателік жүйесіндей бекітілген желілік архитектураны құрайды. U-Net, SegNet және CardiacNet кескінді медициналық тексеруге арналған көрнекті архитектуралардың бірі болып табылады. Соңғы жылдары кеуде қуысының рентгендік суреттерін пайдалана отырып, пневмонияны анықтаудың қысқаша процесін сипаттайтын бірнеше әдістер, әсіресе терең оқыту әдістері енгізілді. Deep Learning әсіресе медициналық бейнелеу [4], кескінді сегментациялау [5, 6] және кескінді қайта құру [7, 8] саласында компьютерлік диагностика технологиясының (CAD) өнімділігін жақсарту үшін сәтті қолданылды. 2017 жылы Раджпуркар және т.б. [9] пневмония диагностикасын жеделдету үшін 121 қабатты CNN моделі болған DenseNet-121 [10] деп аталатын классикалық терең оқыту желісін ұсынды. Тәжірибелі дәрігерлерден айырмашылығы, жоғарырақ F1 ұпайын алды.

Оқыту кезінде оңтайлы желі гиперпараметрлерін табу үшін эволюциялық негізделген алгоритмдер және күшейтілген оқыту (RL) сияқты модельдер енгізілген. Дегенмен, бұл әдістер есептеу тұрғысынан қымбат және көп қуат жұмсайды. Балама ретінде бұл зерттеу пневмонияны анықтау мәселесін шешу үшін концептуалды қарапайым, бірақ тиімді желілік модельді ұсынады.

Модель құру процессінің негізгі қадамдары:

1. Деректерді импорттау;
2. Деректерді алдын-ала өңдеу (data preprocessing);
3. Модель архитектурасын құру;
4. Модельді жаттығу деректерінде оқыту;
5. Сапасын валидациялық деректерді бағалау;
6. Модельді тестілеуден өткізу.

Модель құру процесі 2-суреттегі диаграммада көрсетілген. Алдымен jpeg форматтағы жалпы өлшемі 1.16 ГБ рентгендік суреттер локальді компьютерге жүктеліп алынды.



Сурет 2. Модель құру процессінің диаграммасы

Берілген деректер жоғары деңгейде теңгерімсіз болғандықтан алдын ала өңдеуден өтті. Бұл қадам суреттердің өлшемін бірыңғай 150x150 өлшеміне келтіру, пиксель мәндерін нормализациялау (яғни 0-1 аралығына келтіру), деректерді бұру, жақындату алыстату арқылы көбейту, соңында train, test, validation жиындарына бөлуді қамтыды. Keras Sequential API көмегімен convolution, batch normalization, flatten, dropout, max pooling қабаттарынан құрылған тізбекті желі құрылды. Кейіннен алдын-ала өңделген деректер желі арқылы өткізіліп, валидациялық деректерде сапалық көрсеткіштері есептелді. Қойған мақсатымыз 90% дәлдіктен аспайынша модельге бірқатар өзгертулер енгізілді, соңғы нұсқасы төмендегі 1.2.2 бөлімінде ашып көрсетілген желі болды. Соңында ең жақсы нәтиже беретін желі салмақтары .h5 форматындағы файлға жазылып сақталды.

Сондай-ақ, 2-суретте әрбір негізгі кезеңдердің астында орталық не графикалық процессорда орындалуы және құрамдас процестер жайлы ақпарат берілген. Нейрондық желілер параллельдеуге қолайлы болғандықтан графикалық процессордағы есептеулер уақытты тиімді пайдалануға көп көмектеседі.

1.1 Қолданылған деректер


Модель үшін Гуанчжоудағы әйелдер мен балалар медициналық орталығының jpeg форматтағы 5863 рентгендік суреттен тұратын Kaggle сайысының деректер жинағы Ошибка! Источник ссылки не найден. пайдаланылды. Кеуде қуысының барлық рентгендік суреттері (алдыңғы-артқы) бір жастан бес жасқа дейінгі науқастардан алынды. Деректер жинағы 3 қалтаға (train, test, val) ұйымдастырылған және әрбір екі санатқа жіктелген (қалыпты/пневмония). Кеуде қуысының барлық рентгенографиясы пациенттердің күнделікті клиникалық күтімінің бөлігі ретінде орындалды. Кеуде қуысының рентгендік суреттерін талдау үшін барлық кеуде рентгенограммалары бастапқыда барлық төмен сапалы немесе оқылмайтын сканерлеулерді жою арқылы сапаны бақылау үшін скринингтен өтілген. Кескіндерге арналған диагноздарды үш сарапшы дәрігер бағалады.

Деректер теңгерімсіз болып келеді, себебі сау және пневмония жағдайындағы мысалдар қатынасы үлкен. Ол 3-суреттегі гистограммаларда көрсетілген.



Сурет 3. Әртүрлі деректер жинағындағы класс үлестірімдері.

Деректер жинағынан алынған таңдамалар мен белгілер 4-суретте көрсетілген.



Сурет 4. Класс үлгілерінен рандомды таңдамалар

1.2 Әдістер

1.2.1 Деректерді алдын-ала өңдеу

Кескінді тану мәселесі үшін оқу үлгісін қалыптастыру және реттеу процесі келесі қадамдарды қамтуы мүмкін: үлгіні құру әдісі, кескінді қажетті өлшемге дейін қысу, нормализациялау, фильтрлерді қолдану және т.б. Барлық қадамдарды орындау міндетті емес, керісінше, кейбір қадамдар мүлдем пайдаланылмауы мүмкін, ал басқалары бірнеше рет қайталануы мүмкін.

Масштабтау - кескіннің тік және көлденең өлшемін өзгерту. Масштабтаудың екі түрі бар:

- Пропорционалды - бұл жағдайда суреттің биіктігі мен ені арасындағы қатынас өзгермейді, бірақ жалпы өлшем өзгереді.

- Пропорционалды емес - бұл жағдайда екі өлшем де әртүрлі өзгереді.


Бұл жұмыста масштабтау кескіннің тік және көлденең өлшемін 150x150 пиксельге өзгертуден тұрды.

Деректерді аугментациялау. Оқытуға арналған деректер аз болғанда, шамадан тыс оқыту орын алады. Дерек жетіспеушілікті шешудің бір жолы – берілген өлшемге және өзгергіштікке дейін деректерді көбейту. Көбейту бастапқы деректерге түрлі трансформацияларды қолданумен тікелей байланысты. Бұл әдіс модель ендіден бастап көрмейтін уникалды кіріс экземплярлардың санын арттыруға көмектеседі. Бұл өз кезегінде тексерілетін деректерде жоғары дәлдікті алуға септігін тигізеді. Tensorflow.keras көмегімен берілген өзгертулер мен жана суреттерді генерациялауды ImageDataGenerator класы арқылы жүзеге асыра аламыз. Бұл үшін кескіндерге қолданғмыз келетін трансформацияларды параметр ретінде беру жеткілікті. Кескіндерді аугментациялау параметрлері 1-кестеде көрсетілген.

Кесте 1. Деректерді алдын-ала өңдеу параметрлері

Параметр	Мәні
<i>Resize</i>	150x150
<i>Normalization</i>	(0, 255) → (0, 1)
<i>Rotation Range</i>	0, 30
<i>Zoom Range</i>	0.2
<i>Width_Shift_Range</i>	0.1
<i>Height_Shift_Range</i>	0.1
<i>Horizontal_Flip</i>	False
<i>Vertical_Flip</i>	False


Мұнда горизонталь және вертикаль ауыстыруларға жалған мәнін (1-кестедегі соңғы екі жол) қоюдың себебі бар. Деректерді аугментация шынайы өмірге жақын болуы керек және зерттеліп отырған объектінің табиғатын өзгертпеуі қажет. Егерде кескіндерді толығымен қарама қарсыға ауыстырсақ ол рентгендік кескіндегі басқа органдардың орнының ауысуына алып келеді (5-сурет). Атап айтқанда, жүректің. Басқа ауруларды қоса зерттегенде бұл қате нәтиже беретін еді, себебі жүректің оң жақта орналасуы ауру болып табылады. Бұл әсіресе әртүрлі ауруды классификациялау мәселесінде қателіктер тудыруы мүмкін.



Сурет 5. Рентгендік суретті қарама-қарсы ауыстыру нәтижесі

1.2.2 Ұсынылған желі

Бұл жұмыста ұсынылған нейрондық желі моделінің архитектурасы 6-суретте келтірілген.



Сурет 6. Нейрондық желі архитектурасы

Жалпы параметрлер саны: 1 246 401

Жаттықтырылатын параметрлер саны: 1 245 313

Жаттықтырылмайтын параметрлер саны: 1 088

Keras Sequential API қолданылды. Біріншісі - *конволюциондық (Conv2D) қабат*. Бұл үйренуге болатын сүзгілер жиынтығы десе де болады. Бірінші conv2D қабаты үшін 32 фильтрді, келесі ек қабат үшін 64, және соңғы екі қабат үшін 128, 256 фильтрі орнатылды. Әрбір фильтр ядро фильтрі арқылы кескіннің (ядро өлшемімен анықталған) бір бөлігін түрлендіреді.

CNN осы түрлендірілген кескіндерден барлық кезде пайдалы қасиеттерді бөліп алады. CNN-дегі екінші маңызды деңгей - *біріктіру (MaxPool2D) қабаты*. Бұл қабат жай ғана кішірейту фильтрі ретінде әрекет етеді. Ол көрші 2 пиксельге қарап, максималды мәнді таңдайды. Олар есептеу шығындарын азайту үшін қолданылады және белгілі бір дәрежеде артық орнатуды азайтады. Конволюциялық және біріктіру қабатын біріктіре отырып, CNN жергілікті қасиеттерді біріктіріп, кескіннің көбірек глобальді қасиеттерін біле алады.

Dropout - әр жаттығу үлгісі үшін қабаттағы түйіндердің үлесі кездейсоқ еленбейтін (салмақтарын нөлге теңестіру арқылы) реттелетін әдіс. Бұл желі үлесін кездейсоқ түрде төмендетеді және желіні мүмкіндіктерді үлестірілген түрде үйренуге мәжбүр етеді. Бұл әдіс сонымен қатар жалпылауды жақсартады және шамадан тыс оқытуды азайтады. *'relu'* түзеткіш желіге сызықтық еместікті қосу үшін пайдаланылады.

Flatten қабаты соңғы қасиеттер карталарын бір 1D векторына түрлендіру үшін қолданылады. Бұл тегістеу қадамы кейбір конволюциялық/макспул қабатынан кейін толық қосылған қабатын пайдалану үшін қажет. Ол алдыңғы конволюциондық қабатының барлық табылған жергілікті ерекшеліктерін біріктіреді. Соңында *екі толық қосылған (Dense) қабатындағы* функциялар қолданылды, бұл жасанды нейрондық желілер (ANN) классификаторы. Активациясы - "sigmoid".

Ұсынылған модельде глобальді минимумға аз да болса жақындау үшін платоға кезіккен кезде оқыту жылдамдығын азайту үшін keras.callbacks.ReduceLROnPlateau әдісі қолданылды. Параметрлері 2-кестеде көрсетілген.

Кесте 2. ReduceLROnPlateau әдісі параметрлері

Параметр	Мағынасы	Мәні
monitor	бақыланатын көрсеткіш	'val_accuracy'
patience	жақсармаған дәуірлер саны, одан кейін оқу қарқыны төмендейді	2
factor	оқу қарқынын төмендететін фактор. $new_lr = lr * \text{фактор}$.	0.3
min_lr	оқу жылдамдығының төменгі шегі	0.000001

1.2.3 Классификацияны бағалау метрикалары

Ұсынылған модельді екі пневмония деректер жинағында бағалау үшін төрт стандартты бағалау метрикасы пайдаланылды: Accuracy (дәлдік), Precision, Recall және F1 [12]. Бұл бағалау көрсеткіштерін анықтау үшін алдымен «шын оң», «жалған оң», «шын теріс» және «жалған теріс» терминдерін анықтайық. Бинарлы классификация тапсырмасы үшін деректер жиынындағы екі класс «оң» және «теріс» класс деп аталады делік. Жоғарыда аталған терминдерді келесідей анықтауға болады.

- True Positive (TP) үлгі бойынша дұрыс жіктелген оң класқа жататын үлгіні білдіреді.
 - False Positive (FP) теріс класқа жататын, оң класқа жататын ретінде қате жіктелген үлгіні білдіреді.
 - True Negative (TN) үлгі бойынша дұрыс жіктелген теріс класқа жататын үлгіні білдіреді.
 - False Negative (FN) теріс класқа жататын ретінде қате жіктелген оң класқа жататын үлгіні білдіреді.
- Енді төрт бағалау көрсеткішін келесідей анықтауға болады:

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN}$$

$$Precision = \frac{TP}{TP + FP}$$

$$Recall (Sensitivity) = \frac{TP}{TP + FN}$$

$$F1 = \frac{2}{\frac{1}{Precision} + \frac{1}{Recall}}$$

Дәлдік көрсеткіші (accuracy) модельдің дұрыс болжау санының жалпы өлшемін береді. Дегенмен, модельдің жоғары дәлдік жылдамдығы деректер жинағы теңгерімсіз болса, оның әртүрлі класстарды бірдей ажырату мүмкіндігін қамтамасыз етпейді. Атап айтқанда, медициналық кескін классификациясында барлық сыныптарға жалпылануға болатын модель қажет. Мұндай жағдайларда Precision және Recall мәндері модельдің өнімділігі туралы түсінік береді. Precision модельдің оң класс болжамының дәлдігін көрсетеді. Бұл дұрыс болжамдардың модель берген жалпы болжамдарға қатынасын қамтамасыз етеді. Керісінше, Recall модель дұрыс болжаған ақиқат теріс класс болжамының дәлдігін өлшейді. Бұл екі бағалау көрсеткіші үлгінің FP және FN болжамдарының санын азайта алатынын бағалайды. F1 FP және FN екеуін де ескере отырып, Precision және Recall арасындағы теңгерімді қамтамасыз етеді.

Аталған бағалауларды біріктіріп, жалпы көріністі беретін маңызды көрсеткіш – *confusion matrix* (қателер матрицасы). Бинарлы классификация жағдайында ол келесі түрде болады:

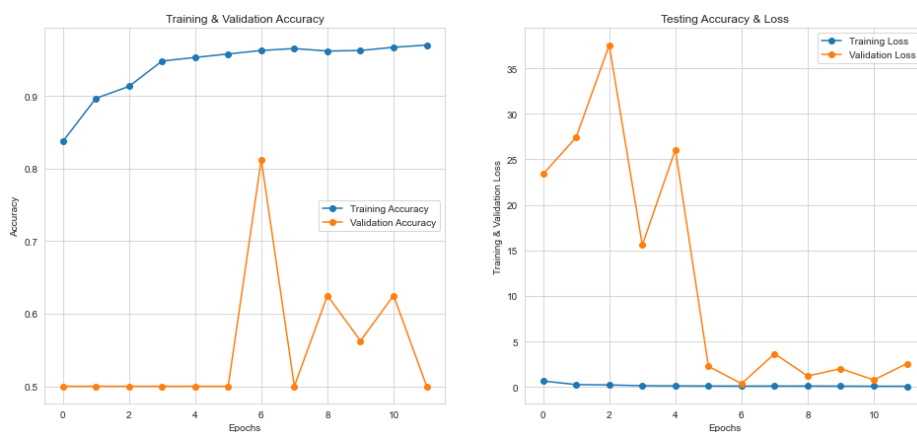
Ақиқат мәндер	Қалыпты	TN	FP
	Пневмония	FN	TP
		Қалыпты	Пневмония

Болжанған мәндер

Сурет 7. Confusion matrix

2 Оқыту процесі мен нәтижелер

Оқыту процесі 12 дәуірге созылды және 26 минут уақыт алды. Процесс барысындағы оқыту деректері мен валидациялық деректердегі accuracy (дәлдік) мен loss келесідей өзгерісте болды.




Сурет 8. Оқыту процесі

Тесттік деректердегі модельдің сапа көрсеткіштері 3-кестеде көрсетілген. Тесттік деректерде модель 92.3% дәлдік көрсетті. Пневмония анықтауда $precision = 91,7\%$, $recall = 96,4\%$, $F1 = 94\%$ мәндері айтарлықтай жақсы көрсеткіштер болып тұр. Мұндағы ең маңызды көрсеткіш recall, себебі пневмонияны анықтау бізге сау өкпе пневмония бар деген жалған нәтиже беруден қымбатырақ.

Кесте 3. Модель нәтижесінің есебі


	Қалыпты	Пневмония	Accuracy	Macro avg	Weighted avg
Precision	0.935	0.917	0.923	0.925	0.924
Recall	0.855	0.964	0.923	0.909	0.923
F1-score	0.893	0.94	0.923	0.916	0.922
Support	234	390	0.923	624	624

9-суретте confusion matrix көрсетілген. 624 рентгендік суреттен 234 сау өкпенің 200-ін модель дұрыс анықтады, 34-інде пневмония бар деп дұрыс анықталмады. 390 пневмония мысалдарының 376-ы дұрыс анықталып, 14-і сау өкпе деген жалған белгіге ие болды, яғни TP=376, FP=34, TN=200, FN=14 деген мәндерге тең.



Сурет 9. Confusion matrix

Модель анықтаған дұрыс, дұрыс емес мысалдар 10-суретте берілген. а және ә суреттері дұрыс анықталған, ал б – модель қате анықтаған рентгенограмма. Бұл мысалда көрініп тұрған пневмонияны сау өкпеден ажыраттаын ақ инфильтранттар модельді шатастырып тұр. Мұндай жағдайлар тіпті тәжірибесі мол радиологқа диагноз қоюды қиындатуы мүмкін, сондай-ақ пневмонияны анықтау үшін кеуде қуысының рентгендік зерттеулері субъективті өзгергіштікке бейім келеді [13].



Сурет 10. Модельдің классификация нәтижелері

Қорытынды

Бұл уақытқа дейін зерттеу аймағында айтарлықтай ауқымды жұмыстар ұсынылған болатын. Өзге авторлар алған дәлдік көрсеткіштерінің біздің желінің дәлдігімен салыстырмалы талдауы 4-кестеде көрсетілген. Байқап отырғанымыздай, дәстүрлі машиналық оқыту алгоритмдері SVM, KNN, k-орташа кластеризациясы, т.б. салыстырғанда нейрондық желілерге негізделген алгоритмдерінің көрсеткіштері жоғары болып тұр. Осы жұмыста көрсетілген желінің артықшылығы:

- уақыттың үнемділігі (оқыту процесіне бар болғаны 26 мин кетті);
- пневмонияны анықтаудың салыстырмалы жоғары дәлдігі (accuracy – 92,3%, recall – 96,4%);
- көп есептеу қуатын талап етпейтін қарапайым модель.

Кесте 4. Алынған нәтижені басқа жұмыстардың нәтижелерімен салыстыру

Зерттеу	Қолданылған әдістер	Деректер қоры	Нәтижелер
Жұмыста ұсынылған модель	CNN	Pediatric chest X-rays	92,3%
Keude қуысының рентгенографиясын қолдана отырып, балалар пневмониясын анықтауда машиналық оқыту классификаторларының тиімділігін салыстырмалы талдау Ошибка! Источник ссылки не найден..	SVM (Support Vector Machine), KNN, NB (Naive Bayes)	PneumoCAD	сәйкесінше 77%, 70%, 68%
Keude қуысының рентгенографиясындағы пневмонияны оқытушымен үйрету арқылы анықтау Ошибка! Источник ссылки не найден..	k-орташа кластеризациясы	Chest X-ray14	60%
Жапсырмалар арасындағы тәуелділікті пайдалану арқылы басынан бастап диагноз қоюды үйрену Ошибка! Источник ссылки не найден..	LSTM (Long Short-Term Memory)	Chest X-ray14	76%
Классификация үшін таңбаланған оптикалық когеренттік томография және кеуде қуысының рентгендік суреттері Ошибка! Источник ссылки не найден..	Ауыспалы оқыту	Pediatric chest X-rays	90.7%
Keude қуысының ауруларын анықтауға арналған терең конвульсиялық нейрондық желілер Ошибка! Источник ссылки не найден..	CNN, SpNN (Competitive probabilistic neural network - Бәсекеге қабілетті ықтимал нейрондық желі), VpNN (Back Propagation Neural Network - Кері таралу нейрондық желісі)	Chest X-ray14	92%
Pneumonia Classification Using Deep Learning from Chest X-ray Images During COVID-19 [18].	Ауыспалы оқыту	Әртүрлі дерекқорлардан	91,43%

Ұсынылған жұмыстар шағын мәліметтер базасында бағаланады және оларды коммерциялық масштабта қолдануға болмайды. Осы орайда, көлемі үлкен бірнеше жоғары маманданған тәуелсіз рентгенологтармен расталған сапалы деректерді қолдану қазіргі қарқынды ескергенде үлкен жетістіктерге алып келуі мүмкін.

Терең оқытудағы көшірмелі оқыту (transfer learning) сияқты тенденциялар көмегімен жинақталатын оқыту процесін құру және деректер қорын кеңейту болашақта жоспарға қойылды. Себебі алынған дәлдік салыстырмалы жоғары болғанымен, зерттеліп отырған аймақ адам өмірімен байланысты болғандықтан 99% дәлдіктің өзі жеткіліксіз болуы мүмкін.

Болашақта рентгенограммаларды дәл автоматтандырылған талдау радиологтың жұмыс процесінің тиімділігін арттырады, медициналық көмектің сапасын арттыру үшін шығындар мен жауап беру уақытын азайту үшін маңызды. Сондай-ақ, тәжірибені қызмет көрсетілмейтін аймақтарға таратуда үлкен мүмкіндіктерге ие.

Пайдаланылған әдебиеттер тізімі:

- 1 Household air pollution and health, 2021. Қолжетімді: <https://www.who.int/news-room/fact-sheets/detail/household-air-pollution-and-health>
- 2 Alistair E. W. Johnson, Tom J. Pollard, Nathaniel R. Greenbaum, Matthew P. Lungren, Chih-ying Deng, Yifan Peng, Zhiyong Lu, Roger G. Mark, Seth J. Berkowitz, Steven Horng, MIMIC-CXR-JPG, a large publicly available database of labeled chest radiographs, 2019. Қолжетімді: <https://arxiv.org/abs/1901.07042>
- 3 Le, W.T.; Maleki, F.; Romero, F.P.; Forghani, R.; Kadoury, S. Overview of machine learning: Part 2 : deep learning for medical image analysis. *Neuroimaging Clin. N. Am.*, vol. 30, pp. 417–431, 2020.
- 4 Our World in Data. Pneumonia by Bernadeta Dadonaite and Max Roser, 2019. Қолжетімді: <https://ourworldindata.org/pneumonia>
- 5 Ronneberger, O.; Fischer, P.; Brox, T. U-net: Convolutional networks for biomedical image segmentation. In *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015*, pp. 234–241, 2015.
- 6 Milletari, F.; Navab, N.; Ahmadi, S.A. V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation. In *Proceedings of the 2016 Fourth International Conference on 3D Vision (3DV)*, pp. 565–571, 25–28 October 2016
- 7 Jeelani, H.; Martin, J.; Vasquez, F.; Salerno, M.; Weller, D. Image quality affects deep learning reconstruction of MRI. In *Proceedings of the 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)*, pp. 357–360, 4–7 April 2018.
- 8 Chlemper, J.S.; Caballero, J.; Hajnal, J.; Price, A.N.; Rueckert, D. A deep cascade of convolutional neural networks for dynamic MR image reconstruction. *IEEE Trans. Med. Imaging*, vol. 37, pp. 491–503, 2017.
- 9 Rajpurkar, P.; Irvin, J.; Zhu, K.; Yang, B.; Mehta, H.; Duan, T.; Ding, D.; Bagul, A.; Langlotz, C.; Shpanskaya, K.; et al. Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. 2017, arXiv:1711.05225.
- 10 Huang, G.; Liu, Z.; Van Der Maaten, L.; Weinberger, K.Q. Densely Connected Convolutional Networks. In *Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, 21–26 July 2017; pp. 2261–2269.
- 11 Dataset Chest X-Ray Images (Pneumonia). Available at: <https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia?datasetId=17810&sortBy=voteCount&language=Python&tagIds=16580>
- 12 Chollet, F. Deep Learning with Python, 2018, p. 23. Manning Publications Co.
- 13 Sousa R. T., Marques O., Soares F. A. A. M. N., Sene I. I. G., De Oliveira L. L. G., and Spoto E. S., Comparative performance analysis of machine learning classifiers in detection of childhood pneumonia using chest radiographs, *Procedia Computer Science*, vol. 18, pp. 2579–2582, 2013, doi: 10.1016/j.procs.2013.05.444.
- 14 Antin B., Kravitz J., and Martayan E., Detecting Pneumonia in Chest X-Rays with Supervised Learning, *Semanticscholar. Org*. pp. 1–5, 2017. <http://cs229.stanford.edu/proj2017/final-reports/5231221.pdf>
- 15 Yao L., Poblens E., Dagunts D., Covington B., Bernard D., and Lyman K., Learning to diagnose from scratch by exploiting dependencies among labels, Oct. 2017.
- 16 Kermany, Daniel; Zhang, Kang; Goldbaum, Michael (2018), Labeled Optical Coherence Tomography (OCT) and Chest X-Ray Images for Classification, *Mendeley Data*, V2, doi: 10.17632/rscbjbr9sj.2. <https://data.mendeley.com/datasets/rscbjbr9sj/2>
- 17 Rahib H. Abiyev, Mohammad Khaleel Sallam Ma'aitah, Deep Convolutional Neural Networks for Chest Diseases Detection, *Journal of Healthcare Engineering*, vol. 2018, Article ID 4168538, 11 pages, 2018, <https://doi.org/10.1155/2018/4168538>.
- 18 Ibrahim, A.U., Ozsoz, M., Serte, S. et al. Pneumonia Classification Using Deep Learning from Chest X-ray Images During COVID-19. *Cogn Comput* (2021). <https://doi.org/10.1007/s12559-020-09787-5>

- 1 Household air pollution and health, 2021. Available at: <https://www.who.int/news-room/fact-sheets/detail/household-air-pollution-and-health>
- 2 Alistair E. W. Johnson, Tom J. Pollard, Nathaniel R. Greenbaum, Matthew P. Lungren, Chih-ying Deng, Yifan Peng, Zhiyong Lu, Roger G. Mark, Seth J. Berkowitz, Steven Horng, MIMIC-CXR-JPG, a large publicly available database of labeled chest radiographs, 2019. Available at: <https://arxiv.org/abs/1901.07042>
- 3 Le, W.T.; Maleki, F.; Romero, F.P.; Forghani, R.; Kadoury, S. Overview of machine learning: Part 2 : deep learning for medical image analysis. *Neuroimaging Clin. N. Am.*, vol. 30, pp. 417–431, 2020.
- 4 Our World in Data. Pneumonia by Bernadeta Dadonaite and Max Roser, 2019. Available at: <https://ourworldindata.org/pneumonia>
- 5 Ronneberger, O.; Fischer, P.; Brox, T. U-net: Convolutional networks for biomedical image segmentation. In *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015*, pp. 234–241, 2015.
- 6 Milletari, F.; Navab, N.; Ahmadi, S.A. V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation. In *Proceedings of the 2016 Fourth International Conference on 3D Vision (3DV)*, pp. 565–571, 25–28 October 2016
- 7 Jeelani, H.; Martin, J.; Vasquez, F.; Salerno, M.; Weller, D. Image quality affects deep learning reconstruction of MRI. In *Proceedings of the 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)*, pp. 357–360, 4–7 April 2018.
- 8 Chlemper, J.S.; Caballero, J.; Hajnal, J.; Price, A.N.; Rueckert, D. A deep cascade of convolutional neural networks for dynamic MR image reconstruction. *IEEE Trans. Med. Imaging*, vol. 37, pp. 491–503, 2017.
- 9 Rajpurkar, P.; Irvin, J.; Zhu, K.; Yang, B.; Mehta, H.; Duan, T.; Ding, D.; Bagul, A.; Langlotz, C.; Shpanskaya, K.; et al. CheXnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. 2017, arXiv:1711.05225.
- 10 Huang, G.; Liu, Z.; Van Der Maaten, L.; Weinberger, K.Q. Densely Connected Convolutional Networks. In *Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, 21–26 July 2017; pp. 2261–2269.
- 11 Dataset Chest X-Ray Images (Pneumonia). Available at: <https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia?datasetId=17810&sortBy=voteCount&language=Python&tagIds=16580>
- 12 Chollet, F. *Deep Learning with Python*, 2018, p. 23. Manning Publications Co
- 13 Sousa R. T., Marques O., Soares F. A. A. M. N., Sene I. I. G., De Oliveira L. L. G., and Spoto E. S., Comparative performance analysis of machine learning classifiers in detection of childhood pneumonia using chest radiographs, *Procedia Computer Science*, vol. 18, pp. 2579–2582, 2013, doi: 10.1016/j.procs.2013.05.444.
- 14 Antin B., Kravitz J., and E. Martayan, Detecting Pneumonia in Chest X-Rays with Supervised Learning, *Semanticscholar. Org.* pp. 1–5, 2017. <http://cs229.stanford.edu/proj2017/final-reports/5231221.pdf>
- 15 Yao L., Poblenz E., Dagunts D., Covington B., Bernard D., and Lyman K., Learning to diagnose from scratch by exploiting dependencies among labels, Oct. 2017.
- 16 Kermany, Daniel; Zhang, Kang; Goldbaum, Michael (2018), Labeled Optical Coherence Tomography (OCT) and Chest X-Ray Images for Classification, *Mendeley Data*, V2, doi: 10.17632/rscbjbr9sj.2. <https://data.mendeley.com/datasets/rscbjbr9sj/2>
- 17 Rahib H. Abiyev, Mohammad Khaleel Sallam Ma'aitah, Deep Convolutional Neural Networks for Chest Diseases Detection, *Journal of Healthcare Engineering*, vol. 2018, Article ID 4168538, 11 pages, 2018, <https://doi.org/10.1155/2018/4168538>.
- 18 Ibrahim, A.U., Ozsoz, M., Serte, S. et al. Pneumonia Classification Using Deep Learning from Chest X-ray Images During COVID-19. *Cogn Comput* (2021). <https://doi.org/10.1007/s12559-020-09787-5>