

VILNIAUS UNIVERSITETAS
MATEMATIKOS IR INFORMATIKOS FAKULTETAS
PROGRAMŲ SISTEMŲ BAKALAURO STUDIJŲ PROGRAMA

Plaučių ligų atpažinimas naudojant rentgeno nuotraukas

Recognition of Lung Diseases Using X-Ray

Bakalauro baigiamasis darbas

Atliko:	Lukas Chatkevičius	(parašas)
Darbo vadovas:	asist. dr. Tomas Plankis	(parašas)
Darbo recenzentas:	prof. dr. Saulius Minkevičius	(parašas)

Vilnius – 2020

Santrauka

Šiame darbe buvo nagrinėta skirtingų duomenų rinkinių įtaka konvoliuciniam neuroniniam tinklui atpažįstant plaučių ligas rentgeno nuotraukose. Atlikus išsamią didžiausių krūtinės ląstos rentgenogramų rinkinių analizę, tais duomenų rinkiniais buvo apmokyti konvoliucinių neuroninių tinklų modeliai. Apmokyti modeliai buvo testuojami su priešingo duomenų rinkinio testavimo rinkiniais. Iš gautų rezultatų padarytos išvados, kad duomenų rinkinio specifiška gali turėti įtakos atpažįstant plaučių ligas.

Raktiniai žodžiai: konvoliucinis neuroninis tinklas, plaučių ligų atpažinimas

Summary

In this paper, the author investigates the influence of different datasets on convolutional neural network ability to recognize lung diseases. After a detailed analysis of the two largest chest x-ray datasets, convolutional neural network models were trained with those datasets. The trained models were tested with test data from the opposite dataset. Obtained results concluded that the specificity of the data might have an impact on the recognition of lung diseases.

Keywords: convolutional neural network, detection of lung diseases

TURINYS

IVADAS	4
1. TEORIJA	7
1.1. Dirbtinis neuroninis tinklas	7
1.2. Konvoliucinis neuroninis tinklas	7
1.2.1. Konvoliucinis sluoksnis	8
1.2.2. Sutelkimo sluoksnis	8
1.2.3. Netiesinis sluoksnis	8
1.2.4. Pilnai sujungtas sluoksnis	8
1.3. KNT architektūros	8
1.4. DenseNet architektūra	9
1.4.1. Tankusis blokas	9
1.4.2. Pereinamasis blokas	10
1.5. KNT pasirinkimas	10
2. DUOMENŲ RINKINIAI	11
2.1. ChestX-ray14 duomenų rinkinys	11
2.2. CheXpert duomenų rinkinys	12
2.3. Duomenų rinkinių paruošimas	13
3. MODELIS	15
3.1. Modelio architektūra	15
3.2. Modelio modifikacijos	15
3.2.1. Optimizavimo algoritmas	15
3.2.2. Mokymo greitis	16
3.2.3. Mokymo greičio keitėjas	16
3.2.4. Parinkti modelio parametrai	16
3.3. Modelio apmokymas	16
3.4. Modelių apmokymo etapas	17
3.5. CheXpert konkursas	17
4. EKSPERIMENTO VYKDYMAS	18
4.1. Apmokymas	18
4.2. Testavimas	18
4.2.1. 14 klasių modelis apmokytas su ChestX-ray14 duomenų rinkiniu	18
4.2.2. 14 klasių modelis apmokytas su CheXpert duomenų rinkiniu	19
4.2.3. 5 klasių modelis apmokytas su ChestX-ray14 duomenų rinkiniu	20
4.2.4. 5 klasių modelis apmokytas su CheXpert duomenų rinkiniu	20
REZULTATAI	21
IŠVADOS	23
LITERATŪRA	24
SAVOKŲ APIBRĖŽIMAI	26
SANTRUMPOS	27
1 PRIEDAS	28

Įvadas

Plaučių ligos - vienos pavojingiausių ligų pasaulyje, nusinešančios milijonus gyvybių kasmet. Europos Sąjungos, 2016 metų ataskaitinio laiktoriaus, mirties priežasčių statistikoje vėžys yra antroje vietoje pagal mirtingumą. Pati dažniausia vėžio forma - plaučių vėžys. Kvėpavimo sistemos ligos pagal mirties priežasties dažnumą yra trečioje vietoje [EUR20]. Plaučių ligų nustatymas skiriasi nuo to, kokiais simptomais pacientas skundžiasi. Vienu atveju užtenka stetoskopu klausyti kvėpavimo sistemos organų sukeltų garsų, jeigu kyla įtarimų daromi kraujo tyrimai. Jeigu vis dar nėra aišku, kas iš tikrųjų kankina žmogų, yra daromas radiologinis tyrimas.

Radiologinis tyrimas - tai krūtinės ląstos rentgenograma. Dažniausiai jis yra atliekama iš priekio ir/arba šono. Šis tyrimas yra labai informatyvus todėl, kad leidžia diagnozuoti anomalijas - navikus, plaučių uždegimą ar kitus neaiškius židinius, kurie gali būti susiję su vėžiu, širdies ligomis. Šiuos tyrimus analizuoja radiologai, kurių poreikis vis auga. Sprendžiant šią problemą, jie yra sandomi dirbti per atstumą t.y. kitoje šalyje esančiam radiologui yra persiunčiama rentgenograma ir yra laukiama rentgenogramos vertinimo ataskaitos, o tai užima nemažai laiko. Dabartinėje situacijoje, kai yra paskelbta globali pandemija, tokie tyrimai yra daromi dar didesniame kiekiui žmonių, todėl įprastiniai radiologiniai tyrimai turi būti atidedami arba daromi vėliau, nei planuota, taip rizikuojant žmonių sveikata.

Automatizuotas krūtinės ląstos rentgeno nuotraukų įvertinimas ir paprastas aprašas, kuris padarytas automatiškai be jokio žmogaus įsikišimo, suteiktų daug naudingos pradinės informacijos radiologams ir kitų sričių gydytojams. Jie galėtų interpretuoti tokios sistemos ataskaitas ir toliau nagrinėti tik tuo atveju, jei tai yra būtina. Taip suteikiant pirmenybę pacientams, kurių būklė sunki, ar reikalingas skubus gydymas.

Kompiuterinė medicininė diagnozė (angl. computer aided medical diagnosis) sumažintų medicinos darbuotojų darbo krūvį, apimtis ir kaštus. Trumpėtų vidutinis laikas, skiriamas rentgenogramos analizei ir ataskaitai. Tokių sistemų poreikis yra didelis, tačiau jų kūrimui reikalingi adaptyvūs, save apmokantys, tikslūs bei galintys dirbti su dideliais vaizdų ir duomenų kiekiais, mašininio mokymosi modeliai. Būtent toks yra konvoliucinių neuroninių tinklų panaudojimo atvejis.

Pastarąjį dešimtmetį, konvoliucinių neuroninių tinklų architektūros ir modeliai sparčiai tobulėja. Prie šio progreso labai prisidėjo GPU pritaikymas dirbtinių neuroninių tinklų skaičiavimams ir didelių, viešai prieinamų vaizdų duomenų rinkinių atsiradimas (ImageNet, CIFAR). Kiekvienais metais modelių pasiekiamas tikslumas yra gerinamas. Nuo pat konvoliucinių neuroninių tinklų architektūrų evoliucijos pradžios, tipiška tinklai tik gilėja, pavyzdžiui ResNet, kuris pripažintas geriausiu ILSVRC 2015 konkurse buvo maždaug 20 kartų gilesnis nei AlexNet ir 8 kartus gilesnis už VGGNet, kurie ankstesniais metais taip pat buvo nugalėtojai [Cod04; GWaM⁺17] Tokie pasiekimai skatina tyrėjus ieškoti tinkamų architektūrų ir būdų jas pritaikyti medicinoje.

Keletas pavyzdžių, kur taikomos konvoliucinių tinklų architektūros: mažų kraujo produktų kaupimosi aptikimas smegenyse [LUC⁺19]; diabetinės retinopatijos aptikimas [GPC⁺16]; pilnai automatizuotas kasos segmentavimas [ZTR⁺19] Šie modelių pritaikymai medicinoje nebūtų įmanomi be tai sričiai išleistų duomenų rinkinių. Kuo jie didesni, tuo neuroninis tinklas geriau gali išmokyti reikiamus parametrus ir klasifikuoti įeinančią informaciją. Būtent didelių duomenų rinkinių nepa-

kankamumas yra viena iš priežasčių, kodėl mašininio mokymosi modelių taikymas medicinoje yra sunki užduotis.

Geras duomenų rinkinys - tai rinkinys, kurį sudaro daug ir aukštos kokybės duomenų. Duomenys turėtų būti peržiūrėti specialistų, kurie gali patvirtinti duomenų teisingumą. Krūtinės ląstos ligų aptikimui šis teiginys taip pat galioja. 2017 ir 2019 metais buvo išleisti krūtinės ląstos rentgeno nuotraukų rinkiniai, kurie paskatino tyrinėtojus aktyviau analizuoti ir kurti modelius skirtus krūtinės ląstos ligų aptikimui, naudojant rentgeno nuotraukas. Šiame darbe bandoma išsiaiškinti, kaip konvoliucinio neuroninio tinklo duomenų rinkiniai veikia atliekamų spėjimų tikslumą.

Darbo tikslas ir uždaviniai

Šio bakalauro darbo tikslas - išsiaiškinti skirtingų duomenų rinkinių įtaką konvoliuciniam neuroniniam tinklui atpažįstant plaučių ligas rentgeno nuotraukose. Tikslui pasiekti buvo iškelti šie uždaviniai:

1. Atlikti konvoliucinių neuroninių tinklų analizę
2. Atlikti duomenų rinkinių analizę ir paruošti naudojimui
3. Įgyvendinti pasirinktos architektūros konvoliucinio neuroninio tinklo modelį
4. Atlikti bandymus su modeliu bei pasirinktais duomenų rinkiniais

Metodika

Darbo tikslui pasiekti buvo atlikta konvoliucinių neuroninių tinklų, esamų architektūrų ir egzistuojančių sprendimų analizė. Buvo pasirinkta būsimo modelio architektūra.

Duomenų rinkinių paieškos etape dideli ir laisvai prieinami rasti 2 rinkiniai, jie buvo detalčiai išanalizuoti ir po paruošimo buvo naudojami bandymuose.

Išsirinktos architektūros modelio implementacijai buvo atlikta karkasų analizė, jos metu buvo pasirinktas PyTorch karkasas, dėl savo populiarumo, operacinių sistemų palaikymo, papildomų bibliotekų pasirinkimo bei greičio atliekant skaičiavimus su tam skirta CUDA technologiją palaikančia vaizdo plokšte.

Darbo atlikimo aplinka

Darbo tikslui įgyvendinti buvo naudojamos dvi aplinkos: nešiojamas kompiuteris ir Google Cloud išnuomotas virtualus serveris. Kadangi nešiojamas kompiuteris turėjo tik integruotą vaizdo plokštę, jis buvo naudojamas konvoliucinio neuroninio tinklo architektūros implementacijai ir modelio optimizavimui. Virtualus serveris buvo naudojamas duomenų apdorojimui, modelio apmokymui, validacijai ir testavimui. Pagrindiniai aplinkų parametrai:


1. Nešiojamas kompiuteris: operacinė sistema macOS, Intel i7 6 branduolių procesorius su 2,6GHz dažniu, 16GB RAM atminties, vaizdo plokštė integruota.

2. Google Cloud virtualus serveris: operacinė sistema Debian, 2 branduolių virtualus procesorius, 13GB RAM atminties, vaizdo plokštė NVIDIA Tesla 100 su 8GB atminties

1. Teorija

1.1. Dirbtinis neuroninis tinklas

Dirbtinis neuroninis tinklas (angl. artificial neural network) - tai matematinis modelis, tačiau jis veikia kitaip, nei paprasti linijiniai skaičiavimai. Dirbtinis neuroninis tinklas yra sudarytas iš tarpusavyje susijungusių dalių, vadinamų neuronais. Neuronai priima informaciją, apdoroja ir siunčia į sekantį sluoksnį. DNT paprastai sudaryti iš vienas po kito einančių sluoksnių (1 pav.), kur kiekvienas sluoksnis yra sudarytas iš neuronų. DNT būna dviejų tipų: sklindantis į priekį (angl. feed-forward), jame informacija juda tik į priekį, ir rekurentinis, kuriame informacija gali sklisti ir į priešingą pusę.



1 pav. Sklindančio į priekį DNT struktūra

DNT neuronas išreikštas matematiškai iš tikrųjų daro paprastus veiksmus: įeinantys duomenys yra padauginami iš svorių (angl. weight) jie yra sumuojami, gautas rezultatas yra perduodamas aktyvacijos funkcijai ir rezultatas siunčiamas toliau į kitą sluoksnį. Tai tęsiasi iki tol kol yra dar paslėptų sluoksnių. Paskutinis sluoksnis - išvesties, jame neuronai gautus parametrus susumuoja, tada yra pritaikoma aktyvavimo funkcija ir DNT gražina rezultatą [Suz11].

1.2. Konvoliucinis neuroninis tinklas

Konvoliucinis neuroninis tinklas - tai DNT rūšis, kuri aktyviai naudojama vaizdų, vaizdinės medžiagos apdorojime, objektų atpažinime, skaitmeniniame natūraliosios kalbos apdorojime. Nuo DNT skiriasi tuo, kad gali dirbti su didesniais duomenų įvesties kiekiais ir specializuojasi į vaizdų apdorojimą, dėl savo architektūros sprendimų. Kiekvienoje šio tinklo architektūroje yra bent vienas konvoliucinis sluoksnis, kuriame taikoma matematinė funkcija - konvoliucija. Bazinės KNT architektūros yra sudaromos iš: konvoliucinių sluoksnių, sutelkimo sluoksnių, netiesiškumo sluoksnių, pilnai sujungtų sluoksnių.

1.2.1. Konvoliucinis sluoksnis

KNT konvoliucinis sluoksnis yra sudarytas iš filtrų, kurių erdvinis dydis yra pasirenkamas (pvz. 3×3 , 5×5). Filtras turi išmokus parametrus, su kuriais yra vykdoma konvoliucija, einant per visą įvesties dydį. Šią operaciją atlikus, gaunamas aktyvacijų parametras (angl. activation map). Viename konvoliuciniame sluoksnyje būna daugiau nei vienas filtras - tai yra KNT parametras, kuris nustatomas modelio architektūros kūrimo etape. Visų filtrų aktyvacijų parametrai yra konvoliucinio sluoksnio išvestis.

1.2.2. Sutelkimo sluoksnis

Sutelkimo sluoksnio paskirtis yra progresyviai mažinti KNT tinkle perduodamų duomenų dydį, parametrų kiekį ir skaičiavimų kainą. Šis sluoksnis KNT architektūrose dažniausiai būna tarp konvoliucinių sluoksnių, todėl, kad stipriai sumažina aktyvacijų skaičių, kurios patenka į sekantį sluoksnį. Standartinės naudojamos matematinės operacijos sutelkimo sluoksnyje yra MAX ir AVG, o filtro dydis 2×2 .

1.2.3. Netiesinis sluoksnis

Netiesinis sluoksnis iš tikrųjų yra aktyvacijos funkcija (angl. activation function), kuri suteikia modeliui netiesiškumo. Netiesinis sluoksnis kiekvienam konvoliucinio sluoksnio sugeneruoto aktyvacijų parametro nariui pritaiko aktyvacijos funkciją ir sugeneruoja lygiai tokio pačio dydžio aktyvacijų parametrai išvesčiai. Dažniausiai naudojama ReLU (angl. Rectified Linear Unit) aktyvacijos funkcija, kuri, gavus reikšmę mažesnę už 0, gražina 0, kitu atveju gražina tą pačią reikšmę. KNT modeliui netiesinis sluoksnis neprideda jokių papildomų parametrų.

1.2.4. Pilnai sujungtas sluoksnis

Pilnai sujungto sluoksnio neuronai yra pilnai sujungti su kiekvienu aktyvacijų parametru iš prieš tai ėjusio sluoksnio. KNT architektūrose šis sluoksnis dažniausiai yra paskutinis, tačiau, kad gauti sprendimą klasifikacijos ar kitam uždaviniui, reikia taikyti atitinkamą funkciją. Kokią funkciją taikyti, reikia rinktis pagal tai kaip ir ką norima klasifikuoti: ar tai yra keleto klasių uždavinys, ar tai yra paprastas klasifikavimas. Pilnai sujungto sluoksnio ir po jo sekančios aktyvacijos funkcijos rezultatas - klasifikatorius, kurio išvestis yra tikimybė, jog įvesties duomenys priklauso tam tikrai klasei. Dažniausiai naudojama sigmoidinė arba softmax funkcija.

1.3. KNT architektūros


Pirmoji KNT architektūra pasiūlyta 1998 metais - LeNet-5 [Haf98], buvo sudaryta vos iš 5 sluoksnių, parametrų kiekis siekė vos 60 tūkstančių, pagrinde buvo naudojama atpažinti rašytiems skaičiams, pašto kodams. Dėl KNT architektūros sudėtingumo ir aukštų reikalavimų kompiuteriams sekė stagnacija.

Atsiradus dideliems viešai prieinamų duomenų rinkiniams, kaip ImageNet [RDS⁺19] ir išaugus kompiuterių galimybėms, prasidėjo aktyvus KNT architektūrų modeliavimas, todėl 2012 metais pasiekiamas proveržis KNT našume ir nauja AlexNet architektūra. Ji ImageNet konkurse, sumažino buvusią geriausią paklaidą nuo 25.8% iki 16.4% [KSZ20]. Ji buvo platesnė ir gilesnė už LeNet ir buvo sudaryta iš 60 mln. parametrų, tai yra 1000 kartų daugiau nei LeNet [KSH12]. Vėlesniais metais KNT architektūros gilėjo ir plėtėjo gerindamos rezultatus, tačiau didindamos modelių apmokymo laiką ir reikalaujamų resursų kiekį. Šiuo metu geriausias tikslumas su ImageNet duomenų rinkiniu yra 98.7% [Cod04], kurį pasiekė FixEfficientNet-L2 architektūros modelis, kurio parametrų skaičius 480 milijonų.

1.4. DenseNet architektūra

DenseNet architektūra pasiūlyta 2016 metais. Ši architektūra pristatė sprendimą, kaip gilėjant KNT išvengti informacijos praradimo jai pereinant per daug sluoksnių. DenseNet sujungia kiekvieną sluoksnį su kitais sluoksniais, taip kiekvienam sluoksniui perduodant visus aktyvacijų parametrus, kurie buvo naudoti, kaip įvestis, prieš jį buvusiems sluoksniams. Tokiu būdu pagerinamas požymių išgavimas, išsprendžiama informacijos praradimo problema ir sumažinamas svorių skaičius visam KNT [HLvdM⁺16].

DenseNet susideda iš konvoliucinių sluoksnių, tankių (angl. dense) blokų (2 pav.), pereinamųjų (angl. transition) blokų, sutelkimo sluoksnių ir klasifikatoriaus (pilnai sujungtas sluoksnis sekamas aktyvacijos funkcijos).



2 pav. DenseNet tankusis blokas


1.4.1. Tankusis blokas

DenseNet architektūros pagrindinė sudedamoji dalis tankusis blokas pavaizduotas 2 paveikslėlyje. Jame yra 6 sluoksniai, kurių aktyvacijų parametrai, kartu su įvesties duomenimis yra perduodami į visus sekančius blokus. Kiekvienas sluoksnis tankiajame bloke susideda iš 1x1 filtro konvoliucijos (požymių išgavimas) ir ją sekančios 3x3 filtro konvoliucijos (požymių kanalų mažinimas). Verta paminėti, kad prieš kiekvieną konvoliucijos sluoksnį yra taikoma rinkinio normalizacijos

transformacija (angl. batch normalization), po jos taikoma aktyvacijos funkcija ReLU. Kiekvieno tankiojo bloko sluoksnio eiga yra tokia: BN->ReLU->Conv(1x1)->BN->ReLU->Conv(3x3).

1.4.2. Pereinamasis blokas

Pereinamasis blokas yra sudarytas iš konvoliucinio sluoksnio su filtro dydžiu 1x1 ir sutelkimo sluoksnio (dydis 2x2), kuris naudoja AVG matematinę funkciją (3 pav.). Konvoliucijos sluoksnis sumažina kanalų (angl. channel) kiekį per pusę. Pereinamasis blokas yra įkomponuotas tarp kiekvieno tankaus bloko, kad sumažintų persiunčiama parametrų kiekį iš vieno bloko į kitą.



3 pav. DenseNet pereinamasis blokas

1.5. KNT pasirinkimas

Tyrimo modeliui sudaryti buvo pasirinktas DenseNet-121 modelis su mažiausiu parametrų kiekiu, apmokytas ImageNet duomenų rinkiniu. DenseNet-121 buvo pasirinktas todėl, kad jo našumas prilygsta ResNet-50 architektūros modeliui, tačiau turi žymiai mažiau parametrų, kas leis greičiau vykdyti tyrimo eksperimento eigą. Verta paminėti, kad panašaus pobūdžio KNT panaudojimo medicinos srityje tyrimuose taip pat buvo naudojamas DenseNet modelis, ar jo bazė.

2. Duomenų rinkiniai

KNT modelio tikslumas ir pritaikymas prie nematytų duomenų labai priklauso nuo jo apmokymui naudoto duomenų rinkinio. Geras duomenų rinkinys - tai rinkinys kuris yra subalansuotas klasių ir atitinkančių vaizdų skaičiumi, pakankamai įvairus vaizdų kampo, ryškumo atžvilgiu, ir, žinoma, labai didelis. Tokiu duomenų rinkiniu apmokytas KNT modelis turėtų pakankamai gerai teikti spėjimus įvairių įeities vaizdų atžvilgiu. Šiuo metu tokių rinkinių yra keletas: CIFAR-10/CIFAR-100, ImageNet.

Medicininis duomenų rinkinių kiekis yra ribotas. Tam yra svarių priežasčių. Visų pirma tie rinkiniai negali būti sudaryti iš internete randamų nuotraukų, kaip ImageNet. Rentgenogramos ir kiti tyrimai, kurių duomenų rinkiniai būtų svarbūs tyrinėtojams, daromi ligoninėse jų pacientams ir tai nėra vieši, bet kam prieinami duomenys [RNZ17].


Didelių krūtinės ląstos rentgeno nuotraukų duomenų rinkinių, kurie būtų laisvai prieinami, šiuo metu yra 3: ChestX-ray14, CheXpert ir MIMIC-CXR. Tyrimui buvo pasirinkti pirmieji du, nes paskutinis, nėra visiškai viešai prieinamas, kad jį pasiekti yra reikalinga vartotojo paskyra ir gautas leidimas.

2.1. ChestX-ray14 duomenų rinkinys

2017 metais NIH klinikinis centras išleido viešai prieinamą krūtinės ląstos rentgeno nuotraukų rinkinį. Jį sudarė 112120 vaizdų, surinktų 1992-2015 metais, iš 30805 skirtingų pacientų. Rinkinyje paciento ir klasių duomenys buvo išgauti iš radiologinių ataskaitų, naudojant NIH sukurtą skaitmeninės natūraliosios kalbos apdorojimo techniką [WPL⁺17]. Duomenų rinkinyje yra 15 skirtingų vaizdų klasių: 13 krūtinės ląstos ligų, išvarža ir nieko nebuvo rasta. Kiekviena nuotrauka gali turėti keletą jai priskirtų klasių.



4 pav. Priekinė rentgenograma




5 pav. Priekinė rentgenograma



6 pav. Šoninė rentgenograma

Diagramoje (7 pav.) matosi rinkinio klasių disbalansas. Kitoje diagramoje (1 priedas 9 pav.) buvo išimta „nerasta“ klasė, kad labiau matytųsi reikšmingų klasių pasiskirstymas. 8 klasės nesiekia 5000 egzempliorių ribos, tačiau ganėtinai panašiai pasiskirstę. Beveik pusė rinkinio nuotraukų neturėjo jokių radinių, kita pusė turėjo vieną ar daugiau radinių.



7 pav. ChestX-ray14 duomenų rinkinio klasių pasiskirstymas


Verta paminėti, kad NIH naudota skaitmeninės natūraliosios kalbos apdorojimo technika atskaitose radusi neapibrėžtumą t.y. kad galbūt kažkoks radinys buvo rastas, radiologo, automatiškai, pagal taisykles nusprendavo ar tai yra teigiamas, ar neigiamas rezultatas ir pažymėdavo 1 (rasta) arba 0 (nerasta).

Tokio masto krūtinės ląstos rentgeno nuotraukų rinkinys buvo išleistas pirmą kartą, todėl nuo jo atsiradimo jis buvo pradėtas naudoti, kaip etalonas visiems esamiems ir kuriamiems mašininio mokymosi modeliams.

2.2. CheXpert duomenų rinkinys

CheXpert tai naujausias ir didžiausias viešai prieinamas krūtinės ląstos rentgeno nuotraukų rinkinys išleistas 2019 metais Stanfordo universiteto mokslininkų, o rentgeno nuotraukos ir duomenys buvo surinkti iš Stanfordo ligoninės tyrimų, darytų 2002-2017 metais. Rinkinio vaizdų kiekis beveik dvigubai didesnis, nei prieš tai aprašytame ChestX-ray14 rinkinyje. CheXpert sudaro 223648 krūtinės ląstos priekinių (žr. 5 pav.) ir šoninių (žr. 6 pav.) rentgeno nuotraukų, ligų diagnozių ir kitų tyrimams svarbių duomenų apie pacientą (lytis, amžius, kelintas tyrimas) iš 65240 skirtingų pacientų. Rinkinyje yra 14 skirtingų klasių: 12 krūtinės ląstoje aptinkamų ligų, palaikymo įtaisai ir nerasta.

Klasėms priklausančių nuotraukų kiekio diagramoje (8 pav.) matosi klasių disbalansas, kaip ir pirmajame rinkinyje. Bet yra keli pastebimi skirtumai: klasių, kurios turi vaizdų akivaizdžiai virš vidurkio kiekis didesnis, vaizdų kiekis su klase nerasta sudaro tik apie 10% viso rinkinio nuotraukų, o tarp rinkinių sutampančių klasių tik 8.



8 pav. CheXpert duomenų rinkinio klasių pasiskirstymas

Visi duomenys apie rentgeno nuotrauką buvo išgauti iš rentgeno tyrimo aprašų, naudojant automatinį trijų etapų teksto išgavėją. Stanfordo mokslininkai savojo teksto išgavimo algoritmo rezultatus palygino su ChestX-ray14 duomenų rinkinio išgavėju. Bendrose klasėse CheXpert rinkinio išgavimo algoritmas pasirodė geriau [IRK⁺19], todėl galima tikėtis, jog šio duomenų rinkinio klasės ir jų nuotraukos bus tikslesnės. Kiekviena nuotrauka gali turėti keletą jai priskirtų klasių, o priskyrimas žymimas 0, jeigu neigiama, 1, jeigu teigiama ir -1, jeigu yra abejojama. Šis neapibrėžtumo pateikimas duomenų rinkinyje įgalina kurti KNT modelius atsižvelgiant į radiologo abejonės faktorių. 10 pav. (1 priedas) diagramoje pateikiama klasių abejotinų vaizdų kiekis.

2.3. Duomenų rinkinių paruošimas

KNT modelio apmokymas vyksta 3 etapais: apmokymas, validacija, testavimas. Geriausiems rezultatams pasiekti reikalingi skirtingi duomenų rinkiniai kiekvienam etapui. Abu duomenų rinkiniai turėjo savo sąrašus, kuriuose buvo nurodytas duomenų kiekis kiekvienam etapui (žr. 1 lentelę), kurių buvo nuspręsta laikytis tam, kad būtų kuo mažiau skirtumų pagrindiniame tiriamajame objekte - duomenų rinkiniuose.

1 lentelė. Duomenų rinkinių dydžiai

Etapas	ChestX-ray14	CheXpert
Apmokymas	73545	223414
Validacija	12979	234
Testavimas	25596	-

CheXpert testavimui atskirto duomenų rinkinio neturėjo, buvo pasirinkta naudoti validacijai skirtą duomenų rinkinio dalį. CheXpert rinkinio validacijos duomenys buvo patikrinti 3 radiologų, jie peržiūrėjo kiekvieną nuotrauką ir balsų daugumos principu (bent jau 2 iš 3) nuspręstas klasių pasiskirstymas. Tokiu būdu šis rinkinys panaikina bet kokio netikslumo galimybę, tarp validacijos klasių. Jį galima laikyti neginčytina tiesa (angl. ground truth) [IRK⁺19].

Abu duomenų rinkiniai turi klasių, kurios neegzistuoja kitame, todėl buvo nuspręsta skirtingų modelių palyginimą daryti iš 5 klasių: atelektazė, edema, kardiomegalija, konsolidacija ir efuzija.

Abiejų rinkinių vaizdų dydžiai buvo per dideli ir nevienodi tarpusavyje, todėl tyrime siekiant kuo geresnio tinklo apmokymo našumo, buvo nuspręsta visus vaizdus sumažinti iki 224x224 pikselių dydžio, kuris yra mažiausias modelio įvesties sluoksnio priimamas dydis.

3. Modelis

3.1. Modelio architektūra

Ligų iš krūtinės ląstos rentgeno nuotraukų atpažinimui buvo pasirinkta DenseNet architektūros variacija su keturiais tankiais blokais: DenseNet-121. Modelio sluoksnių skaičius 121, parametų skaičius arti 7 milijonų (6968206), o užimamas dydis RAM atmintyje - 27 MB.

Modelio paskutinis sluoksnis yra linijinis, todėl reikėjo modifikuoti esamą architektūrą pridėdant sluoksnį su sigmoidine (angl. sigmoid) aktyvacijos funkcija, kuri po pilnai sujungto paskutinio sluoksnio grąžina įvesties priklausymo tikimybę kiekvienai rinkinio klasei. Tokiu būdu modelis iš vienos teisingos klasės (angl. multiclass) sprendimui pritaikyto tapo kelių klasių (angl. multilabel) priskyrimo vaizdai pritaikytu modeliu.

Praktikoje retai pasitaiko, kad tyrinėtojai apmoko visą KNT nuo pat pradžių, tam yra keletas priežasčių:

- Reikalingas didelis laiko kiekis
- Reikalingas didelis kompiuterinių resursų kiekis
- Reikalingas didelis duomenų kiekis apmokymui

Todėl dažniausiai modeliai yra implementuojami iš karto su parametrais (angl. transfer learning), kurie paimami iš jau apmokyto tokio pačio modelio su tam tikru duomenų rinkiniu. Šiam tyrimui buvo pasirinktas DenseNet-121 modelis, su jau apskaičiuotais parametrais, pagal ImageNet duomenų rinkinį. Tokiu būdu, tinklui nebereikės išmokti atskirti linijų, abstrakčių figūrų, papildomo nereikšmingo triukšmo, kurio rentgeno nuotraukose yra nemažai (žr. 4 pav.) Tai padės modeliui mokytis tik esamo tyrimo vaizdų specifikos.

3.2. Modelio modifikacijos

Prieš KNT modelio apmokymą su pilnais duomenų rinkiniais, buvo atliekami bandymai nešiojamo kompiuterio aplinkoje, su pakankamai mažu duomenų kiekiu, kad galima būtų parinkti geriausius parametrus ir jų kombinacijas. Taip pat buvo sukurti du identiški modeliai, kurie skyrėsi tik klasių skaičiumi (14 ir 5) t.y. paskutinio sluoksnio išeinamu duomenų kiekiu.

3.2.1. Optimizavimo algoritmas

Pasirinktas Adam (angl Adaptive Moment Estimation) [Die14] optimizavimo algoritmas, dėl savo gana gerų numatytų parametų ir greitesnio modelio konvergavimosi, nei naudojant SGD (angl. Stochastic gradient descent) optimizavimo algoritmą. Verta pastebėti, kad buvo atlikti bandymai su ADAM algoritmo svorių mažinimo (angl. weight decay) parametru, nustačius jo reikšmę į 10^{-5} ir 10^{-4} . Atlikus bandymus nebuvo pasiektas greitesnis konvergavimas ar tikslumas, todėl buvo nuspręsta pasilikti prie standartinių numatytų parametų.

3.2.2. Mokymo greitis

Mokymo greitis - tai parametras, kuris leidžia kontroliuoti optimizavimo algoritmo, šiuo atveju ADAM, daromus pokyčius modelio svoriams, atsižvelgiant į nuostolių funkciją. Jeigu šis parametro skaičius yra labai mažas (10^{-8}), apmokymo etapas bus labai ilgas, todėl, kad bus daromi labai maži modelio parametrų pokyčiai. Per didelis mokymosi greičio parametras neleis KNT įsisavinti gilesnės informacijos ir modelis diverguos. Jis yra vienas iš svarbiausių parametrų, norint rasti optimumą tarp mokymosi laiko ir KNT modelio tikslumo. ADAM algoritmo implemetacijoje numatytas mokymosi greitis - 10^{-3} . Buvo atlikti bandymai su 10^{-3} , 10^{-4} , 10^{-5} reikšmėmis. Nustatyta, kad modelio tikslumas geresnis, kai mokymosi greitis 10^{-4} .

3.2.3. Mokymo greičio keitėjas

Mokymo greičiui nesikeičiant, po tam tikro apmokymų epochų skaičiaus, modelio mokymasis sulėtėja arba visai sustoja. Šiai problemai spręsti yra pasitelkiamas mokymo greičio keitėjas (angl. learning rate scheduler). Buvo atlikti bandymai su juo ir be jo. KNT modelio mokymosi AUROC buvo geresnis su mokymo greičio keitėju. Pasirinktas mokymo greičio keitėjas, kuris mokymo greičio keitimo poreikį skaičiuoja po kiekvienos epochos, atsižvelgiant į validavimo etapo nuostolių funkcijos vidutinę reikšmę. Tai reiškia, kad kai validavimo etapo nuostolių funkcijos reikšmė nesikeičia, arba didėja jau n epochų, mokymo greitis yra mažinamas.

3.2.4. Parinkti modelio parametrai

2 lentelėje pateikiami tolesnei tyrimo eigai parinkti KNT modelio parametrai. Nuostolių funkcija buvo pasirinkta binarinė kryžminė entropija (angl. BCE), o partijos dydis - 16.

2 lentelė. Modelio hiperparametrai

Parametras	Pasirinkimas
Nuostolių funkcija	BCE
Optimizavimo algoritmas	ADAM
Mokymo greitis	0.0001
Mokymo greičio keitėjas	kas 3 epochas
Partijos dydis	16

Parinkti parametrai buvo implementuoti KNT modelio kode, kuris buvo rašomas naudojant PyTorch karkasą.

3.3. Modelio apmokymas

Prieš modelio apmokymo su pilnais duomenų rinkiniais etapą, reikėjo praplėsti modelio implementaciją su papildomu funkcionalumu, tam, kad būtų tinkamai įgyvendintas eksperimentas. Apmokymo etapai:

1. 14 klasių modelis apmokomas su CheXpert duomenų rinkiniu

2. 14 klasių modelis apmokomas su ChestXnet-14 duomenų rinkiniu
3. 5 klasių modelis apmokomas su CheXpert duomenų rinkiniu
4. 5 klasių modelis apmokomas su ChestXnet-14 duomenų rinkiniu

Kiekvieno apmokymo etapo rezultatas - modelio svoriai, turi būti išsaugomas tolimesniai tyrimo eigai.

Kadangi modelis bus apmokomas su dviem skirtingais duomenų rinkiniais ir po to rezultatai ne tik lyginami tarpusavyje, bet ir atliekamas eksperimentas su kitais testiniais duomenų rinkiniais, reikia, kad modeliui mokantis, modelio efektyvumas būtų matuojamas dažniau, nei kas epochą, todėl, kad iteracijų kiekis per vieną epochą bus didelis. Jeigu einamojo validavimo žingsnio rezultatai yra geresni, nei prieš tai buvusio, modelio svoriai turi būti išsaugomi. Toks metodas yra dažnai taikomas praktikoje, kai dirbama su dideliais duomenų rinkiniais, nes tokiu būdu yra užtikrinami geriausi modelio parametrų išsaugojimo žingsniai.

3.4. Modelių apmokymo etapas

Vykdamas kiekvieną modelių apmokymo etapą, buvo gauti 4 KNT modelio svorių rinkiniai, kurie bus panaudoti duomenų rinkinių įtakai sužinoti, testavimo etape.

3.5. CheXpert konkursas

Stanfordo mokslininkai kartu su krūtinės ląstos nuotraukų rinkiniu pristatė konkursą tokiu pačiu pavadinimu [IRK⁺19]. Jo tikslas skatinti tyrinėtojus ieškoti ir rasti geriausią KNT modelį šiam duomenų rinkiniui ir penkių krūtinės ląstos ligų atpažinimui. Dalyvių konvoliucinio tinklo modelis yra patikrinamas su neviešinamu testinių duomenų rinkiniu, kuris buvo patikrintas radiologų, kad nustatyti neginčijamą tiesą. Po modelio validavimo yra išvedamas bendras AUROC rezultatas ir patalpinamas jų svetainėje.

Konkursui pristatytų modelių jau virš 30, tačiau pirmajame penketuke yra tik vienas modelis, kuris yra atviro kodo ir laisvai prieinamas GitHub repozitorijoje [Hea20]. Jo vidutinis AUROC 0.93. Kartu su modelio programiniu kodu yra pateikti apmokyto modelio svoriai.

4. Eksperimento vykdymas

4.1. Apmokymas

Vaizdai, kurie skirti tinklo apmokymui, buvo augmentuojami vienodai abiem rinkiniams, taikant šias technikas:

- Histogramų išlyginimas (angl. Histogram equalization)
- Konvertavimas iš Grayscale į 3 kanalų RGB
- Atsitiktinis pasukimas kampu(-15,15)
- Atsitiktinis horizontalus pavertimas
- Normalizacija, taikant ImageNet nustatytas normas

Tokiu būdu pasiekiame, kad abiejų duomenų rinkinių vaizdai būtų vienodos įeigos formos, sumažinant tyrimo rezultatų variaciją.

Pirmasis tyrimo etapas buvo 2 skirtingų modelių apmokymas naudojant 2 skirtingus duomenų rinkinius. Epochų skaičius nebuvo griežtai apibrėžtas, todėl, kad buvo suprogramuotas modelio svorių išsaugojimas, jeigu jo rezultatai yra geresni, nei prieš tai išsaugoto svorių rinkinio. Vienintelis reikalavimas - minimalus epochų skaičius 10.

4.2. Testavimas

Iš praeito apmokymo etapo kiekvienai modelio ir duomenų rinkinio kombinacijai buvo paimta po 1 svorių rinkinį, kuris turėjo geriausią visų klasių AUROC vidurkį. Skirtingų duomenų rinkinių palyginimui buvo paimtas tik 5 klasių modelis, todėl, kad 14 klasių modelis skyrėsi iš esmės, tarp duomenų rinkinių sutapo tik 8 klasės.

4.2.1. 14 klasių modelis apmokytas su ChestX-ray14 duomenų rinkiniu

3 lentelėje pateikiami AUROC rezultatai kiekvienai rinkinio klasei išskyrus „nerasta“. Validavimo etapo vidutinis AUROC 0.813, kas yra neblogai, tačiau aiškiai išsiskyrė infiltracija kurios vaizdų, iš visų krūtinės ląstos ligų duomenų rinkinyje buvo daugiausiai.

Testavimo etapo rezultatai buvo šiek tiek prastesni, tačiau labai nedaug. Testavimo rinkinio vidutinis AUROC 0.790. Infiltracija ir pneumonija buvo praščiausiai atpažįstamos ligos.

3 lentelė. 14 klasių modelio apmokyto su ChestX-ray14 rezultatai

Klasė	Validavimo rinkinio AUROC	Testavimo rinkinio AUROC
Atelektazė	0.824	0.757
Edema	0.914	0.828
Efuzija	0.895	0.823
Emfizema	0.890	0.866
Fibrozę	0.701	0.807
Infiltracija	0.595	0.705
Išvarža	0.840	0.845
Kardiomegalija	0.879	0.871
Konsolidacija	0.797	0.739
Masė	0.865	0.792
Mazgas	0.740	0.726
Pleuros sustorėjimas	0.802	0.751
Pneumonija	0.769	0.698
Pneumotoraksas	0.864	0.844
Vidutinis AUROC	0.813	0.790

4.2.2. 14 klasių modelis apmokytas su CheXpert duomenų rinkiniu

CheXpert duomenų rinkinys neturėjo savo atskiro testavimo rinkinio, todėl gauti rezultatai yra geriausio validavimo žingsnio. Vidutinis AUROC 0.777 (žr. 4 lent.), kuris yra prastesnis nei ChestX-ray14 validavimo ir testavimo etapų vidurkiai. Mažiausiai tikslumo turėjusios klasės - išsiplėtęs kardiomediascinas - 0.683 ir atelektazė 0.680. Tai labai prasti rezultatai, rodantys, kad KNT modelis neprisitaikė prie kai kurių duomenų rinkinio klasių.

4 lentelė. 14 klasių modelio apmokyto su CheXpert rezultatai

Klasė	Validavimo rinkinio AUROC
Atelektazė	0.680
Edema	0.802
Efuzija	0.850
Išsiplėtęs kardiomediascinas	0.683
Kardiomegalija	0.831
Konsolidacija	0.739
Lūžis	0.753
Nerasta	0.847
Palaikymo įtaisai	0.854
Plaučių neskaidrumas	0.724
Plaučių pažeidimas	0.777
Pleuros kita	0.749
Pneumonija	0.744
Pneumotoraksas	0.835
Vidutinis AUROC	0.777

4.2.3. 5 klasių modelis apmokytas su ChestX-ray14 duomenų rinkiniu

5 krūtinės ląstos ligų modelis, apmokytas su ChestX-ray14 duomenų rinkiniu, validavimo etape parodė tikrai neblogus rezultatus - AUROC vidurkis, 0.869 (žr. 5 lent.) , nuo kurio labiausiai nutolusi konsolidacijos klasė - 0.792. Apjungus šiuos ir to pačio rinkinio bet 14 klasių modelio rezultatus, matosi, kad atskirų klasių AUROC yra gana panašūs. Šiame bandyme didesnis skirtumas pasimatė tarp validavimo rinkinio ir testavimo rinkinio. Skirtumas tarp AUROC net 0.069.

Šis modelis buvo testuojamas su jam visai nematytu vaizdų duomenų rinkiniu - CheXpert. Modelio prisitaikymas prie visai kito duomenų rinkinio, nei jis yra matęs - tikrai geras. Vidutinis AUROC 0.808 yra beveik toks pat, kaip ir testavimo rinkiniui. Galima teigti, jog duomenų rinkinio pasikeitimas didelės įtakos neturėjo.

5 lentelė. 5 klasių modelio apmokyto su ChestX-ray14 rezultatai

Klasė	Validavimo AUROC	Testavimo AUROC	CheXpert AUROC
Atelektazė	0.838	0.758	0.815
Edema	0.904	0.821	0.743
Efuzija	0.899	0.819	0.838
Kardiomegalija	0.908	0.875	0.782
Konsolidacija	0.792	0.723	0.8617
Vidutinis AUROC	0.869	0.800	0.808

4.2.4. 5 klasių modelis apmokytas su CheXpert duomenų rinkiniu

5 krūtinės ląstos ligų KNT modelis, validavimo etape pasiekė viso tyrimo geriausią rezultatą - vidutinis AUROC 0.890 (žr. 6 lent.). Prasčiausiai aptinkamos ligos - kardiomegalija ir Atelektazė (0.830 ir 0.839). Nuo tokio pačio 5 klasių modelio, tik apmokyto su ChestX-ray14 vidutinio AUROC skirtumas 0.021. Taip pat didelis skirtumas tarp to pačio duomenų rinkinio apmokyto šio ir 14 klasių modelio, šis lenkė pastarąjį daugiau nei 0.1 tikslumu.

Testavimo etape modelis parodė neprisitaikymą nematytam duomenų rinkiniui ChestX-ray14. Validavimo ir testavimo etapų skirtumas labai didelis - šiek tiek daugiau nei 0.1.

6 lentelė. 5 klasių modelio apmokyto su CheXpert rezultatai

Klasė	Validavimo rinkinio AUROC	ChestX-ray14 testavimo rinkinio AUROC
Atelektazė	0.839	0.740
Edema	0.929	0.816
Efuzija	0.925	0.812
Kardiomegalija	0.830	0.862
Konsolidacija	0.923	0.70
Vidutinis AUROC	0.890	0.787

Rezultatai

1. Šio darbo metu buvo atlikta konvoliucinių neuroninių tinklų analizė. Buvo susipažinta su jų veikimo principais ir architektūromis. Sužinota, kokios KNT architektūros populiariausios ir kur jos yra taikomos. Buvo pasirinkta DenseNet-121 architektūra, kurios gylis, ImageNet duomenų rinkinio rezultatai ir parametų skaičius labiausiai tenkina iškeltus reikalavimus - našumo ir tikslumo derinys.
2. Tyrimo įgyvendinimui reikėjo dviejų, ar daugiau krūtinės ląstos rentgeno nuotraukų duomenų rinkinių, ieškant tinkamiausių, buvo išsiaiškinta, kokie duomenys turi būti, norint pasiekti gerų rezultatų. Taip pat buvo išsiaiškinta, kodėl tiek mažai rinkinių ir ne visi laisvai pasiekiami - tai paciento teisės ir duomenų apsauga. Pasirinkti 2 laisvai pasiekiami duomenų rinkiniai: ChestX-ray14 bei CheXpert. Atliekant šių krūtinės ląstos rentgenogramų rinkinių analizę, buvo išsiaiškinta, jog tokio pobūdžio nuotraukos turi papildomų detalių - triukšmo (žr. 4 pav.), kuris gali daryti įtaką KNT modelio rezultatų tikslumui.

Abu rinkiniai atrodė panašios kokybės, tačiau atlikus klasių pasiskirstymo (žr. 7, 8, 9, 10 pav.) palyginimą išryškėjo skirtumai: „sergančių“ ir „sveikų“ vaizdų santykis ChestX-ray14 yra beveik 1:1 ir tuo pačiu - dominuojanti klasė „nerasta“, kadangi ši - 15 klasė, nebuvo mokoma modelio klasifikuoti, galima sakyti, kad rinkinys buvo pusiau balansuotas, nors apmokymui skirtą duomenų rinkinio dalį sudarė tik 73,5 tūkst. vaizdų.

CheXpert rinkinys pasirodė daug solidesnis. Virš 200000 vaizdų, kurie buvo suskirstyti į 14 klasių, tačiau klasių disbalansas yra didesnis (žr. 8 pav.): palaikymo įtaisai, plaučių neskaidrumas - kiekvienas turi bent po 90 tūkstančių vaizdinių, netoli šios ribos ir klasė efuzija. Kitos klasės yra grupėse iki 20 tūkst. arba daugiau.

3. Ruošiant tyrimui reikalingą KNT modelį buvo susipažinta su PyTorch karkasu ir jo bibliotekomis. Teko pasinaudoti keliomis papildomomis integracijomis, pavyzdžiui TensorBoard, todėl, kad karkasas neturėjo tam tikrų apmokymų stebėjimui reikalingų vizualinių galimybių. Darant bandymus su mažu kiekiu duomenų ir ieškant geriausių hiperparametų pilnam modelio apmokymui, buvo išnagrinėtos nuostolių funkcijos ir jų sąryšis su optimizavimo algoritmais. Prieš pilną apmokymą atliktų bandymų dėka, išsiaiškintas geriausias mokymosi greičio parametras DenseNet-121 architektūros modeliui - 0.0001. Šio etapo rezultatas - modifikuotas DenseNet-121 modelis ir paruoštas pilnam apmokymui ir testavimui.
4. Šio darbo tikslas buvo išsiaiškinti skirtingų duomenų rinkinių įtaką konvoliuciniam neuroniniam tinklui atpažįstant plaučių ligas rentgeno nuotraukose, kad jis būtų pasiektas, reikėjo įvykdyti eksperimentą su išsirinktu KNT modeliu ir duomenų rinkiniais. Gauti rezultatai - abiejų rinkinių apmokyti 5 klasių modeliai turėjo didesnę AUROC tikslumą, lyginant su 14 klasių tais pačiais rinkiniais apmokytus modelius. Absoliučiai geriausiai pasirodęs modelis - 5 klasių ir apmokytas naudojant CheXpert krūtinės ląstos rentgeno nuotraukų rinkinį. Jo AUROC - 0.890 validavimo etape. Verta paminėti, kad tik CheXpert validacijos rinkinys buvo peržiūrėtas radiologų.

Modelių su 5 klasėmis ir skirtingais duomenų rinkiniais testavimo etape sąlyginai geriau pasirodė su ChestX-ray14 apmokytas modelis, tačiau bet kuriuo atveju abiejų modelių validacijos etapų AUC buvo aukštesni, nei testavimo su visiškai nematytais vaizdais, iš kito rinkinio.

Išvados

Atlikus tyrimą, ar skirtingi duomenų rinkiniai daro įtaką konvoliuciniam neuroniniam tinklui atpažįstant plaučių ligas rentgeno nuotraukose buvo padarytos išvados:

1. Duomenų rinkinio dydis didelės įtakos neturi, jei yra naudojamas jau apmokytas modelis su kitu dideliu duomenų rinkiniu (pvz. ImageNet). Tyrimo metu 14 klasių modeliai buvo apmokyti su skirtingais duomenų rinkiniais, kurių dydžiai skiriasi dvigubai. Rinkinio, kuris turėjo dvigubai mažiau nuotraukų, apmokymo vidutinis AUROC 0.813, o modelio kurio rinkinį sudarė virš 200 tūkst. vaizdų - AUROC 0.777.
2. Duomenų rinkinio išgavimo būdas turi įtakos KNT modelio rezultatams. Penkių klasių modelis apmokytas CheXpert duomenų rinkiniu, kurio klasių išgavimo metodas yra geresnis, savo validavimo etape vidutinis AUROC 0.890, o su ChestX-ray14 apmokytas modelis CheXpert validavimo rinkiniu - 0.808.
3. Aplinka, iš kurios yra surinktas duomenų rinkinys (tyrimo atveju ligoninės) turi įtakos KNT modelio daromiems sprendimams. Jeigu modelio apmokymui duomenų rinkinys yra surinktas tik iš vienos medicininės įstaigos, negalima teigti, jog tas modelis rodys tuos pačius rezultatus, jį taikant kitos įstaigos nuotraukoms. Penkių klasių modelis apmokytas CheXpert duomenų rinkiniu, validavimo etapo vidutinis AUROC 0.890, tačiau ChestX-ray14 testavimo etapo vidutinis AUROC 0.787.

Literatūra

- [Cod04] Papers With Code. Image classification on imagenet. <https://paperswithcode.com/sota/image-classification-on-imagenet>, 2004. 45 KB, žiūrėta 2020-05-10.
- [Die14] Jimmy B Diederik P. Kingma. Adam: a method for stochastic optimization. <https://arxiv.org/abs/1412.6980v9>, 2014.
- [EUR20] EUROSTAT. Mirties priežasčių statistika. https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Causes_of_death_statistics/lt#Papildoma_Eurostato_informacija, 2020. žiūrėta 2020-05-04.
- [GPC⁺16] Varun Gulshan, Lily Peng, Marc Coram, Martin C. Stumpe, and Derek Wu. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs, 2016.
- [GWaM⁺17] Jiuxiang Gu, Zhenhua Wang, Jason Kuen and Lianyang Ma, Amir Shahroudy, et al. Recent advances in convolutional neural networks. <https://arxiv.org/abs/1512.07108>, 2017.
- [Haf98] Y. Lecun ; L. Bottou ; Y. Bengio ; P. Haffner. Gradient-based learning applied to document recognition. http://vision.stanford.edu/cs598_spring07/papers/Lecun98.pdf, 1998.
- [Hea20] JF Healthcare. Top1 solution of chexpert. <https://github.com/jfhealthcare/Chexpert>, 2020.
- [HLvdM⁺16] Gao Huang, Zhuang Liu, Laurens van der Maaten, and Kilian Q. Weinberger. Densely connected convolutional networks. <https://arxiv.org/abs/1608.06993v5>, 2016.
- [IRK⁺19] Jeremy Irvin, Pranav Rajpurkar, Michael Ko, Yifan Yu, et al. Chexpert: a large chest radiograph dataset with uncertainty labels and expert comparison. <https://arxiv.org/abs/1901.07031v1>, 2019.
- [KSH12] A. Krizhevsky, I. Sutskever, and G. E. Hinton. Imagenet classification with deep convolutional neural networks. <https://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks.pdf>, 2012.
- [KSZ20] A. Khan, A. Sohail, and U. et al. Zahoora. A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, 2018, 2020.
- [LUC⁺19] Saifeng Liu, David Utriainen, Chao Chai, Yongsheng Chen, Lin Wang, Sean K Sethi, Shuang Xia, and E Mark Haacke. Cerebral microbleed detection using susceptibility weighted imaging and deep learning. *NeuroImage*, 198:271–282, 2019.

- [RDS⁺19] Olga Russakovsky, Jia Deng, Hao Su, Jonathan Krause, et al. Imagenet large scale visual recognition challenge. <https://arxiv.org/abs/1409.0575v3>, 2019.
- [RNZ17] Muhammad Imran Razzak, Saeeda Naz, and Ahmad Zaib. Deep learning for medical image processing: overview, challenges and future. <https://arxiv.org/abs/1704.06825v1>, 2017.
- [Suz11] Kenji Suzuki. *Artificial Neural Networks - Methodological Advances and Biomedical Applications*. InTech, 2011. 1-11p.
- [WPL⁺17] Xiaosong Wang, Yifan Peng, Le Lu, Zhiyong Lu, Mohammadhadi Bagheri, and Ronald M. Summers. Chestx-ray8: hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases. <https://arxiv.org/abs/1705.02315v5>, 2017.
- [ZTR⁺19] Ningning Zhao, Nuo Tong, Dan Ruan, and Ke Sheng. Fully automated pancreas segmentation with two-stage 3d convolutional neural networks. <https://arxiv.org/abs/1906.01795v2>, 2019.

Sąvokų apibrėžimai

AUROC - (angl. area under the receiver operating characteristic) tai efektyvumo matas naudojamas įvertinti klasifikavimo modelius.

Epocha - (angl. epoch) neuroninių tinklų hiperparametras, nurodantis, kiek kartų mokymo etape turi būti panaudoti visi duomenys iš duomenų rinkinio.

Hiperparametras - (angl. hyperparameter) tai neuroninių tinklų kintamasis, kuris nustatomas prieš mokymo etapą. Tai gali būti tinklo struktūrinis kintamasis arba kintamasis, kuris nurodo kaip tinklas bus mokomas.

Santrumpos


AUC - AUROC

DNT - Dirbtinis neuroninis tinklas


KNT - Konvoliucinis neuroninis tinklas

ReLU - (angl. Rectified Linear Unit) dalimis tiesinė funkcija

1 priedas



9 pav. ChestX-ray 14 klasės be „nerasta“



10 pav. CheXpert abejotinių klasių kiekis