

ДЕТЕКЦИЈА БОЛЕСТИ КОВИД-19 НА СНИМЦИМА ПЛУЋА УПОТРЕБОМ
КОНВОЛУЦИОНИХ НЕУРОНСКИХ МРЕЖАDETECTION OF COVID-19 VIRUS ON CT SCANS USING CONVOLUTIONAL NEURAL
NETWORKS

Никола Ђуровић, Факултет техничких наука, Нови Сад

Област – ЕЛЕКТРОТЕХНИКА И РАЧУНАРСТВО

Кратак садржај – Пандемија КОВИД-19 вируса изазвала је глобалну кризу са великим бројем случајева и смртних исхода. У раду се истражује употреба снимака плућа добијених употребом компјутерске томографије (ЦТ) за брзу детекцију вируса, користећи дубоко учење и различите моделе конволуционих неуронских мрежа. Рад анализира претходна решења, теорију конволуционих неуронских мрежа, имплементацију модела и презентује добијене резултате.

Кључне речи: машинско учење, конволуционе неуронске мреже, дубоко учење, класификација

Abstract – The COVID-19 pandemic has triggered a global crisis with a high number of cases and fatalities. This paper explores the use of lung images obtained through computer tomography (CT) for the rapid detection of the virus, employing deep learning and various convolutional neural network (CNN) models. The paper analyzes previous solutions, convolutional neural networks theory, describes model implementation, and presents the obtained results.

Keywords: machine learning, convolutional neural networks, deep learning, classification

1. УВОД

Пандемија COVID-19 вируса представља глобалну кризу са великим бројем потврђених случајева и смртних исхода. Вирус се брзо шири и изазива симптоме као што су кашаљ, грозница и респираторне проблеме. Поред PCR и антигенских тестова, за откривање болести се користи и прецизнија компјутерска томографија (ЦТ) иако се појављује ризик од зрачења. Упркос потенцијалним ризицима, ЦТ се сматра бржом и поузданијом техником за дијагнозу КОВИД-19 вируса [1]. Метода захтева присуство радиолога, што може бити изазов. Аутоматизација анализе ЦТ снимака постаје пожељна како би се омогућила брза дијагноза болести. Проблеми у анализи медицинских слика често произилазе из недостатка јавно доступних ЦТ снимака због заштите приватности пацијената.

НАПОМЕНА:

Овај рад проистекао је из мастер рада чији ментор је био др Владимир Бугарски, доцент.

Зато се често користи метода пренесеног учења, користећи већ обучене моделе. Дубоко учење се истиче као ефикасан метод за класификацију медицинских слика и дијагнозу болести. У овом истраживању су предложени модели за откривање КОВИД-19 на основу ЦТ снимака, користећи различите мрежне архитектуре. Истражене су и различите технике подешавања параметара и обогаћивања скупа података. Рад пружа преглед постојећих решења, теоријски оквир неуронских мрежа и детаље имплементације предложених модела.

2. ПОСТОЈЕЋИ МОДЕЛИ

У овом раду користе се подаци са *Kaggle* платформе [2], који су једни од ретких јавно доступних скупова података са ЦТ снимцима плућа за анализу КОВИД-19. Скуп података се састоји од 1.252 КОВИД-19 снимка и 1.229 снимака здравих плућа, димензија 224x224x3 пиксела.

У раду [3], исти скуп података се користи за испитивање ефикасности различитих модела дубоког учења и пренесеног учења. *InceptionV3* модел постиже највишу тачност од 99,59%, док је *VGG16* најмање ефикасан са тачношћу од 69,08%.

У [4], користе се подаци прикупљени из четири института у Кини, са 346 КОВИД снимака и 463 снимака здравих плућа. Разматране су различите архитектуре, укључујући *CTnet-10*, *VGG-19*, *Inception V3*, *DenseNet-169* и *VGG-16*. Најбољи резултат постиже *VGG-19* са тачношћу од 94,12%, док *Inception V3* има најнижу тачност од 53,14%. *CTnet-10* показује добре резултате са тачношћу од 82,1%, а обучавање овог модела траје најкраће (130 секунди).

У истраживању [5], користи се највећи скуп података из Кине са додатном техником обогаћивања података. Развијен је модел за вишеструку класификацију са тачношћу од 99%, способан за детекцију КОВИД-19, других облика пнеумоније и здравих плућа.

У раду [6], користи се велики скуп података који није јавно доступан, са укупно 63.849 снимака. Разматране су архитектуре као што су *Xception*, *ResNet50* и модел развијен од аутора овог рада за ову сврху. Модел који комбинује *Xception* и *ResNet50* постиже тачност од 98%, уз примену различитих техника обогаћивања података.

Ова истраживања показују различите приступе и моделе за детекцију КОВИД-19 на основу ЦТ снимака плућа.

3. НЕУРОНСКЕ МРЕЖЕ

Вештачке неуронске мреже су један од алгоритама учења са надзором. Класификација улазних података, на основу њихових карактеристика, у једну од класа је задатак истренираног модела. Вештачки неурон је основни градивни елемент сваке вештачке неуронске мреже, које представљају основ за разумевање конволуционих неуронских мрежа.

3.1. Конволуционе неуронске мреже

Конволуционе неуронске мреже (*КНН*) су посебне врсте неуронских мрежа које су намењене за обраду визуелних података као што су слике и видео записи. Основна сврха ових мрежа је идентификација облика, карактеристика и шаблона у овим подацима.

КНН користе низ слојева за постизање овог циља:

- **Конволуциони слојеви:** Ови слојеви примењују филтере на улазне податке како би открили различите карактеристике, као што су ивице, углови и текстуре. Ово омогућава мрежи да научи репрезентације слика на различитим нивоима апстракције.
- **Слојеви за сажимање (*pooling*):** Ови слојеви служе за смањење димензионалности података тако што задржавају најважније информације из претходних слојева. Најчешће се користи сажимање максимумом, где се узима максимална вредност из одређених региона.
- **Слој равнања:** Задужен је да вишедимензионалне низове који се добијају као излази из претходних слојева трансформише у једнодимензионални вектор
- **Нормализациони слојеви:** Додавање нормализационих слојева се користи када улазне вредности неке неуронске мреже нису у истом распону, те се помоћу ових слојева све вредности скалирају на исти опсег, што се одражава на време трајања тренинга или конвергирања мреже.
- **Потпуно повезани слојеви:** Након издвајања карактеристика у претходним слојевима, потпуно повезани слојеви се користе за класификацију или регресију. Ови слојеви донесу крајње одлуке на основу научених карактеристика.

Конволуционе неуронске мреже су широко коришћене у разним задацима обраде слика, као што су класификација објеката, детекција лица, сегментација слика и друге апликације у области компјутерске визије. Њихова архитектура омогућава ефикасно препознавање облика и структура у визуелним подацима, чинећи их кључним алатом у домену дубоког учења.

3.2. Параметри мреже

Развој и обука конволуционих неуронских мрежа је комплексан процес који захтева пажљиву селекцију и конфигурацију различитих компоненти како би се постигао висок ниво тачности и генерализације модела. Неколико кључних аспеката овог процеса су:

Подела података

Први корак је подела доступних података на три основна скупа:

- **Тренинг скуп:** Овај скуп се користи за обуку мреже. Обично чини већину доступних података (нпр. 60% - 80%). Модел се прилагођава овим подацима како би минимизирао грешку и унапредио своју способност класификације.
- **Валидациони скуп:** Валидациони скуп се користи током тренинга како би се пратила перформанса модела на подацима које није видео током тренинга. То је важно за детекцију претераног прилагођавања и оптимизацију параметара.
- **Тестни скуп:** Овај скуп се користи за коначну евалуацију перформанси модела након што је тренинг завршен. Модел се тестира на овим подацима како би се проценило његово понашање на потпуно новим подацима.

Параметри и активационе функције

Параметри и активационе функције играју кључну улогу у архитектури *КНН*-а. Одабир функција губитка, броја скривених слојева, броја кернела, величина слојева за сажимање и иницијалне тежине директно утичу на перформансе модела. Активационе функције као што су *ReLU*, хиперболички тангенс и софтмакс играју кључну улогу у преносу информација кроз мрежу и брзини учења.

Регуларизација

Да би се спречило претерано прилагођавање модела на тренинг подацима, користе се различите регуларизационе технике. То укључује:

- **Искључивање (*Dropout*):** Ово је техника која насумично искључује неуроне током тренинга како би се повећала робусност и генерализација модела.
- **L2 и L1 регуларизација:** Додавање казних израза у функцију губитка како би се тежине држале мале и спречило преприлагођавање.
- **Рано заустављање (*Early stopping*):** Праћење разлике у вредностима функције губитка током тренинга и прекидање тренинга ако се перформансе на валидационом скупу погоршавају.
- **Обогаћивање података:** Када су доступни подаци ограничени, примена трансформација на улазне слике, као што су ротација, обртање, померање, зумирање и др. може помоћи у повећању количине доступних података и унапређењу генерализације.

Пренесено учење


У области компјутерске визије, где се често користе велики скупови података, пренесено учење је моћна техника. Ово подразумева коришћење већ обучених модела (нпр. *VGG-16*, *ResNet*) као основе за обуку нових модела за специфичне задатке. Ово може значајно убрзати процес тренинга и побољшати перформансе. Одабир архитектуре модела, као што су *VGG-16*, *VGG-19*, *ResNet50*, *InceptionV3*, *MobileNet* и *Xception*, такође игра кључну улогу. Свака од ових

архитектура има своје специфичне карактеристике и предности.

У суштини, развој и обука КНН-а захтева балансирање многих фактора како би се постигле високе перформансе и генерализација на циљаном задатку. Правилно конфигурисање ових компоненти је кључно за развој поузданог и ефикасног модела неуронске мреже.

4. РЕЗУЛТАТИ И ДИСКУСИЈА

За обуку модела коришћен је *Google Colaboratory* алат, који је бесплатна платформа за извршавање *python* кода на *cloud-u*. Овај алат пружа интерактивно окружење за писање и извршавање кода користећи Јупитер свеске, а такође омогућава приступ графичким и тензор процесорским јединицама (ГПУ и ТПУ) за убрзање рачунања, што је посебно важно код дубоког учења. Коришћени подаци су прикупљени у болници у Сао Паолу, у Бразилу, са циљем развоја модела за рано откривање вируса. Примери снимака из скупа података приказани су на слици 1.



Слика 1. Примери ЦТ снимака плућа из скупа података

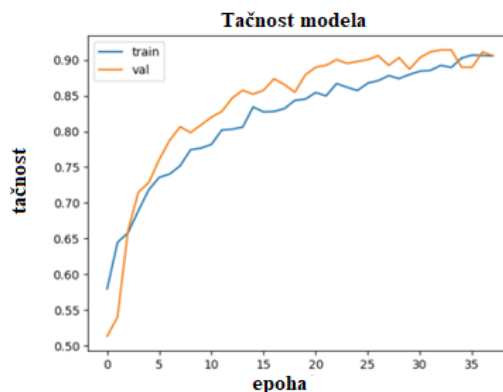
У истраживању су размотрене различите архитектуре КНН модела, укључујући једноставније моделе са неколико конволуционих слојева и слојевима за сажимање, али и комплексније моделе. Разматране су различите технике за постизање бољих перформанси модела, као што су слојеви искључивања, Л2 регуларизација, рано заустављање и обогаћивање података. Као резултат овог истраживања, развијен је модел који постиже тачност од **90%** у детекцији КОВИД-19 вируса на ЦТ снимцима плућа. Осим тога, истраживање упоређује овај модел са другим моделима базираним на пренесеном учењу (*Inception V3*, *VGG-19* и *Xception*), приказујући сличне резултате у тачности детекције.

Развој архитектуре за детекцију КОВИД-19 на ЦТ снимцима плућа почео је са основном конфигурацијом неуронске мреже. Та архитектура укључивала је само 2 конволуциона слоја, слојеве за сажимање и потпуно повезане слојеве. Међутим, током експериментисања са овом почетном конфигурацијом, појавило се неколико проблема. Први проблем је претерано прилагођавање модела подацима за тренинг, што значи да је модел имао веома добре перформансе на тренинг скупу, али је на валидационом и тест скупу лоше генерализовао. Примећене су и осцилације у перформансама модела током тренинга, што указује на нестабилне резултате. У циљу решавања ових проблема вршени су експерименти са различитим техникама и конфигурацијама. Прва промена укључивала је додавање регуларизационих техника, попут *batch* нормализације и слојева искључивања. Ове технике су помогле да се

смањи претерано прилагођавање, али осцилације су и даље биле присутне. Следећа измена је била повећање броја филтера у конволуционим слојевима и додавање Л2 регуларизације, што је делимично побољшало перформансе, али осцилације су и даље биле проблем. Кључни тренутак у побољшању архитектуре дошао је када су постављена 2 уместо 1 неурона на излазном слоју мреже. То је довело до преласка са бинарне на категоријску унакрсну ентропију када је у питању функција губитка, и коришћење софтверских активационих функција. Ово је значајно побољшало тачност и смањило претерано прилагођавање.

Додатно је прилагођена стопа учења и подешени су параметри на слоју искључивања како би се смањиле осцилације и добили стабилнији резултати током тренинга. Коначно, најбољи резултати су постигнути са финалном архитектуром која се састојала од дванаест слојева, од којих су по 2 конволуциона и *batch* нормализациона слоја, 2 слоја сажимања, 3 слоја искључивања и по 1 потпуно повезани, слој равнања и излазни слој.

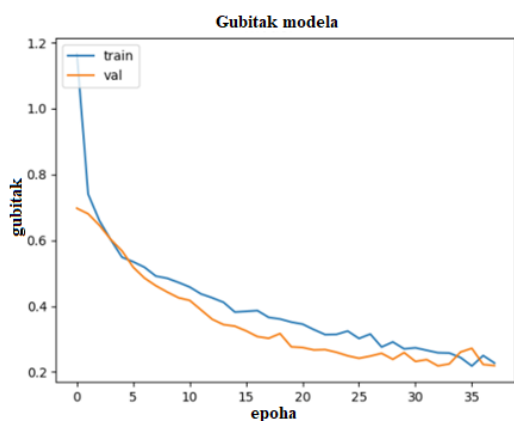
Коришћена је и техника раног заустављања како би се елиминисале осцилације. Постигнута је највиша тачност од **90%** и најмањи губитак од **0,2** на свим скуповима података. Број епоха је био 50, величина *batch-a* 64, а стопа учења 0,0001. Изабран је АДАМ тип оптимизатора. Параметар на прва два слоја искључивања је подешен на 0,2, а на трећем слоју, који се налази непосредно иза излазног слоја, је 0,5. На слици 2 графички је приказана тачност, а на слици 3 губитак на овом моделу. Ова архитектура је се показала као стабилна и добро је генерализовала нове податке, елиминишући претходне проблеме.



Слика 2. Тачност модела на финалној архитектури

Када је у питању пренесено учење, резултати који су постигнути код одређених модела пренесеног учења су сумирани у табели 1. *VGG-19* модел достигао је тачност од 93,79%. Коришћен је АДАМ оптимизатор, а максималан број епоха је 30. Стопа учења је постављена на 0,0001, а величина *batch-a* на 32. Коришћени су исти параметри као и у раду [5]. *Inception V3* архитектура је постигла тачност од 99,19%. Максималан број епоха је 100, а коришћен је АДАМ оптимизатор и стопа учења од 0,001 и величина *batch-a* 16. Коришћена је и регуларизациона техника раног заустављања, а примећени су параметри из рада [4]. *Xception* модел је показао тачност од 97,55%. Максималан број епоха је 50,

величина *batch-a* је 16, а оптимизатор АДАМ. Стопа учења је подешена на 0,0001. Сви параметри су узети из рада [10].



Слика 3. Губитак модела на финалној архитектури

Табела 1. Резултати на моделима пренесеног учења

| Модел | Тачност |
|--------------|---------|
| VGG-19 | 93,79% |
| Inception V3 | 99,19% |
| Xception | 97,55% |

Предности модела у разматраним радовима [3, 4, 5, 6] у односу на моделе који су развијани у овом раду, огледају се у пажљивијем бирању параметара мреже, али и у много већим и разноврснијим скуповима података.

5. ЗАКЉУЧАК

У овом раду, истраживање је спроведено са циљем развијања ефикасног система за детекцију КОВИД-19 вируса на ЦТ снимцима плућа применом конволуционих неуронских мрежа. Након пажљиве анализе најновијих достигнућа у овој области, примењене су неке нове архитектуре како би се показала њихова ефикасност код решавања оваквог медицинског проблема.

Кључни допринос овог рада огледа се у развоју иновативне архитектуре неуронске мреже која је пројектована да ефикасно препознаје и класификује присуство КОВИД-19 вируса на ЦТ снимцима плућа. Кроз систематично експериментисање и оптимизацију параметра, постигнута је тачност од **90%**.

Резултати овог рада наглашавају важност примене дубоког учења и конволуционих неуронских мрежа у медицинској дијагностици, посебно у контексту глобалне пандемије која је трајала до маја 2023. године. Употреба ЦТ снимака плућа као улазних података омогућила је брзу, неинвазивну и поуздану детекцију вируса, чиме се медицинском особљу пружа моћан алат у борби против ове болести.


Ипак, треба напоменути да даље истраживање и валидација резултата на већем скупу података треба да се спроведе како би се потврдила генерализација и поузданост предложене архитектуре. Такође, потребно је истражити могућности за унапређење ефикасности оваквог система, као и интеграцију у клиничку праксу ради шире примене и помоћи докторима за лакшу и бржу детекцију болести.

Овај рад је дао допринос у пољу дијагностике КОВИД-19 вируса применом конволуционих неуронских мрежа на ЦТ снимцима плућа. Резултати и предложене архитектуре отварају врата за даље истраживање и развој напредних метода детекције овог вируса, која би могла бити од кључне важности за брзу и прецизну дијагнозу.

6. ЛИТЕРАТУРА

- [1] A. Bernheim, X. Mei, M. Huang, Y. Yang, Z.A. Fayad, N. Zhang, K. Diao, B. Lin, X. Zhu, K. Li, "Chest CT findings in coronavirus disease 2019 (COVID-19): Relationship to duration of infection." *Radiology*, Vol. 295, pp. 685–691, 2020.
- [2] <https://www.kaggle.com/datasets/plameneduardo/sarscov2-ctscan-dataset> (pristupljeno u avgustu 2023.)
- [3] M.M. Sufian, E.G. Moung, M.H.A. Hijazi, F. Yahya, J.A. Dargham, A. Farzamnia, F. Sia, N.F. Mohd Naim, "COVID-19 Classification through Deep Learning Models with Three-Channel Grayscale CT Images." *Big Data Cogn. Comput.*, 7, 36, 2023.
- [4] V. Shah, R. Keniya, A. Shridharani, M. Punjabi, J. Shah, N. Mehendale, "Diagnosis of COVID-19 using CT scan images and deep learning techniques." *Emerg Radiol*, Vol. 28(3), pp. 497-505, 2021.
- [5] W. Zhao, W. Jiang, X. Qiu, "Deep learning for COVID-19 detection based on CT images." *Sci Rep*, 11, 14353, 2021.
- [6] M. Rahimzadeh, A. Attar, S.M. Sakhaei, "A fully automated deep learning-based network for detecting COVID-19 from a new and large lung CT scan dataset." *Biomed Signal Process Control*, 68, 102588, 2021.

Кратка биографија:



Никола Ђуровић уписао је Факултет техничких наука, смер рачунарство и аутоматика. 2021. године завршава основне академске студије са просечном оценом 9,22, а исте године уписује мастер студије на истом смеру. Положио је све испите на мастер академским студијама предвиђене планом и програмом са просечном оценом 10.
контакт: ndjurovic53@yahoo.com