



ЮГОЗАПАДЕН УНИВЕРСИТЕТ „НЕОФИТ РИЛСКИ”
Природо-математически факултет
Катедра „Математика”

Ирина Добрева Наскинова

МАТЕМАТИЧЕСКИ И КОМПЮТЪРНИ МОДЕЛИ ЗА
ИНТЕЛИГЕНТЕН АНАЛИЗ НА ДАННИ В МЕДИЦИНАТА

АВТОРЕФЕРАТ

на дисертация за присъждане на образователна и научна степен
„доктор” в област на висше образование 4. Природни науки,
математика и информатика, професионално направление 4.5.
Математика, докторска програма: Математическо моделиране и
приложение на математиката

Научни ръководители:
Доц. д-р Михаил Колев
Доц. д-р Мариян Милев

Благоевград
2023

Дисертационният труд се състои от увод, пет глави, заключение, приложение, библиография и списък с публикации по темата. Библиографската справка съдържа 111 заглавия на английски език. Общият обем на дисертацията е 244 страници. Размерът на страницата е във формат А4.

Дисертационният труд е обсъден и предложен за защита от разширен съвет на катедра „Математика“ към Природоматематически факултет при Югозападен университет „Неофит Рилски“ - Благоевград, което ще се състои на 04.07.2023 г.

СЪДЪРЖАНИЕ

УВОД.....	5
1. Литературен обзор, посветен на математическите модели, на които се основава интелигентен анализ на данни, в частност невронните мрежи.....	17
2. Математически модели и подходи, използвани при конструирането на класификационни невронни мрежи.....	23
2.1. Биологични бележки относно моделите за 23	
диагностика на пневмония	23
2.2. Преглед на научните изследвания за използване.....	23
на изкуствен интелект в рентгеновата диагностика.....	23
2.3. Изводи към глава втора.....	24
3. Създаване, усъвършенстване и изследване на математически модели, реализирани чрез невронни мрежи за рентгенова диагностика на пневмония	25
3.1. Описание на данните	25
3.2. Предварителна обработка на данните	25
3.3. Базов модел за диагностика на пневмония	25
3.4. Разширен модел за диагностика на пневмония	25
3.5. Изводи към глава трета	31
4. Построяване, усъвършенстване и изследване на модели с трансфер на знания за рентгенова диагностика на пневмония	31
4.1. Архитектура на модела с трансфер на обучение от NASNetMobile	32
4.2. Оценка на производителността на модела с 33	
трансфер на знания на базата на NASNetMobile.....	33

4.3. Изводи към глава четвърта	34
5. Анализ и изводи от сравнението на моделите	35
5.1. Оценка на моделите на база на данните за трениране.	35
5.2. Оценка на моделите на база на данните за тестване и валидация	35
5.3. Изводи от пета глава	36
ЗАКЛЮЧЕНИЕ И ПРИНОСИ	37
ПУБЛИКАЦИИ ПО ТЕМАТА НА ДИСЕРТАЦИЯТА	39
БИБЛИОГРАФИЯ.....	40
ANNOTATION IN ENGLISH	46
ДЕКЛАРАЦИЯ ЗА ОРИГИНАЛНОСТ	48

УВОД

Актуалност и мотивировка

Настоящият дисертационен труд е посветен на създаването и прилагането на математически и компютърни модели за анализирането на данни, получени при медицински изследвания на пациенти с респираторни заболявания. По-конкретно, използван е апаратът на невронните мрежи за класификация на резултати от рентгенови изследвания на хора, страдащи от пневмония.

Актуалността на проблема за автоматично диагностициране на рентгенови снимки от пациенти с пневмония с помощта на невронни мрежи е изключително важна от медицинска и обществена гледна точка.

Пневмонията е респираторно заболяване, което засяга много хора, особено в развиващите се и слабо развити страни, където високите нива на замърсяване, нехигиенните условия на живот и пренаселеността са относително общи, заедно с недостатъчната медицинска инфраструктура. Поради тази причина, ранното диагностициране на пневмония е от жизнено важно значение, за да се осигури ефективно лечение и да се увеличат шансовете за оцеляване.

Анализът на рентгеновите снимки обаче е трудоемка задача и е подложен на субективна вариабилност. Вследствие на това, разработването на автоматизирани системи за диагностика, използващи изкуствен интелект и невронни мрежи, е предмет на

интензивни изследвания. Например, в едно изследване се използва съвкупност от няколко модели на невронни мрежи за автоматично диагностициране на пневмония с използване на рентгенови снимки.

Успехът на тези методи, както се отразява в тяхната прецизност и чувствителност, подчертава важността на продължаващите усилия за разработване и подобряване на подобни автоматизирани системи. Изкуственият интелект и невронните мрежи могат да играят ключова роля в ранното и точно диагностициране на пневмония, което може значително да улесни работата на медицинския персонал и да подобри качеството на грижите за пациентите.

Освен това, автоматизираните системи могат да бъдат особено полезни в условията на големи епидемии или пандемии, когато броят на пациентите може да надвиши възможностите на медицинския персонал за бързо и точно диагностициране. Такива системи могат да помогнат за оптимизиране на ресурсите и ускоряване на процесите на диагностициране и лечение..

Целта на този дисертационен труд е да се използват математически модели, които са реализирани с помощта на невронни мрежи, за автоматизиране на диагностицирането на пневмония чрез рентгенови снимки.

Обектът на изследването включва набор от рентгенови снимки на белите дробове, заснети по време на рутинни медицински прегледи и с диагнози, поставени от лекари.

Хипотезата, върху която се базира изследването, е че съществуват опростени архитектури на невронни мрежи, които с висока точност могат да

класифицират рентгенови изображения на белите дробове и по този начин да автоматизират откриването на пневмония.

За постигане на поставената цел на дисертационния труд са формулирани следните задачи:

1. Построяване и изследване на собствени модели, базирани на невронни мрежи с различна сложност и дълбочина на архитектурата.
2. Изпитване на различни активационни функции на невронните мрежи и идентифициране на най-добрата от тях. Откриване на подходящи хиперпараметри при обучението на моделите.
3. Оценка на собствените модели и изводи дали модели с опростени архитектури могат да бъдат ефективно използвани за класификация на рентгенови изображения на белите дробове спрямо наличието на пневмония.
4. Установяване дали най-добрите собствени модели на невронни мрежи могат да бъдат оптимизирани допълнително чрез използване на метода на преносимост на знания с предварително обучени невронни мрежи.
5. Сравнение на резултатите от приложените методи и получените модели, както и оценка на тяхното качество за класификация спрямо реалните данни.

Дисертационният труд е структуриран по следния начин:

Увод: Въведение в темата на дисертационния труд, кратък обзор на проблемите и задачите, свързани с разпознаването на рентгенови медицински изображения.

В Глава 1 на дисертационния труд се представят основните понятия и методи, свързани с избраната тема - използването на невронни мрежи. В рамките на тази глава, се разглеждат различни проблеми и задачи, които възникват при изследванията в областта на изкуствения интелект, с фокус върху проблема на преобучаването на невронни мрежи.

Представен е преглед на математическите методи, които се използват за изграждане на невронни мрежи. Това включва анализ на основните компоненти на невронните мрежи, като входни и скрити слоеве, връзките между тях и активационните функции. Проучени са различни математически модели и алгоритми, които подкрепят построяването и тренирането на невронни мрежи, с фокус върху тяхната способност за автоматизирана класификация.

Чрез този анализ и представяне на основните понятия и методи в областта на невронните мрежи, Глава 1 предоставя теоретичната основа за развитието на последващите глави на дисертационния труд, които се фокусират върху конкретното приложение на тези методи за диагностика на пневмония.

В Глава 2 на дисертационния труд се разглеждат моделите, насочени към образова диагностика, конкретно в областта на разпознаването на рентгенови изображения. Тази глава представя обзор на

изследванията, свързани с тази област, и се фокусира върху приложението им в диагностика на пневмония.

В рамките на Глава 2 се представя кратка биологична справка за пневмонията, като се разглеждат различните видове, причините за разболяването, методите на диагностика и лечение. Това дава необходимото контекстуално разбиране на пневмонията и свързаните с нея медицински аспекти.

На основата на представената биологична справка и обзора на изследванията, в тази глава се правят изводи и формулира постановката на задачата за разработване на модел за диагностика на пневмония чрез анализ на рентгенови изображения на белите дробове. Това включва определяне на целта и обхвата на дисертационния труд, както и поставянето на конкретни задачи, които трябва да бъдат решени.

По този начин, Глава 2 служи като основа за развитието на по-нататъшните глави на дисертационния труд, като предоставя контекст и постановка на задачата за изследването в областта на диагностиката на пневмония чрез рентгенови изображения.

В **Глава 3** се представят резултатите от приложението на метода на конволюционни невронни мрежи (CNN) за обработка и анализ на реални емпирични данни от областта на рентгеновата диагностика. В рамките на тази глава са създадени шест собствени модела с различна дълбочина на архитектурата на невронните мрежи и различни активационни функции.

Презентирани са статистически оценки на всички шест модела. Това включва оценка на техните предсказания и способността им да предвиждат наличието или отсъствието на пневмония от рентгеново

изображение. Чрез тези оценки е идентифициран най-добрият модел, който се отличава с най-висока способност за предсказване.

В глава 3 се разглежда важната роля на конволюционните невронни мрежи при обработката и анализа на рентгенови изображения, като се акцентира върху тяхната способност да извличат важни признаци и особености от снимките на белите дробове.

Представените резултати допринасят за разбирането на ефективността на различните архитектури и активационни функции при класификацията на рентгенови изображения на пневмония.

Глава 3 дава важна информация и анализ за изследванията, свързани с приложението на конволюционни невронни мрежи в рентгеновата диагностика на пневмония, като подчертава значимостта на избора на подходяща архитектура и активационни функции за постигане на по-точни и надеждни резултати в класификацията на рентгенови изображения.

В Глава 4 се разглежда изграждането на модел, базиран на трансфер на знания, като се използва предварително обучен модел на невронни мрежи. Този подход използва знанията, придобити от предишно обучени модели, за обучаване на нов модел. Разглежда се възможността за пренасяне на знания от предварително обучени модели на невронни мрежи към модела, разработен за диагностика на пневмония. Това се извършва чрез използване на предварително обучени модели, които са се справили успешно със сходни задачи, и трансферирането на техните знания и опит към новия модел.

Използването на трансфер на знания предоставя предимства, като ускорява обучението на новия модел и може да подобри неговата производителност и точност. Това се дължи на способността на предварително обучените модели да извличат общи и полезни признаци от данните, които могат да бъдат използвани и при новата задача за диагностика на пневмония.

Глава 4 представя важни резултати и изводи от използването на трансфер на знания в контекста на класификацията на рентгенови изображения на белите дробове за диагностика на пневмония. Този модел на обучение допринася за по-ефективна и точна диагностика, като използва знанията, вече придобити от предишни обучения, и ги прилага в новия контекст.

В Глава 5 на дисертационния труд се извършва сравнителен анализ между най-добрия модел, базиран на собствена архитектура, и модела, изграден чрез трансфер на знания. Този анализ има за цел да се определи, кой от двата модела е най-ефективен за диагностика на пневмония по рентгенови изображения.

Сравнителният анализ включва оценка на производителността и точността на двата модела, използвайки статистически методи за оценка и сравнение. Чрез този анализ се определя кой модел предоставя по-добри резултати в класификацията на рентгенови изображения и предсказването на наличието на пневмония.

След провеждането на сравнителния анализ, се избира най-добрият модел от двата и се представя интерпретация на неговите резултати. Това включва детайлно обяснение на причините за неговата ефективност, извлечени от статистическите оценки и анализа на резултатите. Интерпретацията помага за

разбирането на работата на модела и за представяне на основния механизъм, по който той предсказва наличието на пневмония. Интерпретацията на резултатите допълнително обогатява разбирането на работата на модела и подчертава важността на избора и оптимизацията на подходящи модели за успешната диагностика на пневмония чрез рентгенови изображения.

В **Заключението** се прави кратко резюме на дисертационния труд, както и списък на публикациите, свързани с темата, апробации и систематизирани научни приноси на докторанта в областта на използването на описаните методи за машинно обучение в медицината.

Дисертационният труд включва и библиография, където са посочени източниците, използвани при изготвянето на труда.

За осъществяването на задачите, поставени в дисертационния труд, са използвани методи на математическото моделиране и програмиране, които се базират на невронни мрежи и данни от рентгеновата диагностика. Това включва сравнителен анализ на математически модели, програмно реализирани с помощта на невронни мрежи.

За реализирането на математическите модели се използва Python. Python е мощен и гъвкав език за програмиране, който предлага богата библиотека от инструменти и пакети, полезни за обработка на данни и изграждане на невронни мрежи. С помощта на Python могат да се създават, обучават и тестват невронни мрежи за класификация на рентгенови изображения.

Програмното представяне на невронните мрежи означава също дефиниране на архитектурата на мрежата, което включва брой и тип на слоевете,

връзките между тях и активационните функции, които се прилагат. След дефинирането на архитектурата се извършва трениране на модела с помощта на обучаващи данни. На този етап се прави оптимизация на параметрите на модела чрез минимизиране на грешката между предсказанията на модела и истинските стойности на класификацията на рентгеновите изображения.

След тренирането на модела се извършват тестове и валидация, като се използват тестови данни, които не са били използвани по време на тренирането. Това помага да се оцени точността и ефективността на модела.

Програмното реализиране на математическите модели и използването на невронни мрежи в дисертационния труд позволяват анализирането на данни от рентгеновите изображения и класификацията на тези изображения спрямо наличието или отсъствието на пневмония. Това допринася за автоматизацията на диагностика на пневмонията и подобрява точността и ефективността на тази процедура.

Научна новост.

Резултатите от дисертационния труд представят принос в областта на математическото моделиране и програмирането чрез използване на невронни мрежи за класификационен модел за диагностика на пневмония по рентгенови изображения. Идентифицирани са леки опростени архитектури на модели на конволюционни невронни мрежи, които могат да се оптимизират чрез трансфер на знание от мащабно тренирани мрежи, без да добавят значителна сложност.

Математическото моделиране играе ключова роля в дисертационния труд, като се използват

алгоритми и техники за изграждане на невронни мрежи. Това включва определяне на архитектурата на мрежата, избор на подходящи активационни функции и оптимизация на параметрите ѝ. Програмирането с помощта на Python предоставя необходимата гъвкавост и инструменти за реализацията на тези математически модели.

Използването на реални данни от рентгенови изображения на белите дробове, създадени по време на медицински прегледи, позволява изследване на ефективността и точността на класификационния модел. Това включва сравнителен анализ на различни модели, включително тези с различна дълбочина на архитектурата и активационни функции.

Резултатите от дисертационния труд имат практическо приложение в автоматизирането на диагностиката на пневмония, като помагат за бързо и точно откриване на наличието или отсъствието на това заболяване чрез анализ на рентгенови изображения. Това може да подобри ефективността на лекарската практика и намали времето за постановка на диагноза.

Дисертационният труд съчетава математическото моделиране и програмирането чрез невронни мрежи за разработване на класификационен модел за диагностика на пневмония по рентгенови изображения, който има потенциал да промени и подобри практиката в медицинската област.

Апробация

Включените в дисертацията резултати са докладвани на следните научни конференции:

1. XXVII Международна конференция на младите учени, Благоевград, България, 2018.
2. Седма Национална конференция по електронно обучение във висшите училища, Боровец, 2023.09.2018.
3. Seventh International Conference on Finite Difference Methods: Theory and Applications (FDM: T&A'2018), June 11-16, 2018 Lozenetz, Bulgaria
4. VIII Международна научна конференция на ПМФ на ЮЗУ "Modern Trends in Science"-FMNS2019, Благоевград, България, 26 - 30.06.2019.
5. International Conference on Technics, Technologies and Education“ ICTTE2020, Тракийски университет, Ямбол, България, 4 - 6.11.2020.
6. VI International Conference of Mathematics and Computer Science „Congressio-Mathematica”, 28-29.11.2020, Olsztyn, Poland.
7. PhD Student Scientific Session of the FMNS-2020, Blgoevgrad, Bulgaria, 29.11.2020.
8. IX Международна научна конференция на ПМФ на ЮЗУ "Modern Trends in Science"-FMNS-2021, Благоевград, България, 15 - 19.09.2021.
9. VIII International Conference of Mathematics and Computer Science „Congressio-Mathematica”, 19-25.09.2022, Olsztyn, Poland.

10. X Юбилейна международна конференция на ПМФ на ЮЗУ FMNS-2023, Благоевград, България, 14 - 18.06.2023.
11. Scientific Program of the 49th International Conference, Applications of Mathematics in Engineering and Economics, Sozopol, June 10-16, 2023.

Публикации по темата на дисертацията

Получените от изследванията и анализите резултати са публикувани в 5 статии. Една от тях е в български издания, а останалите са в чуждестранни. Всички статии са на английски език. Една от статиите е в сборници доклади от конференции. Четири от статиите са в списания, които са рецензирани в Scopus.

1. Литературен обзор, посветен на математическите модели, на които се основава интелигентен анализ на данни, в частност невронните мрежи

В тази глава се представя обзор на основни математически модели от последните години, използвани за интелигентен анализ на данни и развитието на невронните мрежи.

1.1. Въведение в изкуствените невронни мрежи: Изучават се основните принципи и архитектура на изкуствените невронни мрежи, които се състоят от входни, скрити и изходни слоеве и връзки между тях. (Abusitta et al., 2023; Ben-Cohen et al., 2016, 2016; Bhamidipaty et al., 2021)

1.2. Направления в изкуствения интелект: Анализира се развитието на изкуствения интелект и насоките, които се изследват в тази област, включително машинното обучение, невронни мрежи, генетични алгоритми и други. (Abdiyeva-Aliyeva et al., 2022; Abraham, 2023; Dalta et al., 2019; Esteva et al., 2017) Тези направления включват математически модели и алгоритми, които се използват за интелигентна обработка на данни и вземане на решения.


1.3. Модел на изкуствен перцептрон: Изучава се моделът на изкуствения перцептрон, който представлява най-простия вид невронна мрежа с един входен и един изходен слой. (Eke et al., 2019; Minsky and Papert, 1988; Rosenblatt, 1957) Математическият модел на изкуствения перцептрон може да се представи като:

$$y = f(w*x + b),$$

където y е изхода, f е активационната функция, w

са теглата, x е входът, а b е отместването (bias).

1.4. Класификация на моделите на невронни мрежи:
 Анализират се различните модели на невронни мрежи, като се разглежда как те се класифицират според своята архитектура и връзките между слоевете. (Duda et al., 2001; Gibert et al., 2020; He et al., 2015; Peng et al., 2019; Wang et al., 2018) Някои от класификациите включват невронните мрежи, които разпространяват напред сигналите (forward feed), такива с обратно разпространение на грешките (back propagation of errors), recurrent (рекурентни) и convolutional (конволюционни) невронни мрежи. Разглежда се многослойния перцептрон.



Фигура 1: Многослоен перцептрон (multilayer perceptor - MLP) – изцяло свързана, многослойна, еднопосочна архитектура на НМ.

1.5. Активационни функции в невронните мрежи:
 Изследват се различните активационни функции, които се използват в невронните мрежи, като се анализира тяхната математическа форма и влияние върху изходите

на невроните. (Girshick, 2015) Някои от популярните активационни функции включват сигмоидна функция (sigmoid), стъпаловидна функция (step), ReLU (Rectified Linear Unit) и други.





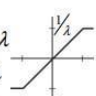
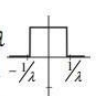
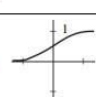
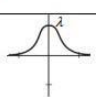
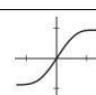
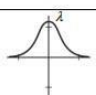
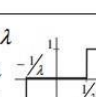
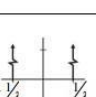
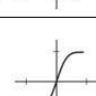
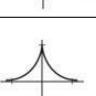
Наименование	Функция $y(u)$	Производна $y' = dy/du$
1. Стъпаловидна	$\text{stp}(u) = \begin{cases} 0, & u \leq 0 \\ 1, & u > 0 \end{cases}$ 	$y' = \delta(u)$ 
2. Сигнум (знакова)	$\text{sgn}(u) = \begin{cases} -1, & u \leq 0 \\ 1, & u > 0 \end{cases}$ 	$y' = 2\delta(u)$ 
3. Линейна с насищане	$\text{sat}(u) = \begin{cases} -1, & u \leq -1/\lambda \\ \lambda u, & u < 1/\lambda \\ +1, & u > 1/\lambda \end{cases}$ 	$y' = \begin{cases} 0, & u \leq -1/\lambda \\ \lambda, & u < 1/\lambda \\ 0, & u > 1/\lambda \end{cases}$ 
4. Сигмоидална	$\text{sgm}(u) = 1/(1 + e^{-\lambda u})$ 	$y' = \lambda y(1 - y)$ 
5. Тангенс-хиперболична	$\text{tgh}(u) = \frac{e^{\lambda u} - e^{-\lambda u}}{e^{\lambda u} + e^{-\lambda u}}$ 	$y' = \lambda(1 - y^2)$ 
6. Релейна със зона на нечувствителност	$\text{dez}(u) = \begin{cases} -1, & u \leq -1/\lambda \\ 0, & u < 1/\lambda \\ +1, & u > 1/\lambda \end{cases}$ 	$y' = \delta(u)$ 
7. Инверсна	$\text{abs}(u) = u/(1 + (u))$ 	$y' = \frac{1}{(1 + (u))^2}$ 

Таблица 1: Активационните функции

Разгледани са подробно активационните функции, начина по който се ползват, техните производни и в кои случаи са подходящи.

1.6. Типове обучения на невронни мрежи: Обсъждат се различните типове обучения на невронни мрежи,

като се анализира как моделите се обучават да приспособяват своите тегла, за да постигнат желаните изходи. Някои от типовете обучения включват надзорено (supervised), ненадзорено (unsupervised) и подсилвано (reinforcement) обучение.(El Rhalibi et al., 2009; Ranjitha et al., 2020; Ren et al., 2015; Thrall et al., 2018)

1.7. Етапи на обучението на невронни мрежи: Обясняват се различните етапи на обучението на невронни мрежи, включително подготовката на данните, избора на алгоритъм за обучение, оптимизация на теглата и валидация на модела. Тези етапи са важни за постигане на добри резултати и ефективно обучение на невронните мрежи. За определяне на теглата за всички връзки е прието обучаващо правило „обратно разпространение на грешката”. Първоначалните стойности на теглата се избират на случаен принцип. Градиентното спускане е метод за намиране на локални минимума на функции, като се движим в посока на отрицателния градиент. В процеса на обучение на невронни мрежи, този метод се използва за определяне на новите стойности на теглата, така че грешката да бъде минимална. Формулата за обновяване на теглата по време на градиентното спускане е:

$$W_n = W_0 - \alpha * \nabla E,$$

където W_n е новата стойност на теглото, W_0 е старата стойност на теглото, α е параметър (наречен learning rate) между 0 и 1, E е грешката.

1.8. Изводи към Глава 1: Направените изводи съдържат обобщение на основните математически модели и концепции, представени в глава 1. Те подчертават важноста на изучаването на невронни мрежи и

математическите модели, които стоят в основата на тях, за развитието на интелигентни системи и анализ на данни.

1. Изучени са принципите, архитектурните топологии и видовете невронни мрежи.
2. Сравнени са активационните функции, сред които се избират най-подходящите при изграждане на собствени невронни мрежи, описани в глава 3 и глава 4.
3. Анализира се начините на обучение на невронните мрежи.
4. Правят се следните изводи:

- невронните мрежи са подходящи за решаване на задачата за автоматизация на образната диагностика на пневмония;

- въпреки че градиентното спускане е полезен метод за оптимизация, той има някои ограничения, включително възможността да попадне в локални минимума. За да се справи с това предизвикателство, могат да се използват различни подходи, като вариации на градиентното спускане или допълнителни техники за избягване на локалните минимума.

- невронните мрежи са съставени от няколко слоя неврони и работят по принципа на разпространение на сигнала напред (forward feed) и корекция на грешките в обратна посока (backpropagation). В процеса на обучение се коригират теглата във връзките между слоевете;

- при обратното разпространение на грешките се използва градиентното спускане, за да се намери

минималната грешка и да се оптимизират теглата на невроните;

- ограничения на обратното разпространение на грешките е ниската скорост на сходимост, което означава, че обучението може да изисква голям брой епохи и обучаващи примери, преди да се достигне желаната точност;

- процесът на обучение може да бъде спрян, когато се изпълни определено условие, като преминаване на определен брой епохи, достигане на минимална грешка или прекратяване на намаляването на грешката. Това помага за контролиране на обучението и предотвратяване на прекомерно обучение (overfitting).

Важен извод е, че грешката на обучаващото множество се минимизира, но това не гарантира, че грешката на тестовото множество ще бъде също толкова ниска. Това се дължи на факта, че невронните мрежи могат да се прекапацитират (overfit) към обучаващите данни и да се запаметят специфични шаблони, които не са общи за цялата проблемна област. Затова е важно да се използва валидационно множество и да се следи за общата производителност на модела, като се избягва прекомерното придържане към обучаващите данни. Някои от описаните в този раздел резултати са засегнати частично в авторската статия [1] и са използвани в останалите публикации по темата на дисертацията.

2. Математически модели и подходи, използвани при конструирането на класификационни невронни мрежи.

Тази глава е посветена на преглед на основни математически методи и подходи, които са използвани в следващите глави при съставянето.

Поради интердисциплинарността на темата освен обзор на състоянието на математическото моделиране на невронните мрежи е направен кратък преглед на пневмонията като заболяване, чиято диагностика се прави с математическите модели на невронни мрежи в Глава 3 и 4.

2.1. Биологични бележки относно моделите за диагностика на пневмония

В този раздел е направен кратък преглед на същността на пневмонията, посочени са основни фактори, способстващи възникването на пневмония (Dadonaite, Bernadeta, n.d.; Franquet, 2001; Hashmi et al., 2020; Hoare and Lim, 2006; Lodha et al., 2013), различните типове на заболяването, средствата на лечение и диагностика (Duda et al., 2001; Er et al., 2010; Thrall et al., 2018). (Er et al., 2010)

2.2. Преглед на научните изследвания за използване на изкуствен интелект в рентгеновата диагностика

В този раздел е направен преглед на основни математически и компютърни модели от последните

години, описващи научните търсения в областта на автоматизация на рентгеновата диагностика (Bian et al., 2021; Er et al., 2010; Kallianos et al., 2019; Tsiknakis et al., 2020; Yasaka and Abe, 2018).

2.3. Изводи към глава втора

1. Изучени и анализирани са характеристиките на пневмонията и обърнато внимание на рентгеновата диагностика, на която са посветени моделите, описани в глава 3 и глава 4.

2. Направен е обзор на съвременното състояние на моделите, подпомагащи образната диагностика. Установено е, че моделите с използване на невронни мрежи са приложени за класификация на рентгенови снимки;

3. Систематизирани са основните направления, върху които са провеждани изследвания с помощта на невронни мрежи за образна диагностика.

4. Формулирана е тезата, че създаването, усъвършенстването и анализът на модели с невронни мрежи, свързани с образната диагностика на пневмония, и провеждането на изследвания и числени експерименти върху моделите чрез подходящо избрани и разработени компютърни алгоритми и програми, може да бъде средство за по-бързо, по-икономично прогнозиране на заболяването.

Описаните в този раздел резултати са използвани частично в авторските статии [I], [II], [III], [IV], [V].

3. Създаване, усъвършенстване и изследване на математически модели, реализирани чрез невронни мрежи за рентгенова диагностика на пневмония

3.1. Описание на данните

Наборът от данни е публично достъпен, предоставен от д-р Пол Муни за състезание Kaggle(Mooney, Paul, 2020). Рентгеновите изображения са общо 5836. Те са сегментирани в тренировъчен и тестов набор, както и в две категории във всяка подгрупа – нормални и пневмония.

3.2. Предварителна обработка на данните

Изображенията за обучение се увеличават изкуствено чрез прилагане за промяна на мащаба, увеличение и вертикално обръщане. Изображенията са допълнително нормализирани.

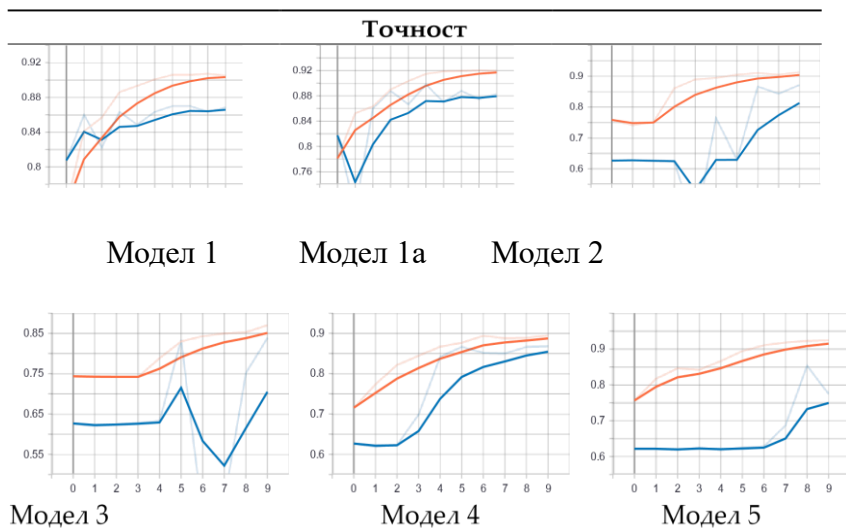
3.3. Базов модел за диагностика на пневмония

В експерименталната част на изследването са разработени три базови топологии на архитектурата на модела.

3.4. Разширен модел за диагностика на пневмония

Разработени са 3 разширени дълбоки топологии на невронни мрежи 3.6. Оценка на трите модела с базава архитектура и трите модела с разширена архитектура Нашите цели са да проверим каква точност може да се

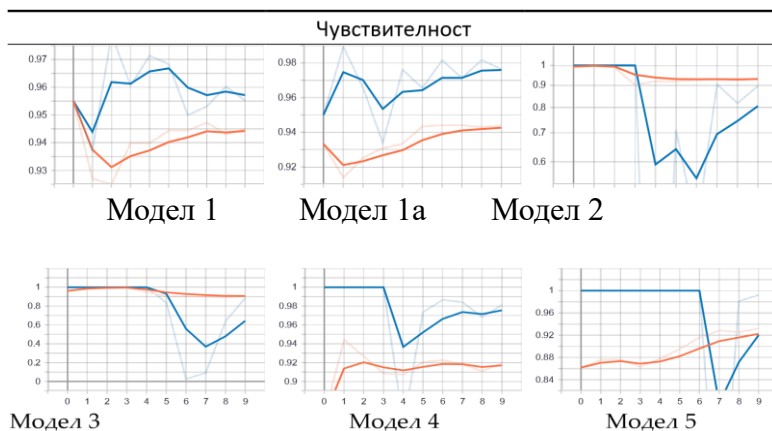
постигне с относително плитки конволюционни невронни мрежи, обучени в 10 епохи, и да сравним това с производителността на модели с по-дълбоки топологии. Прецизирахме моделите и сравнихме резултатите Точността, като инструмент за оценяване, показва едно единствено нещо, колко души от извадката имат верен (коректен) резултат. Ето защо моделът се оценява по повече параметри.



Фигура 2: Точност на базовите и разширени модел

Когато измерваме чувствителността, ние отговаряме на въпроса - от всички изображения с пневмония, колко сме отбелязали правилно. Този показател дава отрицателен резултат за здравите. Чувствителността показва на лекаря шансовете да идентифицира болния, ако има положителен резултат. Тя е делът на действително положителните, които действително се тестват като положителни, т.е.


определя доколко един тест е в състояние да открие действително положителни индивиди в една популация.



Фигура 3. Чувствителност на моделите


Чувствителността се противопоставя на прецизността, тъй като, при еднакъв брой верни положителни резултати, колкото чувствителността е пониска, толкова повече действително болни хора се обявяват за здрави, и обратното, колкото прецизността е по-ниска, толкова повече здрави хора се обявяват за болни, т.е. грешките от втори и първи тип доминират в реализираната класификация.

Прецизността показва на изследвания шансовете да има заболяване, ако има положителен резултат. Чувствителността показва на лекаря шансовете да идентифицира болния, ако има положителен резултат. Високата прецизност е свързана с ниския процент на фалшиви положителни резултати. Колкото прецизността е по-висока, толкова по-малко ще бъдат неверните положителни резултати!



Фигура 4. Прецизност на моделите

Функция на загуба или функция на разходите е функция, която съпоставя стойностите на една или повече променливи в реално число, интуитивно представляващо някаква "цена", свързана със стойността.



Фигура 5. Функция на загубата

Model	Model 1a	Model 2
Функция на загубата	0.1985	0.2064
Точност	0.9208	0.9134
Прецизност	0.9498	0.9493
AUC	0.9693	0.9654
Чувствителност	0.9431	0.9331
Функция на загубата при валидацията	0.3762	0.3216
Точност при валидацията	0.8750	0.8717
Прецизност при валидацията	0.8449	0.8976
AUC при валидацията	0.9494	0.9358
Чувствителност при валидацията	0.9817	0.8976

Сравнение на двата най-добри модела.

Моделът победител от моделите с опростена конволюционна невронна мрежа е Модел 1a. Победителят в моделите с по-дълбока конволюционна невронна мрежа е Модел 2.

Сравнението на моделите показва, че модел 1a с оптимизатор Адам има по-добри показатели, когато обучението обхваща 10 епохи. Модел 1a има точност на валидиране от 87,50%, докато модел 1 е 86,35%. Модел 1 е с точност на валидиране 84,22%, модел 1a – 84,49%. Чувствителността на валидиране на модел 1 е 96,03%, а на модел 1a е 98,17%. Функцията на загубата

при валидиране е 33,10% за модел 1 и 37,62% за модел 1а. AUC за валидиране е 94,61% за модел 1 и 94,94% за модел 1а.

При тестовите данни разликите в резултатите са по-видими. Модел 1а има точност с тестовите данни 92,08%, докато модел 1 е 90,74%. Модел 1 е с точност с тестовите данни 93,29%, модел 1а – 94,98%. И за двата модела чувствителността с тестовите данни е 94,31%. Функцията на загубата е 22,61% за модел 1 и 19,85% за модел 1а. AUC е 95,97% за модел 1 и 96,93% за модел 1а.

Модел 2 е най-добрият модел от по-дълбоките модели на CNN със следните резултати от измерването на ефективността при тестовите данни – за функция на загубата: 20,64%; за точност: 91.34%, за прецизност: 94.93%; за AUC: 96,54%; за чувствителност: 0.93.31%; и за валидационните данни – функция на загуба: 32,16%; точност: 87.17%; прецизност: 89.76%; AUC: 93,58%; чувствителност: 89,76%.

Проблемът за оптимизация се стреми да сведе до минимум функцията на загуба. Така че колкото по-ниска е функцията на загуба, толкова по-надеждна е прогнозата. Загубата на кръстосана ентропия се увеличава, тъй като прогнозираната вероятност се отклонява от действителния клас. Колкото по-ниска е прецизността, толкова повече от изследваните ще бъдат поставени в положението да бъдат обявени за болни.

3.5. Изводи към глава трета

1. Съставени и изследвани са шест модела, въз основа на базовия и разширен модел за класификация на медицински рентгенови изображения.
2. Създадени са собствени архитектури на невронни мрежи за всеки модел.
3. Съставен е алгоритъм за числено решаване на моделите, който е имплементиран с помощта на Python.
4. Извършен е анализ на моделите като е изследвана ролята на активационната функция.
5. Моделите са тренирани и са намерени най-оптималните тегла за моделите. Направено е тестване на моделите и валидиране на резултатите.
6. Използвани са статистически метрики за оценка на моделите и е избран най-добрия. Моделът победител от моделите на плитките конволюционни невронни мрежи е Модел 1а. Победителят в моделите с дълбока архитектура на конволюционна невронна мрежа е Модел 2.

Описаните в тази глава резултати са публикувани частично в авторските статии [II], [III], [IV], [V].

4. Построяване, усъвършенстване и изследване на модели с трансфер на знания за рентгенова диагностика на пневмония

В тази глава са описани и изследвани два модела. Единият е най-добрия от собствените модели, а другият е модел с трансфер на обучение, надграден над първия с използването на предварително обучен модел – NASNetMobile(Apostolopoulos and Mpesiana,

2020; Chen et al., 2018; Hashmi et al., 2020; Sarkar et al., 2018).

4.1. Архитектура на модела с трансфер на обучение от NASNetMobile

Моделът NASNetMobile е изграден върху специализирания модел на CNN.

Таблица 2: Архитектурна топология на NASNetMobile.

Слой	Размер	Параметри
NASNet	(7, 7, 1056)	4269716
Dropout	(7, 7, 1056)	0
Flatten	(51744)	0
Dense	(128)	6623360
Dense	(1)	129

Общо 10,893,205

Обучаеми 6,623,489

Необучаеми 4,269,716


Таблица 3. NASNetMobile параметри

В резултат има общи параметри - 10 893 205, от които обучаеми - 6 623 489 и необучаеми - 4 269 716. Пълната архитектура на модела за обучение NASNetMobile Transfer.

4.2. Оценка на производителността на модела с трансфер на знания на базата на NASNetMobile

NASNet-Mobile е CNN, който обучава повече от милион изображения от базата данни ImageNet. Мрежата може да класифицира изображения в 1000 категории. Производителността на модела се оценява чрез показателите – точност, прецизност, чувствителност, функция на загуба и AUC резултат.

Точност




NASNet-Mobile

Базов CNN

Фигура 6. Точност на моделите

Чувствителността



NASNet-Mobile

Базов CNN

Фигура 7. Чувствителност на моделите.

Чувствителността или вярно положителната норма (True Positive Rate, TPR), като показател, отделя всички с верен положителен резултат (TP) от всички, които са болни (TP+FN). Точността, като инструмент за оценяване, показва едно единствено нещо, колко души от извадката имат верен (коректен) резултат.

4.3. Изводи към глава четвърта

Моделът на трансферно обучение определено подобрява производителността на базисния модел на CNN и резултатът е по-надеждна прогноза за пневмония.

Описаните в този раздел резултати са публикувани частично в авторските статии [IV], [V].

5. Анализ и изводи от сравнението на моделите

В тази глава се анализират резултатите и се правят изводи по отношение на най-добрия от собствените модели и модела с трансфер на обучение, надграден над първия с използването на предварително обучен модел – NASNetMobile.

5.1. Оценка на моделите на база на данните за трениране.

Сравнението на базисния модел и оптимизацията на производителността, получена чрез прилагане на трансферно обучение чрез NASNet-Mobile, показва, че е възможно да се използва предварително обучен модел за общи категории изображения за трансферно обучение в областта на разпознаването на медицински изображения. Специализираният модел на CNN има точност на валидиране от 88,82%, докато моделът NASNet-Mobile има 91,61%. Моделът на CNN има точност на валидиране от 85,62%, моделът за прехвърляне на обучение има 90,07%.

5.2. Оценка на моделите на база на данните за тестване и валидация

За тестовите данни разликите в резултатите са по-видими. Моделът за прехвърляне на обучение има точност на тестване от 96,02%, докато специализираният модел на CNN е 92,06%. Специализираният модел на CNN има точност на тестване от 94,63%, моделът NASNet-Mobile – 97,39%. Извикването при тестване е 94,66% за модела CNN и 97,23% за NASNet-Mobile. Загубата при тестване е 19,63% за специализирания модел и 11,03% за модела за

прехвърляне на обучение. Тестваната AUC е 96,93% за модела CNN и 98,87% за модела NASNet-Mobile.

Прилагането на собствения модел върху данните за валидиране е 98,68%, моделът NASNet е 97,38%. Функцията на загубата при валидиране е 44,43% за модела CNN и 24,13% за модела за прехвърляне на обучение. AUC за валидиране е 93,55% за специализирания модел и 96,54% за модела NASNetMobile.

5.3. Изводи от пета глава

1. Сравнени са най-добрия от собствените модели и модела с трансфер на знания, въз основа на NASNetMobile.

2. Установено е, че моделът с трансфер на знания дава по-добри резултати по всички показатели с около 4%.

3. Направена е оценка въз основа на данни, които моделът не е срещал по време на обучението – данните за тестване и валидация. Резултатите с тези данни също показват устойчиво подобрение на модела с трансфер на знание. [I], [III], [V], [VI].

ЗАКЛЮЧЕНИЕ И ПРИНОСИ

В резултат на проведените изследвания могат да бъдат направени следните заключения и посочени следните приноси:

- В дисертационния труд са предложени и изследвани математически модели, базирани на невронни мрежи, за автоматизиране на диагностика на пневмония чрез рентгенови снимки на белите дробове.

- Извършен е сравнителен анализ на различни архитектури на невронни мрежи, включително тези с различна сложност и активационни функции, с цел определяне на най-добрия собствен опростен модел за класификация на рентгенови изображения на белите дробове, свързана с наличието на пневмония.

- Предложен и изследван е модел, изграден чрез трансфер на знания, като са използвани предварително обучени модели на невронни мрежи за подобряване на резултатите при класификацията на рентгеновите изображения.

- Извършено е сравнение на най-добрия модел, базиран на собствена архитектура, и модела, базиран на трансфер на знания, с цел избор на най-ефективния модел за диагностика на пневмония.

2. Заключение:

- Дисертационният труд допринася за развитието на математическото моделиране и използването на невронни мрежи в областта на медицината, по-конкретно за диагностика на пневмония.

- Разработените математически модели и методи за класификация на рентгенови изображения на белите

дробове представят потенциал за автоматизиране и подобряване на точността на диагностиката на пневмония.

- Проведеният сравнителен анализ показва, че съществуват ефективни опростени и леки модели, изискващи по-малко мощни компютри, които могат да бъдат използвани за класификация на рентгенови снимки на белите дробове и откриване на пневмония. - Използването на трансфер на знания допълнително подобрява резултатите и ефективността на класификационните модели.

- Предложените методи и модели имат потенциал да бъдат внедрени в медицинската практика за по-бърза и по-точна диагностика на пневмония чрез анализ на рентгенови снимки.

Описаните приноси оценявам като научно-приложни и приложни.

ПУБЛИКАЦИИ ПО ТЕМАТА НА ДИСЕРТАЦИЯТА

- I. Marcos-Zambrano, L.J., Karaduzovic-Hadziabdic, K., Loncar Turukalo, T., Przymus, P., Trajkovik, V., Aasmets, O., Berland, M., Gruca, A., Hasic, J., Hron, K., Klammsteiner, T., Kolev, M., Lahti, L., Lopes, M.B., Moreno, V., Naskinova, I., Org, E., Paciência, I., Papoutsoglou, G., Shigdel, R., Stres, B., Vilne, B., Yousef, M., Zdravevski, E., Tsamardinos, I., Carrillo de Santa Pau, E., Claesson, M.J., Moreno-Indias, I., Truu, J., 2021. Applications of Machine Learning in Human Microbiome Studies: A Review on Feature Selection, Biomarker Identification, Disease Prediction and Treatment. *Front. Microbiol.* 12, 634511. <https://doi.org/10.3389/fmicb.2021.634511>
- II. Naskinova, I., 2023. Transfer learning with NASNet-Mobile for Pneumonia X-ray classification. *Asian-Eur. J. Math.* 16, 2250240. <https://doi.org/10.1142/S1793557122502400>
- III. Naskinova, I., 2021. On Convolutional Neural Networks for Chest X-ray Classification. IOP Conf. Ser. Mater. Sci. Eng. 1031, 012075. <https://doi.org/10.1088/1757-899x/1031/1/012075>
- IV. Naskinova, I., 2020. Convolutional Neural Networks for X-Ray Image Classification. Presented at the PhD Student Scientific Session of the FMNS'2020.

- V. Naskinova, I., Kolev, M., Markovska, A., 2020. On the innate immune response to intracellular bacterial infections. *Asian-Eur. J. Math.* 13. <https://doi.org/10.1142/S1793557120501703>

БИБЛИОГРАФИЯ

- Abdiyeva-Aliyeva, G., Aliyev, J., Sadigov, U., 2022. Application of classification algorithms of Machine learning in cybersecurity. *Procedia Comput. Sci.* 215, 909–919. <https://doi.org/10.1016/j.procs.2022.12.093>
- Abraham, G., 2023. Explainable AI for Anomaly Detection. www.electronicdesign.com. URL <https://www.electronicdesign.com/technologies/embedded/machine-learning/article/21266589/cevaexplainable-ai-for-anomaly-detection>
- Abusitta, A., de Carvalho, G.H.S., Wahab, O.A., Halabi, T., Fung, B.C.M., Mamoori, S.A., 2023. Deep learningenabled anomaly detection for IoT systems. *Internet Things* 21, 100656. <https://doi.org/10.1016/j.iot.2022.100656>
- Apostolopoulos, I.D., Mpesiana, T.A., 2020. Covid-19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks. *Phys. Eng. Sci. Med.* 43, 635–640. <https://doi.org/10.1007/s13246-020-00865-4>
- Ben-Cohen, A., Diamant, I., Klang, E., Amitai, M., Greenspan, H., 2016. Fully Convolutional Network

- for Liver Segmentation and Lesions Detection, in: Carneiro, G., Mateus, D., Peter, L., Bradley, A., Tavares, J.M.R.S., Belagiannis, V., Papa, J.P., Nascimento, J.C., Loog, M., Lu, Z., Cardoso, J.S., Corneise, J. (Eds.), *Deep Learning and Data Labeling for Medical Applications*, Lecture Notes in Computer Science. Springer International Publishing, Cham, pp. 77–85.
https://doi.org/10.1007/978-3-319-46976-8_9
- Bhamidipaty, A., Patel, D., Lin, S., Jayaraman, S., Ganapavarapu, G., 2021. What is anomaly detection? developer.ibm.com.
- Bian, S., Li, C., Fu, Y., Ren, Y., Wu, T., Li, G.-P., Li, B., 2021. Machine learning-based real-time monitoring system for smart connected worker to improve energy efficiency. *J. Manuf. Syst.* 61, 66–76.
<https://doi.org/10.1016/j.jmsy.2021.08.009>
- Chen, S., Zhou, Y., Chen, Y., Gu, J., 2018. fastp: an ultrafast all-in-one FASTQ preprocessor. *Bioinformatics* 34, i884–i890.
<https://doi.org/10.1093/bioinformatics/bty560>
- Dadonaite, Bernadeta, B., n.d. Pneumonia. [OurWorldInData.org](https://ourworldindata.org/pneumonia). URL
<https://ourworldindata.org/pneumonia>
- Dalta, I.M., Nur, F.P.D., Amaral, S.T., Adiono, T., 2019. Artificial Intelligence Based In-Store Traffic Monitoring System for Evaluating Retail Performance, in: 2019 IEEE 8th Global Conference on Consumer Electronics (GCCE). Presented at the 2019 IEEE 8th Global Conference on Consumer Electronics (GCCE), IEEE, Osaka, Japan, pp. 430–431.
<https://doi.org/10.1109/GCCE46687.2019.9015310>

- Duda, R.O., Hart, P.E., Stork, D.G., 2001. Pattern classification, 2nd ed. ed. Wiley, New York.
- Eke, H.N., Petrovski, A., Ahriz, H., 2019. The use of machine learning algorithms for detecting advanced persistent threats, in: Proceedings of the 12th International Conference on Security of Information and Networks. Presented at the SIN 2019: The 12th International Conference on Security of Information and Networks, ACM, Sochi Russia, pp. 1–8.
<https://doi.org/10.1145/3357613.3357618> El
- Rhalibi, A., Wong, K.W., Price, M., 2009. Artificial Intelligence for Computer Games. *Int. J. Comput. Games Technol.* 2009, 1–3.
<https://doi.org/10.1155/2009/251652>
- Er, O., Yumusak, N., Temurtas, F., 2010. Chest diseases diagnosis using artificial neural networks. *Expert Syst. Appl.* 37, 7648–7655.
<https://doi.org/10.1016/j.eswa.2010.04.078>
- Esteva, A., Kuprel, B., Novoa, R.A., Ko, J., Swetter, S.M., Blau, H.M., Thrun, S., 2017. Dermatologist-level classification of skin cancer with deep neural networks. *Nature* 542, 115–118.
<https://doi.org/10.1038/nature21056>
- Franquet, T., 2001. Imaging of pneumonia: trends and algorithms. *Eur. Respir. J.* 18, 196.
- Gibert, D., Mateu, C., Planes, J., 2020. The rise of machine learning for detection and classification of malware: Research developments, trends and challenges. *J. Netw. Comput. Appl.* 153, 102526.
<https://doi.org/10.1016/j.jnca.2019.102526>
- Girshick, R., 2015. Fast R-CNN.

- Hashmi, M.F., Katiyar, S., Keskar, A.G., Bokde, N.D., Geem, Z.W., 2020. Efficient Pneumonia Detection in Chest Xray Images Using Deep Transfer Learning. *Diagnostics* 10, 417.
<https://doi.org/10.3390/diagnostics10060417>
- He, K., Zhang, X., Ren, S., Sun, J., 2015. Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification, in: 2015 IEEE International Conference on Computer Vision (ICCV). Presented at the 2015 IEEE International Conference on Computer Vision (ICCV), IEEE, Santiago, Chile, pp. 1026–1034.
<https://doi.org/10.1109/ICCV.2015.123>
- Hoare, Z., Lim, W.S., 2006. Pneumonia: update on diagnosis and management. *BMJ* 332, 1077–1079.
<https://doi.org/10.1136/bmj.332.7549.1077>
- Kallianos, K., Mongan, J., Antani, S., Henry, T., Taylor, A., Abuya, J., Kohli, M., 2019. How far have we come? Artificial intelligence for chest radiograph interpretation. *Clin. Radiol.* 74, 338–345.
<https://doi.org/10.1016/j.crad.2018.12.015>
- Lodha, R., Kabra, S.K., Pandey, R.M., 2013. Antibiotics for community-acquired pneumonia in children. *Cochrane Database Syst. Rev.* CD004874.
<https://doi.org/10.1002/14651858.CD004874.pub4>
- Minsky, M.L., Papert, S., 1988. *Perceptrons: An Introduction to Computational Geometry*. Cambridge.
- Mooney, Paul, 2020. Chest X-Ray Images (Pneumonia). URL
<https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia/version/2> (accessed 11.8.20).

- Peng, Y., Dharssi, S., Chen, Q., Keenan, T.D., Agrón, E., Wong, W.T., Chew, E.Y., Lu, Z., 2019. DeepSeeNet: A Deep Learning Model for Automated Classification of Patient-based Agerelated Macular Degeneration Severity from Color Fundus Photographs. *Ophthalmology* 126, 565–575.
<https://doi.org/10.1016/j.ophtha.2018.11.015>
- Ranjitha, M., Nathan, K., Joseph, L., 2020. Artificial Intelligence Algorithms and Techniques in the computation of Player-Adaptive Games. *J. Phys. Conf. Ser.* 1427, 012006.
<https://doi.org/10.1088/1742-6596/1427/1/012006>
- Ren, S., He, K., Girshick, R., Sun, J., 2015. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, in: Cortes, C., Lawrence, N.D., Lee, D.D., Sugiyama, M., Garnett, R. (Eds.), *Advances in Neural Information Processing Systems* 28. Curran Associates, Inc., pp. 91–99.
- Rosenblatt, F., 1957. *The Perceptron, a Perceiving and Recognizing Automaton Project Para, Report: Cornell Aeronautical Laboratory. Cornell Aeronautical Laboratory.*
- Sarkar, D., Bali, R., Ghosh, T., 2018. *Hands-on transfer learning with Python: implement advanced deep learning and neural network models using TensorFlow and Keras.*
- Thrall, J.H., Li, X., Li, Q., Cruz, C., Do, S., Dreyer, K., Brink, J., 2018. Artificial Intelligence and Machine Learning in Radiology: Opportunities, Challenges, Pitfalls, and Criteria for Success. *J. Am. Coll. Radiol.* 15, 504–508.
<https://doi.org/10.1016/j.jacr.2017.12.026>

- Tsiknakis, N., Trivizakis, E., Vassalou, E., Papadakis, G., Spandidos, D., Tsatsakis, A., Sánchez-García, J., López-González, R., Papanikolaou, N., Karantanas, A., Marias, K., 2020. Interpretable artificial intelligence framework for COVID-19 screening on chest X-rays. *Exp. Ther. Med.* 20, 727–735.
<https://doi.org/10.3892/etm.2020.8797>
- Wang, X., Peng, Y., Lu, L., Lu, Z., Summers, R.M., 2018. TieNet: Text-Image Embedding Network for Common Thorax Disease Classification and Reporting in Chest X-Rays, in: 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Presented at the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, Salt Lake City, UT, pp. 9049–9058.
<https://doi.org/10.1109/CVPR.2018.00943>
- Yasaka, K., Abe, O., 2018. Deep learning and artificial intelligence in radiology: Current applications and future directions. *PLOS Med.* 15, e1002707.
<https://doi.org/10.1371/journal.pmed.1002707>

ANNOTATION IN ENGLISH

This annotation presents the key contributions and findings of a dissertation in the field of mathematics. The dissertation focuses on the application of mathematical models implemented through neural networks for automating the diagnosis of pneumonia using X-ray images.

The research investigates a collection of X-ray images of the lungs taken during routine medical examinations, with diagnoses provided by medical professionals. The hypothesis of the study suggests the existence of simplified neural network architectures capable of accurately classifying X-ray images of the lungs to automate the detection of pneumonia.

To achieve the research objective, several tasks were formulated:

1. Construct and analyze custom models based on neural networks with varying complexity and depth of architecture.
2. Experiment with different activation functions for neural networks and identify the most suitable ones. Discover appropriate hyperparameters for training the models.
3. Evaluate the custom models and draw conclusions on whether models with simplified architectures can effectively classify X-ray images of the lungs regarding the presence of pneumonia.
4. Determine if the best custom neural network models can be further optimized through the use of transfer learning, utilizing pre-trained neural networks.

5. Conduct a comparison of the applied methods, the resulting models, and their classification performances against real-world data.

The dissertation structure comprises an introduction, four chapters, a conclusion, bibliography, and spans a total of 119 printed pages. The chapters cover essential concepts, methods, and a literature review related to the chosen topic, present results obtained from applying convolutional neural networks to analyze real empirical data in radiology, demonstrate the construction of transfer learning models, and provide a comparative analysis of the best models. The conclusion summarizes the dissertation, includes a list of publications, validations, and highlights the scientific contributions in utilizing the described machine learning methods in the field of medicine.

Overall, this dissertation contributes to the advancement of mathematical modeling and demonstrates the practical implementation of neural networks for automating the diagnosis of pneumonia using X-ray images, potentially improving the accuracy and efficiency of this diagnostic procedure in medical practice.

ДЕКЛАРАЦИЯ ЗА ОРИГИНАЛНОСТ

Декларирам, че настоящата дисертация съдържа оригинални резултати, получени при проведени от мен научни изследвания (с подкрепата и съдействието на научния ми ръководител). Резултати, които са получени, описани и/или публикувани от други учени, са надлежно и подробно описани в раздел „Библиография“.

Настоящата дисертация не е прилагана за придобиване на научна степен в друго висше училище, университет или научен институт.

Подпис:

/Ирина Наскинова/