

ИНСТИТУТ ПО БИОФИЗИКА И БИОМЕДИЦИНСКО ИНЖЕНЕРСТВО
БЪЛГАРСКА АКАДЕМИЯ НА НАУКИТЕ

Дълбоки невронни мрежи
за целите на диагностиката в медицината

Александър Огнянов Маразов

АВТОРЕФЕРАТ НА
ДИСЕРТАЦИОНЕН ТРУД

ЗА ПРИДОБИВАНЕ НА ОБРАЗОВАТЕЛНА И НАУЧНА СТЕПЕН ДОКТОР
ПРОФЕСИОНАЛНО НАПРАВЛЕНИЕ: 4.6 “Информатика и компютърни науки”
ДОКТОРСКА ПРОГРАМА: “Информатика”

НАУЧЕН РЪКОВОДИТЕЛ:
ДОЦ. Д-Р ЛЮДМИЛА ПАВЛОВА ТОДОРОВА

София, 2024

Дисертационният труд е обсъден и насочен за защита от разширено секционно заседание на секция „Биоинформатика и математическо моделиране“ към Институт по биофизика и биомедицинско инженерство – БАН на 25.04.2024г.

Настоящият дисертационен труд е структуриран в увод, пет глави, заключение-резюме на получените резултати, декларация за оригиналност, библиография, списък на авторските публикации, списък със забелязани цитирания, четири приложения и е в обем от 162 страници. Цитирани са 146 източника.

Защитата на дисертационния труд ще се състои на2024 г. от часа в заседателната зала на Института по биофизика и биомедицинско инженерство – Българска академия на науките (ул. “Акад. Георги Бончев”, бл. 21, София) на открито заседание на научното жури в състав:

Титулярни членове:

- проф. Мария Нишева (СУ ”Св. Кл. Охридски“)
- проф. Петя Копринкова (ИИКТ – БАН)
- проф. Сотир Сотиров (Университет „Проф. Асен Златаров, Бургас)
- проф. Олимпия Роева (ИБФБМИ – БАН)
- доц. Петър Василев (ИБФБМИ – БАН)

Резервни членове:

- проф. Евдокия Сотирова (Университет „Проф. Асен Златаров, Бургас)
- доц. Симеон Рибегин (ИБФБМИ – БАН)

Автор: Александър Огнянов Маразов

ЗАГЛАВИЕ: Дълбоки невронни мрежи за целите на диагностиката в медицината

Списък на съкращенията

- **БА** – болест на Алцхаймер
- **ИРД** – интуиционистки размита двойка
- **ИРМ** – интуиционистки размити множества / **IFS** – intuitionistic fuzzy sets
- **CNN** – Convolutional Neural Networks – конволюционни невронни мрежи
- **PM** – размито множество
- **СТ** – computed tomography – компютърна томография
- **ЯМР** – ядрено-магнитен резонанс / **MRI** – Magnetic resonance imaging
- **ResNet** – residual neural network
- **ILSVRC** – ImageNet Large Scale Visual Recognition Challenge
- **PM** – размито множество / **FS** – fuzzy sets
- **IFNN** – intuitionistic fuzzy neural network – интуиционистки размита невронна мрежа
- **IFDNN** – intuitionistic fuzzy deep neural network – интуиционистки размита дълбока невронна мрежа
- **LSTM** – long short-term memory – дълго-краткосрочна памет
- **RBFNN** – radial basis function neural network – невронни мрежи с радиална базисна функция
- **OvO** – One-vs-One – един срещу един
- **OvR** – One-vs-Rest – един срещу останалите
- **SVM** – Support Vector Machines – методът на опорните вектори
- **TP** – True Positives – истински позитивни
- **TN** – True Negatives – истински негативни
- **FP** – False Positives – фалшиво позитивни
- **FN** – False Negatives – фалшиво негативни

Увод

Подходи, базирани на размита и интуиционистки размита логика все по-често се прилагат за ефективна сегментация на мозъчни структури и за извличане на подходящи характеристики от изображенията на мозъка [1] с цел постигане на правилна класификация. Класификационната задача в машинното самообучение е процесът на присвояване на категория или клас на нови обекти въз основа на техните характеристики или признаци.

Деменцията, особено болестта на Алцхаймер (БА), е най-критичното невродегенеративно заболяване, засягащо паметта и когнитивните функции. Над 55 милиона души по света имат деменция. БА представлява 60-70% от случаите. Това фатално прогресиращо заболяване изисква ранна идентификация и намеса за подобряване на бъдещите здравни резултати [2, 3].

Болестта на Алцхаймер е глобален проблем, изискващ ефективни диагностични подходи, и дълбокото обучение е обещаващо за точно и ранно откриване на болестта. Целта на настоящия труд е да се проектират, тренират и оптимизират алгоритми с дълбоки невронни мрежи за подобряване на диагностицирането и стадирането на болестта на Алцхаймер, използвайки интуиционистки размити множества и интеркритериален анализ.

Дисертационният труд е структуриран по следния начин.

Глава 1 на представената работа е разделена на 4 раздела. В Раздел 1.1 е направен преглед на невронните мрежи, с акцент върху конволюционни невронни мрежи. В Раздел 1.2 е представена накратко теоретичната основа на интуиционистки размитите множества (ИРМ) и тяхното приложение за целите на медицинската диагностика. В Раздел 1.3 е разгледан в теоретичен аспект методът на интеркритериалния анализ, базиран на апарата на индексиранияте матрици и на интуиционистки размитата логика.

В Глава 2 е представено приложение на конволюционни невронни мрежи за диагностика на болестта на Алцхаймер. Описани са програмният код, изборът на модел и стъпка, тренирането на модела и са анализирани получените резултати. В заключението на главата са дадени преимуществата на разработения код.

В Глава 3 на дисертационния труд са представени нови начини за инференция, разработени на базата на интеркритериалния анализ и на метода на Кемени-Йънг. Предложен е нов метод за извеждане в машинното самообучение, който минимизира разликата между подредбите на ансамбъл от класификатори. Представен е начин за определяне на степените на принадлежност, непринадлежност и неопределеност на предпочитанията в смисъла на интуиционистка размитата логика, чрез използване на интеркритериалния анализ.

Глава 5 е посветена на изчислителната сложност при пресмятане на

интеркритериалните броячи. Дефинирано и доказано е твърдение за взаимно еднозначно съответствие между броя на несъответствията в интеркритериалните броячи и броя инверсии във вектор. Разработен е подход за редуциране на пресмятанията, който е реализиран програмно.

Част от получените в дисертационния труд резултати са публикувани в четири труда. Една публикация е в международно списание с импакт-фактор “Mathematics” ($IF = 2.4$, Q1). Една публикация е в международно списание “International Journal Bioautomation” с SJR ($SJR = 0.159$), две публикации са в Годишника на секция “Информатика” (една от които – студия), издание на Съюза на учените в България. Резултати, получени в дисертационния труд, ще бъдат докладвани на Конгреса на Европейската академия по неврология в Хелзинки, Финландия, и на международна конференция BioInfoMed’2024 в Бургас, България.

Цел на дисертационния труд

Подобряване на диагностичния процес в медицината посредством проектиране, трениране и оптимизиране на програмни алгоритми с конволюционни дълбоки невронни мрежи.

За постигане на целта са поставени следните задачи:

1. Да се реализират програмно невронни мрежи за диагностициране на стадията на болестта на Алцхаймер.
2. Да се определят специфичността и чувствителността на разработените модели.
3. Да бъде подобрена точността на моделите с нов метод на извеждане.
4. Да се оцени точността на извежданията в термините на интуиционистки размитите множества чрез интеркритериалния анализ.
5. Да се предложи метод за определяне на прагови стойности за степените на принадлежност и неопределеност, чрез който да се повиши точността на моделите.
6. Да се намери подход за подобряване на скоростта на интеркритериалния анализ.

Глава 1

Литературен обзор

1.1 Невронни мрежи

Невронните мрежи са мощно средство за анализ, моделиране и решаване на разнообразни проблеми в областта на изкуствения интелект. От първите, вдъхновени от човешкия мозък, до съвременните имплементации, те са преминали през значително развитие и са се утвърдили като една от основните технологии за машинно обучение.


1.1.1 История на невронните мрежи

През 1957 година, Розенблат (Rosenblatt) представя модел на невронна мрежа, известен като перцептрон (вж. Фигура 1.1).

Въпреки първоначалния ентузиазъм, ограниченията на еднослойните перцептрони са разкрити в [4]. В нея те доказват, че еднослойните перцептрони не могат да решат проблеми като XOR функцията. За да се преодолее това ограничение се изтъква необходимостта от многослойни архитектури.

1.1.2 Конволюционни невронни мрежи

Конволюционни невронни мрежи - Convolutional Neural Networks (CNN) са вид изкуствени невронни мрежи, проектирани за обработка на данни с пространствена



Фигура 1.1: Представление на перцептрон с един слой и сигмоидална функция на активация

структура, като изображения. Техните архитектури са вдъхновени от биологичната организация на визуалния кортекс на човешкия мозък и са оптимизирани за извличане на характеристики от визуални данни, като ръбове, текстури, форми и други.

С развитието на CNNs, появата на дълбоки архитектури става все по-значима. ResNet (Residual Network) е представен от Хе и сътр. през 2015 г. [5]. Резидуалните блокове имат вида $B(x) = F(x) + x$. Това позволява на мрежата да учи по-ефективно и да избягва проблемите с изчезващия градиент.

1.2 Интуиционистки размити множества

1.2.1 Теоретична основа на интуиционистки размити множества

Нека е фиксирано множеството E . Множеството A се нарича интуиционистки размито множество (ИРМ), ако има вида [6]:

$$A = \{\langle x, \mu_A(x), \nu_A(x) \rangle \mid x \in E\}$$

където функциите $\mu_A : E \rightarrow [0, 1]$ и $\nu_A : E \rightarrow [0, 1]$ задават съответно степента на принадлежност и на непринадлежност на елемента $x \in E$ към интуиционистки размитото множество A , което е подмножество на E и за всяко $x \in E$:

$$0 \leq \mu_A(x) + \nu_A(x) \leq 1$$

Функцията π_A , която се определя от формулата:

$$\pi_A(x) = 1 - \mu_A(x) - \nu_A(x)$$

задава степента на неопределеност на принадлежността на елемента $x \in E$ към множеството A . В случаите, когато E е размито множество, степента на неопределеност $\pi_A(x) = 0$ за всяко x . Степента на принадлежност на елемент в ИРМ се определя като степента, до която елементът принадлежи към дадено множество, докато степента на непринадлежност представлява степента, до която елементът не принадлежи към това множество. Третият параметър, въведен в ИРМ, е степента на неопределеност, която количествено определя степента на неопределеност, свързана със степените на принадлежност и непринадлежност. Въвеждането на този параметър ги прави по-подходящи за представяне на неточна и неясна информация [7, 8, 9, 10, 11].

1.2.2 Норми и метрики в интуиционистки размитите множества

Всички ИРМ над фиксиран универсум E образуват метрично пространство с метрика, която се отнася не към елементите на E , а към стойностите на функциите μ и ν , тъй като "нормата" на даден елемент x на ИРМ съпоставя на този елемент число, свързано със стойностите на функциите μ и ν , изчислени за този елемент x . Наличието на втората функционална компонента ν довежда до дефинирането [12] на различни норми за всяко x относно фиксирано $A \subset E$.

1.2.3 ИРМ за целите на медицинската диагностика въз основа на МР изображения

Медицинските изображения са активна област на изследване, където аномалиите се откриват неинвазивно. Поради сложността на изображенията много от структурите са трудно видими и различни компютърни техники се прилагат от изследователите за обработка на медицински изображения.

1.2.4 ИРМ и невронни мрежи

През 2023 г. Atanassov и сътр. [13] разработват концепция за интуиционистки размита дълбока невронна мрежа (IFDNN), която комбинира изкуствени невронни мрежи и интуиционистки размити множества. Целта е да се комбинират предимствата на двата метода.

1.3 Метод на интеркритериалния анализ

Методът на интеркритериалния анализ, е метод за изследване на зависимостите между критерии, които оценяват набор от обекти. Основана се на интуиционистки размитите множества като математически инструмент за третиране на неопределеност, както и на индексиранияте матрици от обобщените мрежи.

Нека е дадена матрица $M = (a_{C_p, O_q})$ с размерност m на n . За всеки две цели числа p и q , изпълняващи неравенствата $1 \leq p \leq m$ и $1 \leq q \leq n$:

- C_p е критерий;
- O_q е обект;
- a_{C_p, O_q} е оценката на q -тия обект спрямо p -тия критерий.

Всяка такава оценка се определя като реално число или като друг обект, който е сравним с останалите оценки спрямо дадена релация R . Формално можем да дефинираме за всяко i, k, l релацията $R(a_{C_i, O_k}, a_{C_i, O_l})$.

Нека $\bar{R}$ е дуалната релация на R , така че $\bar{R}$ е удовлетворена, тогава и само тогава, когато R не е удовлетворена. Например, ако R е релацията “ $<$ ”, то тогава $\bar{R}$ е релацията “ $\geq$ ”.

1.3.1 Интеркритериални броячи

На базата на предходните релации, можем да конструираме броячи, чрез които да получим оценки между критериите.

Нека S_{ij}^μ е броят на случаите, в които $R(a_{C_i, O_k}, a_{C_i, O_l})$ и $R(a_{C_j, O_k}, a_{C_j, O_l})$ са удовлетворени едновременно. Нека S_{ij}^ν е броят на случаите, в които $R(a_{C_i, O_k}, a_{C_i, O_l})$ и $\bar{R}(a_{C_j, O_k}, a_{C_j, O_l})$ са удовлетворени едновременно.

Тъй като общият брой сравнения по двойки между обектите е $(n^2 - n)/2$, може да се види, че:

$$S_{ij}^\mu + S_{ij}^\nu \leq \frac{(n^2 - n)}{2}$$

За всяко i, j , такива че $1 \leq i < j \leq m$, и за $n \geq 2$ определяме:

$$\begin{aligned}\mu_{ij} &= \frac{2}{(n^2 - n)} S_{ij}^{\mu}, \\ \nu_{ij} &= \frac{2}{(n^2 - n)} S_{ij}^{\nu}.\end{aligned}\tag{1.1}$$

Конструираме интуиционистки размита двойка $\langle \mu_{ij}, \nu_{ij} \rangle$, чрез тези две стойности, за всеки два критерия C_i и C_j . Тази двойка представлява интуиционистки размита оценка на сходството между двата критерия.

Глава 2

Диагностика на Алцхаймер с конволюционни неврони мрежи

В тази глава е разгледано приложение на конволюционни невронни мрежи за диагностика на болестта на Алцхаймер. Подходът следва изследване на автора публикувано в [14].

2.1 Данни

За целта на настоящето изследване използваме свободни данни от платформата *kaggle* [15]. Около 5000 MRI (изображения от ядрено магнитен резонанс) са разделени в множество за трениране (*train set*) и множество за тестване (*test set*) на случаен принцип.

Всяко изображение е анотирано с един от следните четири класа:

1. NonDemented - без деменция
2. VeryMildDemented - много слаба деменция
3. MildDemented - слаба деменция
4. ModerateDemented - умерена деменция

Всички изображения и анотации се наричат дейтасет (*dataset*).

2.2 Образна диагностика чрез конволюционни невронни мрежи

Предложено е решение с малко код (*low code*), което използва библиотеката *fastai*. Подхода е универсален и с минимални промени може да се приложи за други заболявания, които имат образна диагностика.

2.3 Програмен код

Избирана е архитектура на конволюционна невронна мрежа *resnet34*. *ResNet* [5] [5]. Има варианти с по-малко параметри (например *ResNet18*), както и с повече (например *ResNet101*). Моделът, който се зарежда, е трениран на изображения [16], които нямат нищо общо с MRI, но въпреки това подобряват резултатите и правят възможно тренирането да бъде много по-бързо.


2.3.1 Избор на стъпка

Стъпката в оптимизационните задачи за изкуствен интелект се нарича learning rate. Това е най-важният параметър при тренирането на невронни мрежи.

fastai предоставя визуална помощ при избора на learning rate чрез метода.

Традиционно определянето на подходящ learning rate е изисквало проби и грешки. В [17] Смит предлага алтернативен подход.

На Фигура 2.2 е представена графика на загубите за модела *resnet34* трениран върху ЯМР изображенията на болестта на Алцхаймер. В случая е показана точката на най-стръмно спускане на загубата (valley). За learning rate се избира стойност, близка до тази точка, или най-малката достигната стойност. В случая избираме 0.00144, което не е най-малката стойност, но е близко едновременно до локалния минимум около 10^{-3} и до точката valley.



Фигура 2.2: Графика на загубите за модела *resnet34*, трениран върху ЯМР изображенията на болестта на Алцхаймер. valley е точката на най-стръмно спускане на загубата. Препоръчително е да се избере learning rate около нея.

2.4 Трениране на модела

Тренираме модела на графична карта NVIDIA Tesla P100 за около 30 минути. Тренирането на графична карта ускорява времето за тренирането няколко пъти, сравнено с трениране на обикновен процесор [18].

За самото трениране използваме техниката fine tuning. Това позволява да започнем тренирането с предварително натренирани параметри, които да дотренираме.

2.5 Резултати

В Таблица 2.1 е представена матрица на действителните и предвидените класове – матрица на объркаността (confusion matrix). Стойностите по главния диагонал са верните предвиждания. Лесно се забелязва, че грешките са концентрирани в близки категории:

- NonDemented и VeryMildDemented са сбъркани в 218 примера
- VeryMildDemented и MildDemented са сбъркани в 374 примера

Това може да се интерпретира по два начина. Първо, няма консенсус между анотаторите къде минават границите на отделните класове. Или второ, важните признаци, отделящи двете състояния, не са били научени от модела. При преглед на данните от експерт по Алцхаймер се установи, че е трудно да се даде категоричен отговор за прогреса на заболяването само на база на изображенията. Това би могло да причини и двата изброени проблема.

Анотация	Предвиждане			
	NonDemented	VeryMildDemented	MildDemented	ModerateDemented
NonDemented	543	94	3	0
VeryMildDemented	124	309	15	0
MildDemented	65	64	50	0
ModerateDemented	2	5	1	4

Таблица 2.1: Матрица на объркаността върху тестовото множество.

Чувствителността на модела, дефинирана чрез $TP/(TP+FN)$ е 70%, а специфичността, дефинирана чрез $TN/(TN+FP)$, е 85%.

На Фигура 2.3 са представени резултатите от модела *resnet34* върху девет случайно избрани изображения.


На фигура 2.4 са представени резултатите от модела *resnet34*, които моделът дава за 9 грешни предвиждания с най-голяма сигурност. Резултата на модела е близко до 1, което показва голяма сигурност в предвиждането. От друга страна, реалните класове са съседни класове: NonDemented и VeryMildDemented; VeryMildDemented и MildDemented; MildDemented и ModerateDemented.

2.6 Заключение


В Раздел 2.5 демонстрираме, че с малко количество код и кратко време за трениране, можем да получим модел с много добри резултати. Също така трябва да се отбележи, че кодът може много лесно да бъде адаптиран за образната диагностика на друго заболяване.

Подобни автоматизирани системи не могат да заменят преценката на лекар. Основните им приложения са за (1) подпомагане на лекар в диагностиката или (2) автоматизирано извличане на примери от голям обем данни.

В Глава 3 ще разгледаме подход, който може да подобри значително резултатите на класификационната задача чрез агрегиране на предвижданията на няколко класификатора.



Фигура 2.3: Извадка от девет произволни изображения. Над всяко изображение са отбелязани: класа на предвиждането/анотирания клас. Повечето предвиждания са правилни.



Фигура 2.4: Извадка от девет грешно класифицирани изображения с най-голяма сигурност в предвижданията. Над всяко изображение са отбелязани: класа на предвиждането/анотирания клас/загубата за примера/увереността на модела. Загубата за примера е дефинирана като стойността, която конкретния пример допринася в целевата функция.

Глава 3

Метод за извеждане, основан на метода Кемени-Йънг

В Глава 3 са предложени нови начини за извеждане, базирани на метода на Кемени-Йънг (Kemenu–Young) в машинното самообучение. Подхода разширява резултати, публикувани в [19].

3.1 Методът на Кемени-Йънг

Този метод за агрегация на изборни резултати е предложен от Джон Кемени [20] през 1959 г. Идеята зад метода е да се определи рангова подредба на алтернативите, която минимизира разликата между тази подредба и индивидуалните предпочитания на всеки участник. За целта се използва матрица на предпочитания, която отразява степента на предпочитане на всяка двойка алтернативи от страна на всеки участник. Тази матрица се използва за съставяне на алтернативни рангове, които след това се сравняват с цел определяне на общата рангова подредба.

Предполагаме, че имаме множество от n алтернативи $X = \{x_1, x_2, \dots, x_n\}$ и матрица на предпочитания P , където P_{ij} означава предпочитането на алтернатива x_i пред алтернатива x_j . Тези предпочитания могат да бъдат измерени, например, чрез брой гласове за дадена двойка алтернативи.

Целта е да се намери рангова подредба σ на алтернативите, която минимизира сумата на разликите между предпочитанията на участниците и ранговата подредба:

$$\min \sum_{i < j} P_{\sigma(i)\sigma(j)}$$

при условие, че σ е пермутация на индексите $\{1, 2, \dots, n\}$.

Това може да бъде формулирано като задача за намиране на минимален хамилтонов цикъл, което е NP-трудна задача [21]. Нека всяка връзка има тегло, което е свързано с предпочитанията между две алтернативи. За практическото решаване на такива задачи се използват оптимизатори за целочислени задачи (MIP solver)[21].

3.2 Интуиционистки интерпретации на метода на Кемени-Йънг

Интеркритериалният анализ дава възможност да се даде интерпретация в термините на интуиционистки размити множества на метода на Кемени-Йънг. Степените на неопределеност и непринадлежност в интуиционистките множества са удобен инструмент за оценка на качеството на предвидените резултати.

Методът на Кемени-Йънг използва бюлетини, върху които избирателите класират вариантите според техния ред на предпочитание. Избирател може да класира повече от един вариант на едно и също ниво на предпочитание. Некласирани варианти обикновено се тълкуват като най-малко предпочитани. За да установим съответствие с термините на интеркритериалния анализ (вж. Раздел 1.3.1) ще използваме следните правила:

- равнокласифицираните варианти ще увеличават брояча на неопределеност
- предпочитанията ще увеличават брояча на принадлежност

Първата стъпка е създаването на матрица, която брой двустранните предпочитания на избирателите. Втората стъпка е да се тестват всички възможни класирания, да се изчисли оценка за всяко такова класиране и да се сравнят оценките. Всяка оценка за класиране е равна на сумата от двустранните предпочитания, които се отнасят за това класиране. Класирането, което има най-голяма оценка, е избраното по метода на Кемени-Йънг.

3.2.1 Броене и класиране по метода на Кемени-Йънг

Въведена е формална дефиниция за класиране.

Дефиниция 3.1. Класиране наричаме наредена n -орка $(X_1, X_2, \dots, X_n)$, подредена от най-ниско класирания елемент X_1 до най-високо класирания елемент X_n .

В общия случай не съществува класиране $(X_1, X_2, \dots, X_n)$, което за всеки $i < j$ всеки избирател $X_i \preceq X_j$. Това мотивира нуждата от процедура, която да даде класиране, което е оптимално в някакъв смисъл.

3.2.2 Изчисляване на общото класиране

След като се обхождат всички възможни пермутации на класиранията на кандидатите и се изчисли оценка за всяко, може да се идентифицира класирането, което има най-голяма оценка, и това става общото класиране според метода на Кемени-Йънг.

3.2.3 Матрица на обобщението

След като общото класиране е изчислено, броят на сравненията на двойки може да бъде организиран в матрица на обобщението.

3.3 Извеждане в машинното самообучение

Извеждане в машинното самообучение е процесът на получаване на резултат или предсказания от модела, който е бил обучен с помощта на данните. След като моделът е обучен чрез подходящ алгоритъм върху обучаващия набор от данни, извеждането се използва за получаване на предсказания за нови или непознати данни, които не са били част от обучението.

Важно е да се отбележи, че извеждането не включва обновяване на параметрите на модела. Те са фиксирани след обучението, а извеждането използва тези параметри за извеждане на предсказания. Това прави извеждането по-бързо от обучението, тъй като не се изисква промяна на параметрите на модела.

3.4 Проблеми при извеждането на класификационни задачи с няколко класа

Нека разгледаме обобщението на задачата за класифициране от два класа към K -класа. Проблемите при класификацията на множество класове могат да представят специфични предизвикателства, които се различават от тези в двоичните класификационни задачи. Класификаторите могат да произведат K -мерен вектор със стойности, съответстващи на сигурността за всеки клас. Освен това, има два други подхода за справяне с множествената класификация: “един срещу един” (OvO) и “един срещу останалите” (OvR), всеки със своите предимства и ограничения.

3.4.1 Един срещу един (OvO):

В OvO (One vs One) се обучава двоичен класификатор за всяка двойка класове. За N класа това дава $K(K-1)/2$ класификатора. Въпреки че изисква повече класификатори, OvO може да бъде изчислително ефективен за алгоритми, които се мащабират добре с броя на образците. Такъв пример е методът на опорните вектори (support vector machines, SVM). Въпреки това OvO може да страда от дисбаланс в разпределението на класовете в получените двоични данни.

3.4.2 Един срещу останалите (OvR):

В OvR (One vs Rest) се обучава двоичен класификатор за всеки клас, като се разглеждат екземплярите на този клас като положителни примери, а екземплярите на всички останали класове – като отрицателни примери. OvR обикновено дава N класификатора за N класа. Въпреки че OvR може по-ефективно да се справя с дисбаланса в класовете отколкото OvO, той може да доведе до по-малко точни резултати, ако класификаторите са насочени към преобладаващия клас.

3.4.3 Нормализирани вероятности

Невронните мрежи и други класификатори могат да дадат изход в многомерен вектор. Най-често при класификация се ползва метод за нормализиране на

изходните вектори. При него за всеки пример генерираме вектор с дължина, равна на броя на класовете, чийто елементи се сумират до 1. Всеки елемент на вектора се интерпретира като “вероятност” класа на съответната позиция да е действителния клас. Вероятност е в кавички, защото без калибрация тези числа не са близки до истинските вероятности.

3.5 Калибрация на класификатори

Калибрацията в машинното обучение е процесът на коригиране на прогнозите или вероятностите, предоставени от моделите, така че те да бъдат възможно най-близки до реалните стойности или вероятности на събитията, които се опитваме да предскажем [22]. Този процес се извършва с цел увереността в модела да бъде максимизирана и да се подобри неговата точност.

Методите за калибриране се прилагат след като модела е трениран. Те използват валидационни данни, за да се състави функция за калибриране на предварително обучен модел, която трансформира прогнозите на модела, за да бъдат по-добре калибрирани.

Най-общо методите могат да се разделят на параметрични и непараметрични [23]. Параметричните намират параметрите на функция, която най-добре приближава предвижданията на модела до реализираните вероятности. Пример за параметричен метод е Бриер [24]. Непараметричните методи разглеждат само подредбата на предвидените класове. Изотоничната калибрация е пример за непараметричен метод [25].

В дисертационния труд е показано как се получава оценката за правдоподобността на резултата в термините на интуиционистки размитите множества. Това представлява непараметричен метод за калибрация, основан на метода на интеркритериалния анализ.


3.6 Агрегиране на резултатите

Новият подход за агрегация е получен като са взети наредбите от различните натренирани класификатори и е избран победител по метода на Кемени-Йънг. За да се използва новият подход за извеждане достатъчно бързо, се прилага стандартна процедура за преобразуване на метода на Кемени-Йънг в оптимизационна задача. За вход на процедурата се използват различните класирания от класификаторите, които подлежат на агрегиране.

3.6.1 Приложение

Използван е ансамбъл от класификатори, върху които е приложен методът, описан в Раздел 3.6. На дейтасета с ЯМР изображения за диагностициране на болестта на Алцхаймер са тренирани девет класификатора. Не е от съществено значение какъв е видът на класификаторите, тъй като метода за агрегация е универсален.

На Фигура 3.2 са показани матриците на обърканост за агрегирания модел по новия метод и на един класификатор. Агрегирането значително подобрява броя



Фигура 3.1: Илюстрация на подхода за извеждане. Тренирани са по три модела от resnet18, resnet34 и resnet50.


правилни предвиждания (главния диагонал на матрицата на объркването), спрямо индивидуалните класификатори, показани по-долу. Наблюдаваме подобрене, което варира от 27 до 103 точни предвиждания повече, спрямо оригиналните девет модела.

3.7 Практична имплементация на метода за извеждане


За рангове с малка дължина един начин да се изчисли оптимална агрегация е чрез сравнение на резултатите от всички възможни рангове – подход чрез метода на грубата сила [26]. Този подход има алгоритмична сложност $O(n!)$ поради нуждата да се обхождат всички пермутации на категориите.

3.7.1 Формулиране на задача за целочислено оптимизиране

Метода на Кемени-Йънг е NP-труден дори само за четири избиратели [27]. За практическото приложение е построен насочен граф с тегла $G = (V, E)$ с категориите като върхове. Ребрата се дефинират по следния начин: за всяка двойка кандидати i, j , нека $\#>\{i>j\}$, означава броя на избирателите, които класират i по-високо от j . Поставяме ребро между всяка двойка i, j с тегло $w_e = |\#>\{i>j\} - \#>\{j>i\}|$ (ако не е нулево). Ориентацията на реброто е от по-малко предпочитан към по-предпочитан връх.



(а) Резултатите след агрегация по метода, описан в Раздел 3.6. Агрегирането значително подобрява броя правилни предвиждания (главният диагонал на матрицата на объркването), спрямо индивидуалните класификатори, показани по-долу.



(б) *ResNet18* модел има повече грешки спрямо Фигура 3.2а.

Фигура 3.2: Резултати на различните методи за извеждане.

Формулирането се базира на алтернативното тълкуване на оптималната агрегация по Кемени-Йънг, което минимизира теглата на ребрата, с които не се съгласява:

$$\min \sum_{e \in E} w_e x_e$$

при условието:

$$\forall i \neq j \in V, x_{ij} + x_{ji} = 1 \forall i \neq j \neq k \neq i \in V, x_{ij} + x_{jk} + x_{ki} \geq 1$$

В горепосочената задача всички променливи са цели бинарни числа, Те имат следното тълкуване:

$x_{ij} = 1$, ако в агрегирания ранг i е класиран по-ниско от j .

Ограниченията съществено налагат, че променливите дефинират тотална наредба. Първият набор от ограничения налага антисиметрия и пълнота: или i е класиран по-ниско от j , или обратното. Вторият набор от ограничения налага транзитивност [26].

Глава 4

Оценка с интеркритериален анализ на извеждания в машинното самообучение

В тази глава е приложена процедура, основана на интеркритериалния анализ, върху метода, въведен в Раздел 3.6. Конкретният метод за извеждане не е от съществено значение за процедурата, която е представена. Достатъчно е да съществуват двойки предпочитания за всеки пример.

Нека имаме агрегирано класиране, произведено от модели $c_1, c_2, \dots, c_m$. Тези модели ще са обектите в интеркритериалния анализ (вж. Раздел 1.3).

С i, j ще означаваме класове от класификационната задача. Нека общия брой класове е K . Различните класове ще асоциираме с критериите в интеркритериалния анализ (вж. Раздел 1.3).


На Фигура 4.1 са представени класификатори c_k и c_l . Представени са и предвидените стойности от класификатора $c_k - a_{i,k}, a_{j,k}$ за класове i и j , съответно.

Нека агрегираният метод за извеждане е избрал за победител клас j . Изчисляваме $\mu_{i,j}, \nu_{i,j}$ както са дефинирани във Формула 1.1, за всеки клас i , различен от j . Т.е. броим в каква част от случаите два произволно избрани класификатора k и l ще имат съгласие или несъгласие при подреждането на класовете i и j , съответно за $\mu_{i,j}, \nu_{i,j}$. За релацията в интеркритериалния анализ можем да използваме стандартно сравнение на изходните стойности, но може да се използва и по-сложна релация, която по-добре отразява степента на неопределеност, както е направено в Раздел 4.1.

Осредняваме $\mu_{i,j}$ и $\nu_{i,j}$ по i , за да получим интуитивистки размита оценка на предвидения клас след агрегация j , (μ_j, ν_j) .

4.1 Приложение върху класификаторите на болестта на Алцхаймер

Разгледано е приложение на метода, предложен в Раздел 4, върху агрегацията на деветте класификатора на болестта на Алцхаймер, използвани в Раздел 3.6.1. За да получим по-достоверни резултати за неопределеността, дефинираме



Фигура 4.1: Нормализирани вероятности за класове i, j и за модели k, l . Елемента на матрицата $a_{i,k}$ е предвиждането на модел k за клас i . Прилагаме интеркритериален анализ като броим броя съгласия и несъгласия на релациите $R_l(a_{i,k}, a_{j,k})$ и $R_k(a_{i,l}, a_{j,l})$. Релациите R_l и R_k , в общия случай, могат да са различни.

предвижданията за два класа за равни, ако разликата им е по-малко от 0.25. Програмната реализация на *Python* може да се намери в класа *IntervalNumber*.

Резултатите от приложения метод са представени чрез интуиционистки размити интерпретационни триъгълници. Примерите от всяка клетка на матрицата на объркаността от Фигура 3.2а, представяме с отделен интуиционистки размит интерпретационен триъгълник. На Фигура 4.2 долния триъгълник отговаря на клетка с ред *MildDemented* и стълб *NonDemented* в Фигура 3.2а с общо 51 примера.

Примерите със сгрешени предвиждания имат по-голяма неопределеност. Това показва, че оценките с интеркритериалния анализ могат да се използват за засичане на грешките на модела. В Раздел 4.2 е разгледано как може да бъде използван този факт по-конкретно.


4.2 Резултати над прагова стойност

Представен е метод за увеличаване на точността на предвижданията като са избрани само предвижданията, които са оценени за достоверни, чрез прилагане на прагови стойности подобно на класификацията, въведена в [28]. Предвижданията, които не се смятат за достоверни, могат да бъдат разгледани допълнително от експерт. Делът на примерите, които не минават през експерт, се нарича покритие.

За целта:

1. Задаваме предварителна точност на изведените резултати.
2. Намираме степен на принадлежност и неопределеност, над която предвижданията изпълняват зададената точност при най-голямо покритие.


За модела, предвиждащ Алцхаймер, е фиксирана точност 90%. Намерено е, че



Фигура 4.2: Интуиционистки размити интерпретационни триъгълници на примерите от матрицата на объркването от Фигура 3.2а. Над всяка графика е отделязан от кой ред и колона на матрицата са примерите.

праг на принадлежност към класа над 0.9 и праг на неопределеност под 0.3 изпълнява тази точност при най-голямо покритие.

На Фигура 4.8 е представена матрицата на обърканост, получена при прилагане на посочените прагови стойности. Сравнителният анализ показва, че резултатите са съществено по-точни спрямо начина, по който са били получени преди въвеждането на тези прагове.



Фигура 4.8: Матрица на обърканост след прилагане на принадлежност над 0.9 и неопределеност под 0.3.

С тези прагове са получени предвиждания за 777 примера от общо 1279 примера в тестовия дейтасет. Това прави покритие от 60,75% при точност от 90%.

4.3 Агрегиране на резултатите и оценка с интеркритериален анализ при OvO

Интеркритериалния подход за извеждания може да се приложи при процедурата OvO. При стандартната процедура за извеждане при метода OvO агрегацията се осъществява чрез осредняване на предвидените стойностите (score) на всички $K(K-1)/2$ класификатора. Това е процедурата в *scikit-learn* [29]. Този подход не изисква много изчисления за разлика от предложения в Раздел 3.6. В повечето случаи това не е проблем, защото крайният модел е ансамбъл от малко съставни модели. За да приложим Раздел 3.6 намираме наредба, която минимизира несъгласията в $K(K-1)/2$ -те класификатора по метода на Кемени-Йънг.

4.4 Постигане на наредба

В [30] е доказан резултат относно наредбата върху интуиционистки размити двойки, генерирани от средното аритметично на степен (M_p) за $p > 0$. Въведено е семейство от наредби върху интуиционистки размити двойки, генерирани от

претегленото средно аритметично на степен (M_p^α) и е доказано, че за тях важи подобен резултат. Разглежданите наредби по естествен начин разширяват класическата частична наредба и позволяват сравняването на предварително несравними алтернативи. Показвано е, че съществува $p > 0$, за което при новата наредба всички елементи стават сравними.

Дефиниция 4.1 ([31]). Означаваме интуиционистки размитите двойки (ИРД) с $\langle a, b \rangle$.

$$a + b \leq 1 \quad (4.1)$$

В [32] е дадена следната дефиниция за сравнение на интуиционистки двойки.

Дефиниция 4.2. За две интуиционистки двойки: $u = \langle u_1, u_2 \rangle$ и $v = \langle v_1, v_2 \rangle$, казваме, че u е по-малко или равно на v , т.е.:

$$u \leq v \Leftrightarrow \begin{cases} u_1 \leq v_1 \\ u_2 \geq v_2 \end{cases}.$$

Дефиниция 4.3 ([33], стр. 175). Средното аритметично на степен на две неотрицателни числа x и y се определя по следния начин:

$$M_p(x, y) = \left(\frac{x^p + y^p}{2} \right)^{\frac{1}{p}}. \quad (4.2)$$

Средното аритметично на степен има следното интересно свойство [33] (стр. 175):

$$M_p(x, y) \leq M_q(x, y) \text{ за } p \leq q.$$

Дефиниция 4.4 (вж. [33], стр. 175). Средното аритметично на степен с тегло α на две неотрицателни числа x и y се определя по следния начин:

$$M_p^\alpha(x, y) = (\alpha x^p + (1 - \alpha)y^p)^{\frac{1}{p}}, \quad (4.3)$$

където $\alpha \in (\frac{1}{2}, 1)$.

Дефиниция 4.5 ([31]). За дадени две ИРД-ки $u = \langle u_1, u_2 \rangle$ и $v = \langle v_1, v_2 \rangle$, казваме, че u е предпочитан пред v по средното геометрично на степен p с предпочитан първи компонент, и пишем $u \preceq_{\mu; M_p} v$, ако

$$\begin{cases} 1 - u_1 \geq 1 - v_1 \\ M_p(1 - u_1, u_2) \geq M_p(1 - v_1, v_2). \end{cases} \quad (4.4)$$

Дефиниция 4.6. За дадени две ИРД-ки $u = \langle u_1, u_2 \rangle$ и $v = \langle v_1, v_2 \rangle$, казваме, че u е предпочитано пред v по средното геометрично на степен p с тегло α , и пишем $u \preceq_{\mu; M_p^\alpha} v$, ако

$$\begin{cases} 1 - u_1 \geq 1 - v_1 \\ M_p^\alpha(1 - u_1, u_2) \geq M_p^\alpha(1 - v_1, v_2). \end{cases} \quad (4.5)$$

Доказана е и използвана следната лема:

Лема 4.1. За всяка константа $c \in (\frac{1}{2}, 1)$ и за всички $t \in (0, 1 - c)$, следното неравенство е изпълнено:

$$(2c - 1) \ln(2c - 1) > (c - t) \ln(c - t) + (c + t) \ln(c + t). \quad (4.6)$$

Доказана е и следната лема:

Лема 4.2. Нека $a \in (\frac{1}{2}, 1)$. Тогава, за всички $k \in (1, \frac{a}{1-a})$ и $t \in (0, a - k(1 - a)]$, е вярно, че

$$ka \ln(a) + (k(1 - a) + t) \ln(k(1 - a) + t) < t \ln(t). \quad (4.7)$$

4.4.1 Основни резултати

Формулиран и доказан е основния резултат в следната теорема.

Теорема 4.1. Нека $u = \langle u_1, u_2 \rangle$ и $v = \langle v_1, v_2 \rangle$. Ако

$$u \preceq_{\mu; M_p} v \quad (4.8)$$

за някое $p > 0$, то

$$u \preceq_{\mu; M_q} v \quad (4.9)$$

за всички $q > p$.

Този резултат позволява да се генерират всички наредби с $p > 0$ като преход от частична към пълна наредба. Това се постига при граничния преход $p = \infty$. От (4.9), знаем, че тази подредба запазва релациите, т.е. увеличаваме броя на сравнимите елементи по консистентен начин. Въвеждането на тегло α позволява да нагласим фино наредбата, като се придвижваме все по-близо до линейната подредба, генерирана с по-голямо тегло на първата компонента. Доказана е следната теорема.

Теорема 4.2. Нека $u = \langle u_1, u_2 \rangle$ и $v = \langle v_1, v_2 \rangle$. Нека $\alpha \in (\frac{1}{2}, 1)$. Тогава, ако

$$u \preceq_{\mu; M_p^\alpha} v \quad (4.10)$$

за някое $p > 0$, имаме

$$u \preceq_{\mu; M_q^\alpha} v \quad (4.11)$$

за всички $q > p$.

Нека $u = \langle u_1, u_2 \rangle$ и $v = \langle v_1, v_2 \rangle$. Нека $\alpha_1 \in (\frac{1}{2}, 1), \alpha_2 \in (\alpha_1, 1)$. Тогава, ако за някое $p > 0$,

$$u \preceq_{\mu; M_p^{\alpha_1}} v \quad (4.12)$$

следва, че

$$u \preceq_{\mu; M_p^{\alpha_2}} v. \quad (4.13)$$

4.4.2 Приложение върху резултатите за стадиране на болестта на Алцхаймер

Представен е код на *Python* за намиране на стойността на p , който превръща интуиционистки размити двойки в тотална наредба. Така е намерена стойност $p = 12.81$, постигаща тотална наредба за резултатите от Раздел 4.1.

Глава 5

Подобряване на бързодействието на алгоритъма за интеркритериален анализ

В тази глава е показано, че изчисляването на интеркритериалните броячи може да се направи за $O(n \log n)$ (квазилинейна сложност). До този момент всички имплементации са използвали $O(n^2)$ изчисления [34, 35, 36], което не позволява обработка на данни над стотици хиляди. Резултатите са представени за пръв път в [37].

5.1 Означения

Всички вектори, които се разглеждат в тази глава са n -мерни, елементите на които можем да подредим с релация на наредба " $\leq$ ". Елементите на различните вектори не е нужно да принадлежат на едно и също множество, но въпреки това ще записваме " $\leq$ " за всеки от тях.

Дефиниция 5.1. Нека k и l са два n -мерни вектора. Казваме, че индекси i, j , $i < j$ са в **несъответствие (disagreement)** [38], тогава и само тогава, когато

$$k_i \leq k_j \wedge l_i > l_j \vee k_i > k_j \wedge l_i \leq l_j$$

Дефиниция 5.2. Ще означаваме с $\text{count_disagreements}(k, l)$ броя несъответствия между k и l

Има $n(n-1)/2$ такива комбинации от индекси i, j , $i < j$, които тривиално могат да се обхоят за $O(n^2)$.

Показано е, че броя несъответствия между k и l , $\text{count_disagreements}(k, l)$, може да бъде пресметнат за $O(n \log n)$. Предходните имплементации се изпълняват за $O(n^2)$, колкото са комбинациите от индекси.

Дефиниция 5.3. Казваме, че индекси i, j , $i < j$ са в **равенство (неопределеност)** [38], тогава и само тогава, когато

$$k_i = k_j \wedge l_i = l_j$$

Равенство между елементите може да дефинираме по естествения начин при наличие на наредба.

Дефиниция 5.4. Казваме, че индекси i, j , $i < j$ са в **съответствие (agreement)** [38], тогава и само тогава, когато не са изпълнени нито дефиницията за несъответствие, нито за неопределеност.

Дефиниция 5.5. Инверсия във вектор v наричаме комбинации от индекси i, j , $i < j$, за които $v_i > v_j$. [39]

Инверсиите на един вектор могат да бъдат изчислени за $O(n \log n)$, както е показано в [39]. Алгоритъма се основава на модификация на *Merge Sort*, който е със сложност $O(n \log n)$.

За вектори, които позволяват равенства между елементите си, ще въведем следното удобно означение.

Дефиниция 5.6. $\hat{v}$ наричаме **изброен вектор** на вектора v^1 и дефинираме елементите му с наредените двойки:

$$\hat{v}_i = (v_i, i)$$

Наредбата на елементите на v разширяваме до лексикографска наредба по естествения начин за $\hat{v}$. Тъй като индексите са уникални, равенства при елементите на изброени вектори не са възможни, дори и да има равенства в началния вектор.

Дефиниция 5.7. Броя инверсии във вектор v ще означаваме с $\text{count_inversions}(v)$.

Дефиниция 5.8. Нека k и l са два вектора. Нека въведем означението $\text{sort}_k(l)$, което сортира елементите на l с подредбата на k .

Нека запишем горната дефиниция чрез сортираща пермутация. Да разгледаме пермутацията σ , която сортира k . За индекси i, j , $i < j \Leftrightarrow k_{\sigma(i)} \leq k_{\sigma(j)}$. Тогава за i -тия елемент имаме

$$\text{sort}_k(l)_i = l_{\sigma(i)}$$

Сортирането е операция, която може да се извърши за $O(n \log n)$ операции [39].

Доказано е следното твърдение:

Твърдение 5.1.

$$\text{count_disagreements}(k, l) = \text{count_inversions}(\text{sort}_{\hat{k}}(\hat{l}))$$

5.2 Пресмятане на интеркритериалните броячи

Използвани са определенията на интеркритериалните броячи от [38] за два критерия k и l , които за краткост отъждествяваме с векторите от стойностите върху n -те обекта. S_{kl}^μ е броят съответствия (agreements), S_{kl}^ν е броят несъответствия (disagreement), S_{kl}^π е броят равенства.

Показано е как да се пресметне S_{kl}^π за $O(n \log n)$.

¹По подобие на функцията в Python `enumerate`, която дава (i, v_i)

5.3 Програмена реализация

Алгоритъмът е реализиран и тестван на Python. Проведено е автоматично тестване с библиотека за рандомизирано тестване *Hypothesis*, което покрива широк спектър от случаи, с които се установява, че двете имплементации в кода с $O(n \log n)$ и $O(n^2)$ дават еднакви резултати.

С този подход се намалява времето за прилагането на интеркритериалния анализ в [40].

5.4 Предишни резултати

Degree of disagreement в интеркритериалния анализ [38] се различава от метриката τ на Кендал [41] по това, че се позволява равенство между елементите. Известно е, че Метриката τ на Кендал може да бъде сведена до броене на инверсии в например [42]. Равенствата в дефиницията на интеркритериалния анализ не пречат на свеждането на `count_disagreements` до броене на инверсии. В [41] се споменава и резултат на Чан и Патрашку [43], който позволява дори по-бързо броене на инверсии с $O(n\sqrt{\log n})$.

Тъй като за изчислението на брояча на равенствата S_{kl}^π не са използвани инверсии, въпросът, дали интеркритериалните броячи могат да бъдат изчислени за $O(n\sqrt{\log n})$, засега остава открит.

Заклучение – Резюме на получените резултати

В настоящия дисертационен труд е реализиран програмно метод, който дава добри резултати при стадирането на болестта на Алцхаймер. Кодът има следните съществени предимства:

- лесен за адаптиране за образната диагностика на друго заболяване
- кратко време за трениране
- малко количество код

Автоматичното диагностициране позволява да се провежда профилактично наблюдение на голям брой пациенти.

Разработен е нов метод на извеждане, базиран на метода на Кемени-Йънг, който предоставя стабилна агрегация на ансамбъл от класификатори. Новият метод е реализиран с програмен код, който решава проблема за NP-трудността при задачи за класифициране на много класове.

При използването на класификационни модели е важно не само да получим възможно най-точен резултат, но и да имаме оценка за точността му. За това е разработен нов метод за оценка на точността на класификационни модели, който се базира на интеркритериалния анализ. Новият метод дава интерпретация на получените резултати в термините на интуционистки размитата логика.

Прилагането на интеркритериалния анализ върху данни с повече измерения става непрактично поради текущите имплементации с квадратична сложност. В отговор на този проблем е предложен алгоритъм с квазилинейна точност.

Насоки за бъдеща работа

- Разработеният метод за диагностика с дълбоки конволюционни невронни мрежи за стадирането на болестта на Алцхаймер да бъде пренесен за други заболявания, които изискват образна диагностика. Подходящи кандидати са болестта на Паркинсон, множествена склероза и други неврологични заболявания.
- Новият метод за извеждане, основан на метода на Кемени-Йънг, да бъде имплементиран програмно, освен за ансамбли, и за OvO класификатори. Това ще даде възможност да бъде прилаган за широк клас от класификационни модели.
- Да се потвърди или отхвърли възможността за допълнително забързване на интеркритериалния анализ до $O(n\sqrt{\log n})$. При намиране на по-бърз алгоритъм интеркритериалния анализ ще може да бъде пресмятан по-бързо и за по-големи обеми от данни.

Основни приноси на дисертационния труд

Научни приноси

1. Предложен е метод за извеждане, базиран на метода на Кемени-Йънг.
2. Предложен е метод за оценка на извеждания на класификационни задачи в термините на интуиционистки размитите множества, базиран на интеркритериалния анализ.
3. Предложен е метод за прилагане на прагови стойности към степените на принадлежност и неопределеност, който значително повишава точността на селектираните резултати
4. Предложен е алгоритъм за подобряване на скоростта на интеркритериалния анализ до $O(n \log(n))$.

Научно-приложни приноси

1. Имплементиран е програмен код на невронни мрежи за диагностициране на стадите на болестта на Алцхаймер.
2. Постигнати са чувствителност на модела от 70%, и специфичност от 85%.
3. Разработен е код на *Python* за новия метод за извеждане, базиран на метода на Кемени-Йънг. Използвана е оптимизационна библиотека *ortools* за постигане на практични времена.
4. Разработеният метод за извеждане дава консистентни резултати, които по начина на построение са устойчиви на грешки.
5. Разработен е код на *Python* на новия метод за оценка на извеждания на класификационни задачи в термините на интуиционистки размитите множества, базиран на интеркритериалния анализ. Кода използва нетривиална релация за равенство между предвижданията на класификатори.
6. Разработен е код за прилагане на прагови стойности към степените на принадлежност и неопределеност. Приложен е към задачата за класификация на болестта на Алцхаймер, като се постига значително повишаване на

точността на селектираните резултати. Постигнати са чувствителност на модела от 80% и специфичност от 95%.

7. Разработен е код на *Python* за подобряване на скоростта на интеркритериалния анализ до $O(n \log(n))$. Текущите имплементации, използващи алгоритъм със сложност $O(n^2)$, са сравнени с новата имплементация чрез пакет за автоматично рандомизирано тестване *Hypothesis*.

Списък на публикациите по дисертационния труд

Научни статии в списания с импакт фактор

1. Vassilev P., Stoyanov T., Todorova L., Marazov A., Andonov V., Ikonov N. Orderings over Intuitionistic Fuzzy Pairs Generated by the Power Mean and the Weighted Power Mean. *Mathematics* 2023, 11(13), 2893; <https://doi.org/10.3390/math11132893>.

ИФ = 2.4 (2022) Попада в категория Q1

Научни статии в списания със SJR ранг в SCOPUS

2. Marazov A., Shanon, A. Improved Speed of InterCriteria Analysis. *International Journal Bioautomation*, (inpress); SJR (SCImago Journal Rankings) (2022): 0.159

Рецензирани научни публикации, издадени от национални научни издателства

3. Маразов А. Образна диагностика на болестта на Алцхаймер с конволюционни невронни мрежи: имплементация с fastai. Годишник на секция “Информатика” Annual of “Informatics” Section Съюз на учените в България Union of Scientists in Bulgaria; Том 11, 2021, 15–23 Volume 11, 2021, 15–23; ISSN 1313–6852.

4. Маразов. А. ”Метод за извеждане в машинното самообучение, основан на метода на Кемени-Йънг“. In: Annual of “Informatics” Section Union of Scientists in Bulgaria 12 (2022/2023), pp. 72–94. ISSN: 1313-6852.

Участия в научни форуми

5. Ignatova V., Marazov. A. Spectrum of vascular cognitive impairment according to the type of brain vascular damage. 10th EAN Congress in Helsinki, Finland on 29 June-02 July, 2024. (приет абстракт).

6. Marazov A., Vassilev P. Assessment with InterCriteria Analysis of Outputs in Machine Learning. 3rd International Symposium on Bioinformatics and Biomedicine, BioInfoMed’2024, 4–6 July 2024 (приет абстракт).

Списък на цитиранията по дисертационния труд

Забелязано е едно цитиране на научните публикации, свързани с дисертационния труд:

1. Статия “Vassilev, P, Stoyanov T., Todorova L., Marazov A., Andonov V., Ikonov N. Orderings over Intuitionistic Fuzzy Pairs Generated by the Power Mean and the Weighted Power Mean. <https://www.mdpi.com/2227-7390/11/13/2893> *Mathematics* 2023, 11(13), 2893; <https://doi.org/10.3390/math11132893>.”

е цитирана в:

Тодорова, С. Обзор върху публикациите по индексирани матрици. Годишник на секция “Информатика” Annual of “Informatics” Section Съюз на учените в България Union of Scientists in Bulgaria, Том XII, 2022-2023, 32-62 Volume XII, 2022-2023, 32-62

Библиография

- [1] K. S. Neetha and D. L. Narayan. “Segmentation and Classification of Brain Tumour Using LRIFCM and LSTM”. In: *Multimedia Tools and Applications* (2024), pp. 1–26.
- [2] R. K. Singh and D. K. Choubey. “Alzheimer’s Dementia and its Various Biomarker Details with Several Detection Methodologies-A Comprehensive Review”. In: *2024 14th International Conference on Cloud Computing, Data Science & Engineering (Confluence)*. IEEE. Jan. 2024, pp. 657–662.
- [3] S. Suganyadevi et al. “Deep Learning Based Alzheimer Disease Diagnosis: A Comprehensive Review”. In: *SN Computer Science* 5.4 (2024), p. 391.
- [4] Marvin Minsky and Seymour Papert. *Perceptrons: An Introduction to Computational Geometry*. MIT Press, 1969.
- [5] Kaiming He et al. “Deep Residual Learning for Image Recognition”. In: *CoRR* abs/1512.03385 (2015). arXiv: 1512.03385. URL: <http://arxiv.org/abs/1512.03385>.
- [6] K Atanassov. “Intuitionistic fuzzy sets”. In: *VII научна сесия на ИТКР, София, юни* (1983).
- [7] K.T. Atanassov. “Research on intuitionistic fuzzy sets in Bulgaria”. In: *Fuzzy Sets Syst.* 22 (1987), p. 93.
- [8] K T Atanassov and G Gargov. “Interval-valued intuitionistic fuzzy sets”. In: *Fuzzy Sets Syst* 31 (1989), pp. 343–349.
- [9] K.T. Atanassov. “Remarks on the intuitionistic fuzzy sets”. In: *Fuzzy Sets Syst.* 51 (1992), pp. 117–118.
- [10] K.T. Atanassov. “Research on intuitionistic fuzzy sets, 1990–1992”. In: *Fuzzy Sets Syst.* 54 (1993), pp. 363–364.
- [11] K.T. Atanassov. “New operations defined over the intuitionistic fuzzy sets”. In: *Fuzzy Sets Syst.* 61 (1994), pp. 137–142.
- [12] К Атанасов. *Актуални проблеми на науката*. БАН, Център за научна информация, 1989.
- [13] Krassimir Atanassov, Sotir Sotirov, and Tania Pencheva. “Intuitionistic Fuzzy Deep Neural Network”. In: *Mathematics* 11.3 (2023), p. 716. DOI: 10.3390/math11030716.
- [14] Alexander Marazov. “ОБРАЗНА ДИАГНОСТИКА НА БОЛЕСТТА НА АЛЦХАЙМЕР С КОНВОЛЮЦИОННИ НЕВРОННИ МРЕЖИ: ИМПЛЕМЕНТАЦИЯ С FASTAI”. In: *Annual of “Informatics” Section Union of Scientists in Bulgaria* 11 (2021/2022), pp. 1–13. ISSN: 1313-6852.

- [15] S Dubey. *Alzheimer's Dataset (4 class of Images)*. 2020. URL: <https://www.kaggle.com/datasets/tourist55/alzheimers-dataset-4-class-of-images>.
- [16] J Deng et al. "Imagenet: A large-scale hierarchical image database". In: *2009 IEEE conference on computer vision and pattern recognition*. 2009, pp. 248–255.
- [17] Leslie N. Smith. "Cyclical Learning Rates for Training Neural Networks". In: *2017 IEEE Winter Conference on Applications of Computer Vision (WACV)*. 2017, pp. 464–472. DOI: 10.1109/WACV.2017.58.
- [18] Anusha Jayasimhan and P Pabitha. "A comparison between CPU and GPU for image classification using Convolutional Neural Networks". In: *2022 International Conference on Communication, Computing and Internet of Things (IC3IoT)*. 2022, pp. 1–4. DOI: 10.1109/IC3IoT53935.2022.9767990.
- [19] А. Маразов. "Инференция с интеркритериален анализ и метода на Kemeny-Young". In: *Annual of "Informatics" Section Union of Scientists in Bulgaria* 12 (2022/2023), pp. 72–94. ISSN: 1313-6852.
- [20] John Kemeny. *Mathematics without Numbers*. 1959.
- [21] Tim Roughgarden. *Algorithms Illuminated (Part 4): Algorithms for NP-Hard Problems*. English. Soundlikeyourself Publishing, LLC, July 2020, p. 273. ISBN: 0999282964.
- [22] Bianca Zadrozny and Charles Elkan. "Transforming classifier scores into accurate multiclass probability estimates". In: *Proceedings of the eighth ACM SIGKDD international conference on Knowledge discovery and data mining* (2002), pp. 694–699.
- [23] Telmo Silva Filho et al. "Classifier Calibration: A Survey on How to Assess and Improve Predicted Class Probabilities". In: *Machine Learning* 112.9 (Sept. 2023), pp. 3211–3260. ISSN: 1573-0565. DOI: 10.1007/s10994-023-06336-7. URL: <https://doi.org/10.1007/s10994-023-06336-7>.
- [24] G. W. Brier. "Verification of Forecasts Expressed in Terms of Probability". In: *Monthly Weather Review* 78.1 (1950), pp. 1–3.
- [25] R. E. Barlow and H. D. Brunk. "The Isotonic Regression Problem and Its Dual". In: *Journal of the American Statistical Association* 67.337 (1972), pp. 140–147.
- [26] V Conitzer, A Davenport, and J Kalagnanam. "Improved Bounds for Computing Kemeny Rankings". In: 2006.
- [27] JJ Bartholdi III, CA Tovey, and MA Trick. "The Computational Difficulty of Manipulating an Election". In: (1989).
- [28] Krassimir Atanassov, Vassia Atanassova, and Georgi Gluhchev. "Notes on Intuitionistic Fuzzy Sets". In: *InterCriteria Analysis: Ideas and Problems* 21.1 (2015), pp. 81–88. ISSN: 1310-4926.
- [29] Fabian Pedregosa et al. "Scikit-learn: Machine learning in Python". In: *Journal of machine learning research* 12.Oct (2011), pp. 2825–2830.

- [30] P. Vassilev et al. “Orderings over Intuitionistic Fuzzy Pairs Generated by the Power Mean and the Weighted Power Mean”. In: *Mathematics* 11.13 (2023), p. 2893. DOI: 10.3390/math11132893.
- [31] P. Vassilev and T. Stoyanov. “On Power Mean Generated Orderings between Intuitionistic Fuzzy Pairs”. In: *Advances in Fuzzy Logic and Technology 2017. EUSFLAT IWIFSGN 2017*. Ed. by J. Kacprzyk et al. Vol. 643. Advances in Intelligent Systems and Computing. Cham, Switzerland: Springer, 2018, pp. 476–481. DOI: 10.1007/978-3-319-66827-7_44.
- [32] Krassimir T. Atanassov. *On Intuitionistic Fuzzy Sets Theory*. Berlin: Springer, 2012.
- [33] P.S. Bullen. *Handbook of Means and Their Inequalities*. Dordrecht, The Netherlands: Kluwer Academic Publishers, 2003.
- [34] D. Mavrov et al. “InterCriteria Software Design: Graphic Interpretation within the Intuitionistic Fuzzy Triangle”. In: *Proceedings of the Fifth International Symposium on Business Modeling and Software Design*. 2015, pp. 279–283.
- [35] D. Mavrov. “Software for intercriteria analysis: Working with the results”. In: *Annual of “Informatics” Section, Union of Scientists in Bulgaria* 8 (2015-2016), pp. 37–44. ISSN: 1313-6852.
- [36] N. Ikononov, P. Vassilev, and O. Roeva. “ICrAData – Software for InterCriteria Analysis”. In: *Int J Bioautomation* 22.1 (2018), pp. 1–10.
- [37] A. Marazov A. Shanon. “Improved Speed of InterCriteria Analysis”. In: *International Journal Bioautomation* (2024).
- [38] Krassimir Atanassov, D. Mavrov, and Vassia Atanassova. “Intercriteria Decision Making: A New Approach for Multicriteria Decision Making, Based on Index Matrices and Intuitionistic Fuzzy Sets”. In: *Issues in Intuitionistic Fuzzy Sets and Generalized Nets* 11 (2014), pp. 1–8.
- [39] Tim Roughgarden. *Algorithms Illuminated (Part 1): The Basics*. Soundlikeyourself Publishing, 2017. Chap. 3.2, p. 62. ISBN: 9780999282908.
- [40] L. Todorova, J. Surchev, and A. Marazov. “Assessment of the Factors Influencing the Survival of the Ventricular Shunt in Infantile Hydrocephalus”. In: *International Journal of Bioautomation* 27.2 (2023), pp. 107–116. DOI: 10.7546/ijba.2023.27.2.000926.
- [41] Wikipedia. *Kendall tau distance*. URL: https://en.wikipedia.org/wiki/Kendall_tau_distance.
- [42] W. Knight. “A Computer Method for Calculating Kendall’s Tau with Ungrouped Data”. In: *Journal of the American Statistical Association* 61.314 (1966), pp. 436–439. DOI: 10.2307/2282833. JSTOR: 2282833.
- [43] Timothy M. Chan and Mihai Pătraşcu. “Counting Inversions, Offline Orthogonal Range Counting, and Related Problems”. In: *Proceedings of the Twenty-First Annual ACM-SIAM Symposium on Discrete Algorithms*. 2010, p. 161. ISBN: 978-0-89871-701-3. DOI: 10.1137/1.9781611973075.15.