

СЕКЦИЯ „СЪВРЕМЕННИ ТЕХНОЛОГИИ, ИНОВАЦИИ И ИЗКУСТВЕН ИНТЕЛЕКТ
В МЕДИЦИНАТА“

ОТ ДАННИ КЪМ ДИАГНОЗА: ИНТЕЛИГЕНТНИ СИСТЕМИ ЗА ПОДКРЕПА НА
МЕДИЦИНСКИ РЕШЕНИЯ ПРИ ОБРАЗНА ДИАГНОСТИКА НА ГЪРДАТА

Сотир Сотиров, Красимир Кралев, Димка Шивачева

Бургаски държавен университет „Проф. д-р Асен Златаров“, бул. „Проф. Якимов“1, Бургас
8010, България

e-mails: ssotirov@btu.bg, kkralev@btu.bg,
dimka-shivacheva@uniburgas.bg

Резюме: Ранната диагностика на рак на гърдата остава един от най-критичните фактори за успешен изход от лечението, като мамографията продължава да бъде „златен стандарт“ за скрининг. Въпреки това, визуалният анализ на мамографски изображения е сложен процес, податлив на субективни грешки и умора на радиолога. Настоящата разработка изследва интеграцията на методи за дълбоко обучение (Deep Learning) с цел автоматизиране на диагностичния процес и повишаване на точността при разпознаване на патологии. Основната цел е създаването на модел за подпомагане на клиничните решения, който да действа като „второ мнение“, класифицирайки аномалиите в ранен етап чрез използване на аотираната база данни CBIS-DDSM.

Методологията на изследването включва изграждането на специализиран подход (pipeline) за предварителна обработка на данни, който трансформира суровите DICOM изображения в 16-битов PNG формат, запазвайки информационната дълбочина, необходима за прецизен анализ. Приложена е стратегия за бинарна класификация (масни срещу калцифицирани образувания) чрез използване на конволюционна невронна мрежа с архитектура ResNet-101 и трансферно обучение. Въведена е персонализирана схема за разделяне на данните (80% обучение, 10% валидиране, 10% тест), което позволява по-строг контрол върху процеса на обучение и предотвратяване на преобучаването (overfitting).

Резултатите демонстрират, че комбинирането на правилна предварителна обработка (изрязване на методи за отделяне на значимата визуална информация и нормализация) с мощни архитектури за компютърно зрение води до създаването на устойчив модел, подходящ за разпознаване на вариации в изображенията. Разработената система не цели да замени лекаря, а да оптимизира клиничния път, като филтрира и категоризира потенциалните лезии с висока точност. Това изследване подчертава потенциала на биоинформатиката да трансформира масивните медицински данни в ясни диагностични индикатори, намалявайки времето за анализ и риска от пропуснати микроскопични аномалии.

Ключови думи: интелигентни системи, невронни мрежи, разпознаване, диагностика, мамография.

FROM DATA TO DIAGNOSIS: INTELLIGENT MEDICAL DECISION SUPPORT
SYSTEMS IN BREAST IMAGING

Sotir Sotirov, Krasimir Kralev, Dimka Shivacheva

Burgas State University „Prof. Dr. Asen Zlatarov“, Prof. Yakimov Blvd. No. 1,
8010, Burgas, Bulgaria

e-mails: ssotirov@btu.bg, kkralev@btu.bg, dimka-shivacheva@uniburgas.bg

Abstract: *Early diagnosis of breast cancer remains one of the most critical factors for a successful treatment outcome, with mammography continuing to be the "gold standard" for screening. However, the visual analysis of mammographic images is a complex process prone to subjective errors and radiologist fatigue. This study explores the integration of Deep Learning methods to automate the diagnostic process and enhance accuracy in pathology detection. The primary objective is to create a clinical decision support model that acts as a "second opinion," classifying early-stage anomalies using the annotated CBIS-DDSM dataset.*

The research methodology involves constructing a specialized data preprocessing pipeline that transforms raw DICOM images into 16-bit PNG format, preserving the informational depth necessary for precise analysis. A binary classification strategy (masses vs. calcifications) was applied using a Convolutional Neural Network (CNN) with a ResNet-101 architecture and transfer learning. A custom data splitting scheme (80% training, 10% validation, 10% testing) was introduced, allowing for stricter control over the training process and the prevention of overfitting.

The results demonstrate that combining proper preprocessing (cropping methods to isolate significant visual information and normalization) with powerful computer vision architectures leads to the creation of a robust model suitable for recognizing image variations. The developed system does not aim to replace the physician but to optimize the clinical workflow by filtering and categorizing potential lesions with high accuracy. This research highlights the potential of bioinformatics to transform massive medical data into clear diagnostic indicators, reducing analysis time and the risk of missing microscopic anomalies.

Keywords: intelligent systems, neural networks, recognition, diagnosis, mammography

1. Въведение

Ранната диагностика на рак на гърдата остава един от критичните приоритети в съвременната медицина. Мамографията е признат скринингов метод, който позволява идентифициране на микроскопични аномалии в ранните стадии на болестта, когато лечението е най-ефективно. Въпреки напредъка в медицинските консултации, анализа на мамографските изображения остава сложна и трудоемка задача, която зависи от опита и внимателността на радиолога.

Технологиите на изкуствения интелект, и в частност дълбокото обучение (deep learning), предоставят нови възможности за автоматизиране и подобряване на точността на диагностичните процеси. Невронните мрежи са способни да научат сложни модели от големи количества медицински данни и да предоставят подпомагане на клиничните решения. Ефективността на подобни подходи е демонстрирана и при други клинични приложения в образната диагностика, като например използването на модулни конволюционни невронни мрежи за автоматизирано откриване на пневмония при деца чрез рентгенови изображения, където са постигнати високи нива на диагностична точност и устойчивост на модела [7].

Целта на настоящото изследване е разработването и оценката на модел на базата на конволюционна невронна мрежа за автоматично разпознаване и класификация на аномалии в мамографските изображения.

2. Цел, задачи и методи на проучването

2.1. Описание на дата сет.

За провеждането на това проучване е използван набор от данни, предоставен от Националния институт по здравеопазване, Националния институт по рака, наречен „CBIS-DDSM | Курирана подгрупа от цифрова база данни за скринингова мамография“ Това е актуализирана версия на цифровата база данни за скринингова мамография (DDSM) и съдържа 2620 сканирани филмови мамографски изследвания. Всички изследвания са на аномални случаи, така че в резултатите няма „нормална“ категория. В нашата статия ще класифицираме изследванията по тип лезия в две отделни категории – „калцифицирани образувания“ и „масни образувания“:

2.2. Класификационни подходи и категории.

Аномалиите в мамографските изображения могат да бъдат класифицирани по няколко критерии:

По тип лезия:

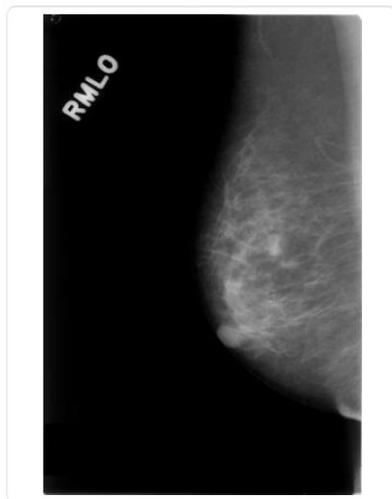
- Масно образувание - тумор или аномално нарастване на тъкан
- Калцифицирано образувание - малки калциеви отлагания

По тип патология:

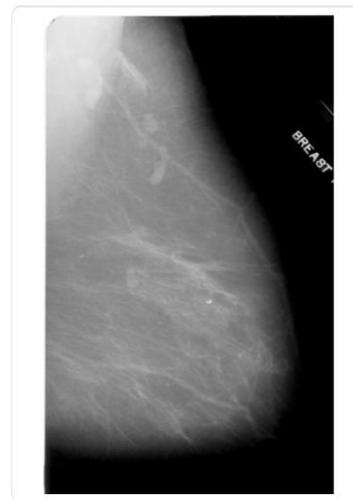
- Доброкачествени (неракови) образувания
- Недоброкачествени (ракови) образувания

По-подробно може да се добави още една патологична категория – доброкачествени без обратно връзка.

Масно образувание



Калцифицирано образувание



Фиг. 1. Изображения на аномалии по тип лезия

Всички изображения са аотирани и в описанието на набора от данни са включени повече подробности за аномалиите, като например различни подкласи за класовете маса и калцификация. Това означава, че има няколко подхода за прогнозиране на аномалиите.

- Бинарна класификация (най-често срещана) – Първо класифицираме изображенията в две категории (маса и калцификация), след което класифицираме отново всички изображения в бинарни категории, като проучваме типа патология (доброкачествена и злокачествена). Подвариантът е да се класифицират с различни мрежи изображенията на маса и калцификация.

- Многокласова класификация (по избор) – класифицираме изображенията в небинарни класове. Например, можем да използваме една мрежа, за да класифицираме в четири класа (доброкачествена маса, злокачествена маса, доброкачествена калцификация и злокачествена калцификация).

- Комбинирана класификация – първо класифицираме в бинарна класификация (маса и калцификация), след което класифицираме в многокласова класификация (доброкачествена, доброкачествена без обратно обаждане и злокачествена).

В нашия казус ще използваме бинарна класификация за първата стъпка, за да разделим изображенията на образувания и калцификация.

2.3. Типове изгледи в мамографията.

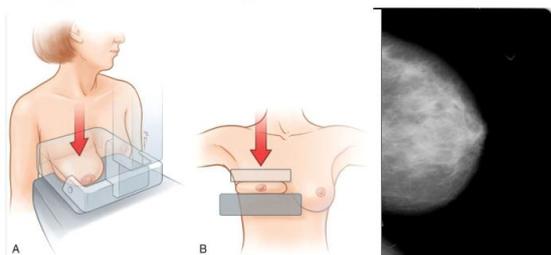
Мамографските изображения се получават при два стандартизирани изгледа, които са задължителни както при скрининг, така и при диагностични изследвания:

Изображенията също са разделени на два типа (CC и MLO). В мамографията (образна диагностика на гърдата) CC и MLO се отнасят до двата стандартни изгледа, заснети по време на скрининг или диагностично изследване.

- СС или Craniocaudal („от главата до опашката“) показва гърдата, компресирана вертикално (отгоре надолу) и заснема цялата гърда отгоре, фокусирайки се върху центъра и вътрешните/външните области. Целта на изследването на това изображение е да се оцени медиалната (вътрешната) и латералната (външната) гърдна тъкан, за да се открият лезии в близост до гърдната стена.

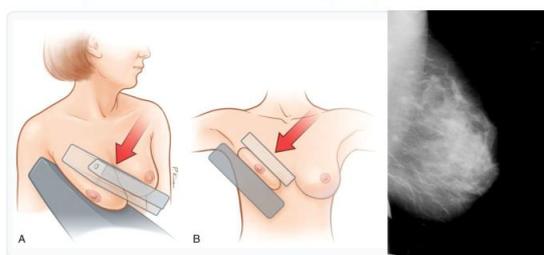
- MLO или медиолатерално наклонено („наклонено странично изображение“) показва гърдата, компресирана наклонено (под ъгъл 30–60° от страни), и заснема повече аксиларна (подмишнична) тъкан и горния външен квадрант (където се появяват около 50% от раковите заболявания). Целта на това изследване е да се визуализира задната (дълбока) тъкан на гърдата и лимфните възли, допълвайки СС изображението за пълно покритие.

СС (Craniocaudal)



Гледка "отгоре надолу". Оценява медиалната и латералната тъкан. Открива лезии близо до гърдната стена.

MLO (Mediolateral Oblique)



Страничен наклон (30–60°). Обхваща аксиларната (подмишнична) тъкан, където са 50% от раковите заболявания.

Фиг. 2. Стандартни изгледи на мамографски изображения

И двата изгледа се използват като част от стандартния протокол, изискван за скринингови мамографии (например в САЩ и ЕС). Ако ги изследваме и двата, ще имаме проверка за наличие на аномалии и ще помогнем за изграждането на 3D локализационен модел чрез триангулация на точното местоположение на образуване/калцификация. Съществува и вероятност лезията да е видима в един изглед, но скрита в друг, което също спомага за по-добра точност на откриването.

2.4. Разделение на датасета на части удобни за обучение на невронна мрежа.

Стъпка от нашето проучване е да разделим изображенията на три различни набора за обучение, валидиране и тестване. Наборът от данни CBIS-DDSM има предварително дефинирано разпределение на определени изображения за обучение на мрежата и определени за тестване. Ние имаме различен подход, като ги разделяме на случаен принцип на три набора (добавяме валидиране в сравнение с подхода на CBIS-DDSM). Тъй като няма повече от едно изображение на един и същ пациент за един тип изглед, считаме, че съдържащата се аномалия е уникална и няма съображения за оценяване на същите аномалии в тестовия набор, както аномалиите, съхранени в наборите за обучение и валидиране. Приехме подхода да разделим изображенията на 80%-10%-10% разпределение на данните между наборите за обучение-валидиране-тестване.

2.5. Подходи за решаване на задачата за разпознаване на заболявания при мамография чрез невронни мрежи.

Изграждането на невронна мрежа, обучена с тези изображения, може да се подходи по два различни начина – да се изградят отделни мрежи за всеки тип изгледи или да се обучи модел с двата типа. Очакваме да имаме по-точни резултати при отделно обучение, но тъй като тъканта и аномалиите са еднакви, вторият метод също е вариант. За да имаме достатъчно количество данни за обучение на една мрежа, ще използваме метода на комбиниране на двата изгледа.

2.6. Програмна среда за построяване и обучение на невронна мрежа.

В съвременната разработка на невронни мрежи Python се е наложил като де факто индустриален стандарт, благодарение на своята екосистема с отворен код и мощни библиотеки (frameworks) като TensorFlow (с Keras) и PyTorch. Тези инструменти предлагат гъвкавост и пълен контрол върху архитектурата на моделите, като PyTorch е предпочитан в научните изследвания заради динамичната си архитектура, а TensorFlow/Keras – в индустриалното внедряване заради мащабируемостта и лекотата на използване. Този подход изисква по-задълбочени умения по програмиране, но осигурява достъп до най-новите алгоритми в сферата на изкуствения интелект.

За разлика от тях, MATLAB предлага по-инженерно ориентиран подход чрез своя Deep Learning Toolbox, който акцентира върху визуалното проектиране и интеграцията със симулационни среди. Силната страна на MATLAB е възможността за работа с минимално писане на код (Low-code) чрез графични приложения за конструиране на мрежи, както и директната връзка със Simulink за тестване на моделите в сложни физически системи (например в автомобилостроенето или роботиката). Въпреки че е платен продукт, той е незаменим за специалисти, които трябва да внедрят AI решения в хардуерна среда с високи изисквания за надеждност.

2.7. Практическо изпълнение на задачата за разпознаване на маммографски изображения.

Наборът от данни CBIS-DDSM съдържа декомпресирани изображения, съхранени в DICOM формат, и дава 16-битова дълбочина на сиво-бяла скала (само едно измерение). За да ги използваме, четем изображенията с функцията `dicomread` на Matlab. Можем да ги използваме директно за обучение на мрежата, но за да запазим системните ресурси, ги конвертираме в 16-битови png изображения, тъй като jpg форматът съхранява само 8 бита, и ги запазиме в системната памет за по-късна употреба. Като част от първоначалната трансформация на изображенията, ние също се опитваме да извлечем значимата част от изображението, да я изрежем и да я конвертираме в изображение с правоъгълна форма от 400x400 пиксела. Така че, първоначалната обработка на изображението се състои от следното:

- 1) Четем изображението с функцията `dicomread` на Matlab
- 2) Извличаме най-големия обект в изображението. Това е обектът „гърда“ и по този начин премахваме незначителните части от изображенията, като например надписите върху изображенията (примерно изображение е показано на фигурата по-долу). Например, някои изображения имат информация за заснетата гледка, отпечатана върху изображението, а това е незначителна информация за нашето проучване.
- 3) Изрязваме само най-големия обект, като използваме неговата маска. По този начин се отърваме от безсмислените празни пространства, които заемат площ от изображението. Важно е да се знае, че самата маска се обработва чрез закръгляване на границите ѝ и запълване на празнините, които са вътрешни за най-големия заснети обект. Това е част от мерките за съхранение на значими данни.
- 4) Намаляваме изрязването до размер 400x400 пиксела. Считаме, че този размер е достатъчен за нас, поради факта, че повечето предварително обучени мрежи, използвани за този вид разпознаване, имат входен слой с размери 224 на 224 или 299 на 299 най-много. Така че, с изображения с размер 400x400 имаме достатъчно място, за да направим допълнителна предварителна обработка на изображенията и като последна стъпка да постигнем необходимия размер на входната мрежа, без да увеличаваме мащаба и съответно да загубим данни.
- 5) Запазваме изображенията в 16-битов png файл с дълбочина на сивото. Предварително обучената модель използва режим на обучение с цвят, така че не е

неразумно да се съхранява информацията в 3-слоен режим, но за да спестим дисково пространство и системни ресурси за по-късния процес, избрахме формата с дълбочина на сивото. Друго съображение е – не е ли по-добре да се използва 8-битов jrg формат? Отговорът е, че в по-късните етапи със сигурност ще имаме процес на нормализиране на данните, стойността на пикселите ще бъде прехвърлена от цяло число към плаваща запетая, а стойността на плаващата запетая ще бъде по-точна, ако се изчисли от 16-битово цяло число. В противовес на съображенията за ресурсите – в края на краищата ще работим с нормализирани плаващи данни, така че изчисленията в мрежовия модел ще се правят така или иначе с плаващи числа, така че запазването в 8-битова дълбочина няма да ни даде толкова икономия на ресурси, колкото е необходимо, на цената на загуба на точност.



Фиг. 3. Предварителна обработени изображенията

2.8. Подготовка на изображенията за използване в невронната мрежа.

Важно е да се отбележи, че като част от обучението на един и същ мрежов модел, обучителните и валидационните набори използват една и съща процедура, докато тестовият набор може да използва различна. На този етап от нашето проучване ние предварително обработваме обучителните и валидационните набори, както следва:

1) Първоначално променяме размера на изображението. В зависимост от размера на входния слой, трябва да предоставим подходящ размер за следващата стъпка. Например, ако обучаваме с resnet, входният слой е 224 на 224 на 3. В този момент имаме изображение с размер 400x400x1 и считаме, че за следващата стъпка е най-добре да имаме изображение с размер 300x300x1.

2) Изрежете изображението с произволен размер. Опитваме се да изрежем произволно от изображението с променен размер. Вземаме произволна точка от изображението и се опитваме да изрежем с тази пиксел като отправна точка. Изрезаното трябва да е с минимална дължина на страната, равна на размера на страната на входния слой (224 в случая на ResNet). Ако не успеем да изрежем в 10 опита, вземаме централното изрязано. Това се прави, тъй като нашето изискване е да не се допуска увеличаване на размера. – тъй като крайното входно изображение трябва да е със страничен размер 224, ако получим изрязване с по-малък страничен размер, очевидно по-късно ще се получи увеличаване на размера. Обяснявайки тази процедура, можем да обясним защо първоначалното преоразмеряване в нашия случай е 300x300. Ако изберем по-големи страни, е възможно да загубим значимите данни и да пропуснем аномалията в изрязването.

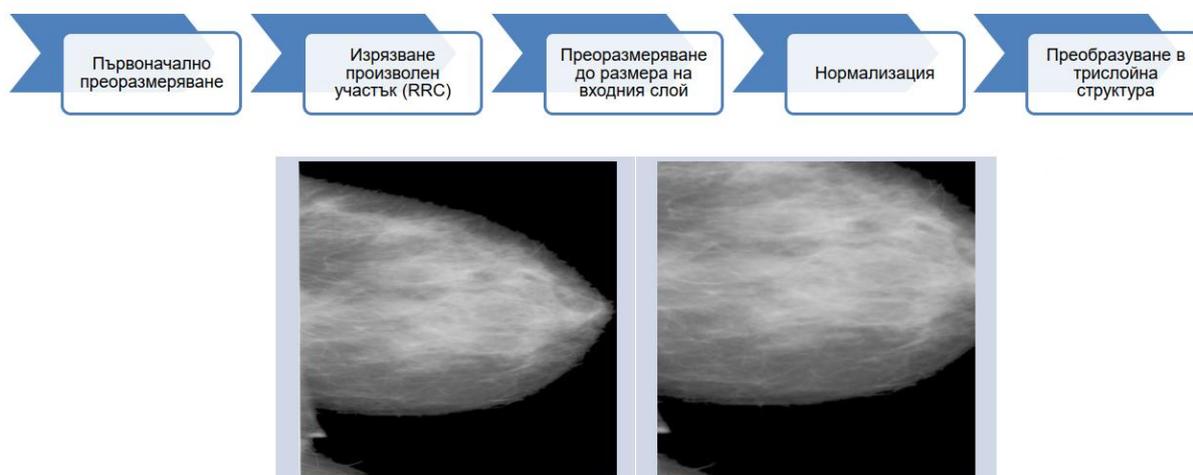
3) Преоразмеряваме изображението до размер на входния слой 224 на 224 за ResNet.

4) Ако използваме мрежов модел без нормализация, трябва да нормализираме изображенията сега. Както в MATLAB, моделът ResNet има параметър за

нормализация във входния слой, зададен на „zerocenter“, което означава, че там ще се извърши нормализация zerocenter и не е необходимо да се прави нормализация на данните като предварително условие.

5) Повтаряме изрязването 224 на 224 три пъти, като преобразуваме изображението в 3-слоино цветно изображение, както е необходимо за входа.

Описаният процес е ръчно предварително дефиниран като функция за четене (ReadFcn) на MATLAB imageDatastore обект, който ще се използва за обучението на мрежата.



Фиг. 4. Подготовка на изображенията за използване в невронната мрежа.

2.9. Аугментации по време на обучението на невронната мрежа.

Създадохме наборите от данни, използвани за обучение на мрежата, и сега е моментът да дефинираме техните разширения за всеки епох. Това са малки случайни промени в данните на изображенията, които помагат за изграждането на модел за прогнозиране, като по-точен и устойчив за различни типове входни изображения. Използваме следните опции за разширяване:

- "RandRotation" - Случайно завъртане
- „RandXScale“ – случайно преоразмеряване на x скалата
- "RandYScale" - Случайно преоразмеряване на y скалата
- "RandXTranslation" – Случайно преместване по ос x
- „RandYTranslation“ – Случайно преместване по ос y
- „RandXReflection“ – Случайно транспониране на x стойности

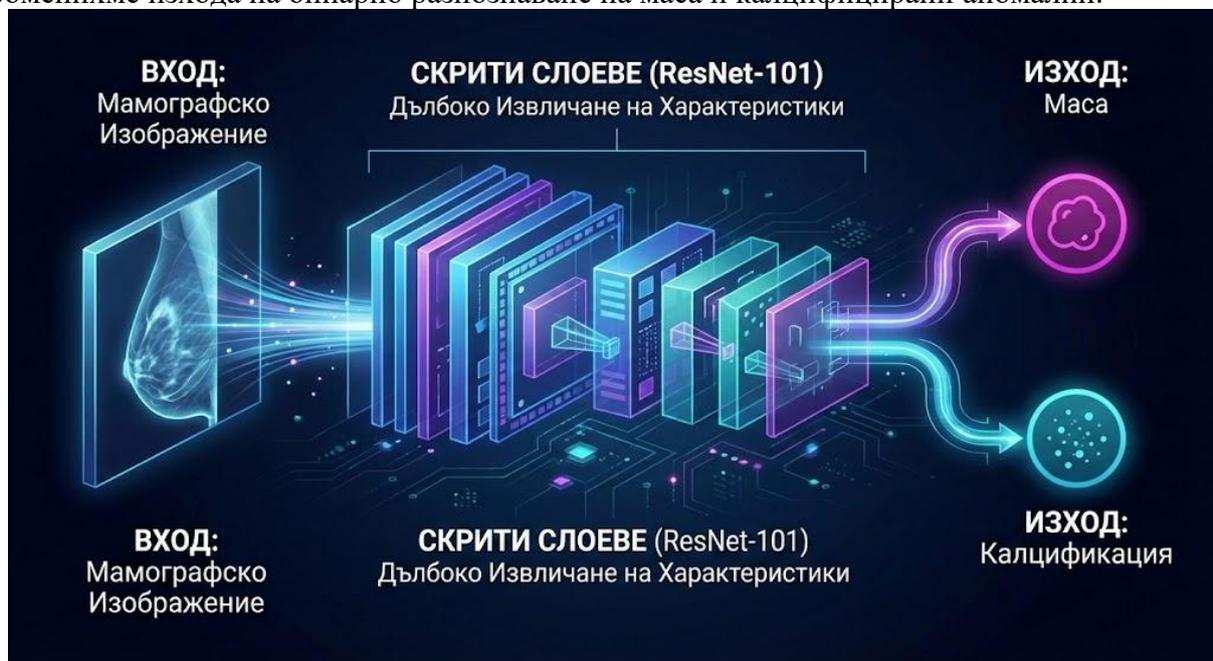
В MATLAB това се задава като обект за генериране на данни в мрежа



Фиг. 5. Аугментация на изображенията.

2.10. Избор на мрежов модел за трансферно обучение.

Следващата стъпка е да зададем конструкцията на мрежовия модел и връзките между слоевете. Както бе споменато по-рано, ние използвахме режим ResNet 101 с предварително обучените тегла и отклонения на ImageNet. Той има предварително дефинирани конструкции и връзки между слоевете и за нашите нужди променихме само изходните слоеве. Тъй като това е предварително обучен CNN модел за разпознаване на инстанции от няколко класа, ние променихме изхода на бинарно разпознаване на маса и калцифицирани аномалии.



Фиг. 6. Приложение на ResNet 101 за обучение на невронната мрежа,

2.11. Опции за обучение на невронната мрежа.

Последното нещо, необходимо за започване на обучението, е настройката на опциите за обучение. Вдъхновени от решението CBIS-DDSM, опитахме няколко комбинации. За да се постигне най-добрата производителност, е необходима фина настройка и като част от нашето проучване използвахме следното:

- Оптимизатор: adam (адаптивен импулс) се предпочита пред sgdм за медицински изображения.
- Размер на партидата: 16 или 32, по-малките партии се обобщават по-добре, но ще са необходими повече епохи.
- Начална скорост на обучение: $1e-4$ – ако е твърде висока, рискуваме да превишим целта, но ако е твърде ниска, страдаме от бавна конвергенция.
- LearnRateSchedule: piecewise – понижава скоростта на обучение, както е дефинирано.
- LearnRateDropFactor: 0,45 – умножава скоростта на обучение по тази стойност, когато условието е изпълнено.
- LearnRateDropPeriod: 5 – условие за понижаване на скоростта на обучение, или с други думи, на всеки 5 епохи скоростта на обучение се понижава, като се умножава по коефициента на понижение.
- MaxEpochs: 35 – обучението на модела спира след максимум 35 епохи или с други думи след проверка на резултатите от 6 понижения на скоростта на обучение. Минималната LR в края ще бъде 0,0000008303765625 (или приблизително $8e-7$).

Зададохме и някои други опции, като честотата на валидиране и резултатът при излизане да бъде опцията за най-добра валидираща загуба с търпение от 21 епохи (или неуспешни по-добри резултати, получени за 21 последователни епохи).

3. Резултати и обсъждане

Моделите, постигащи точност в диапазона 88% до 92%, се класифицират като показващи високи резултати. Тази категория обикновено обхваща подходи, базирани на техники като трансферно обучение (Transfer Learning) и аугментация на данни (Data Augmentation) – методологията, приложена и в настоящото изследване. За сравнение, отличните резултати, определяни като „съвременно ниво на развитие“ (State-of-the-Art), обикновено изискват нива на точност, надвишаващи 93-95%.

Рискове при интерпретацията на свръхвисока точност. Важно е да се отбележи, че докладвани резултати над 97-98% често са индикатор за преобучаване (overfitting) към конкретната база данни или се отнасят до класификация на предварително изрязани малки участъци (patches), а не на цялостни маммографски изображения. Използването на строго отделен валидационен набор е критичен метод за гарантиране на способността на модела да обобщава (generalization). Въпреки че този подход често води до понижаване на номиналната крайна точност в сравнение с чистото обучение, той осигурява много по-реалистична и надеждна оценка за реалната приложимост на модела.

За изготвянето на тази статия използвахме набор от данни, предоставен от Националния институт по здравеопазване, Националния институт по рака, наречен Curated Breast Imaging Subset of Digital Database for Screening Mammography (CBIS-DDSM) - Курирана подгрупа от цифрова база данни за скринингова маммография. Тя е с CC BY 3.0 лицензия и е достъпна на следния адрес: <https://www.cancerimagingarchive.net/collection/cbis-ddsm/>

4. Изводи

Ключова роля на предварителната обработка и запазването на дълбочината на данните

Експериментите потвърждават, че качествената подготовка на входните данни е критична за точността на диагностичния модел. Преобразуването на DICOM изображенията в 16-битов PNG формат, вместо в стандартния 8-битов JPG, позволява запазване на по-висока прецизност при последващата нормализация и изчисления с плаваща запетая в невронната мрежа. Допълнителното извличане на "Region of Interest" (ROI) и елиминирането на артефакти и надписи гарантира, че моделът се обучава единствено върху значимата гръдна тъкан.

Ефективност на трансферното обучение (Transfer Learning) в медицинската образна диагностика

Използването на предварително обучени архитектури, като ResNet-101, се доказва като успешна стратегия при анализ на специализирани медицински данни. Адаптирането на модел, обучен върху ImageNet, чрез модификация на изходните слоеве за бинарна класификация (маса/калцификация), позволява постигане на висока производителност без необходимост от огромни изчислителни ресурси и време за обучение от нулата.

Подобряване на генерализацията чрез персонализирано разделяне на данните

Отклоняването от стандартното разпределение на CBIS-DDSM и въвеждането на собствена схема за разделяне на данните (80% обучение, 10% валидиране, 10% тест) осигурява по-обективна оценка на модела по време на обучението. Добавянето на валидационен набор, който липсва в оригиналната дефиниция на базата данни, позволява по-прецизен контрол върху процеса на обучение (чрез проследяване на *Validation Loss*) и предотвратява преобучаването (overfitting) преди финалния тест.

Значение на хиперпараметрите и аугментацията за устойчивостта на модела

За преодоляване на ограниченията на медицинските набори от данни (като CBIS-DDSM) и избягване на преобучане (overfitting), от съществено значение е фината настройка на опциите за обучение. Използването на оптимизатор Adam, динамичен график на скоростта на обучение (piecewise schedule) и техники за аугментация на данните (случайни ротации, мащабиране и транскации) създава по-робастен модел, способен да разпознава патологии в различни вариации на изображенията.

Изкуственият интелект като инструмент за подпомагане, а не заместване

Разработеният модел демонстрира, че дълбокото обучение може успешно да автоматизира трудоемката задача по първоначална класификация на аномалии. Системата функционира като ефективен "втори чифт очи", подпомагайки радиолога в идентифицирането на микроскопични аномалии и намалявайки риска от грешки, породени от умора или сложност на анализа, като по този начин оптимизира клиничния път от данните до диагнозата.

Благодарност

Докладът се финансира Проект BG05SFPR001-3.004-0025-C01 „Докторантски училища за наука, иновации и зелена енергия в ИКТ“, финансиран от Оперативна програма „Образование“

Библиография

1. Lee RS, Gimenez F, Hoogi A, Miyake KK, Gorovoy M, Rubin DL. Curated Breast Imaging Subset of DDSM (CBIS-DDSM). The Cancer Imaging Archive. 2017.
2. Heath M, Bowyer K, Kopans D, Moore R, Kegelmeyer WP. The Digital Database for Screening Mammography. In: Yaffe MJ, editor. Proceedings of the 5th International Workshop on Digital Mammography. 2001. p. 212–218.
3. He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016. p. 770–778.
4. MATLAB. Version R2024a. Natick (MA): The MathWorks Inc.; 2024.
5. MathWorks. Deep Learning Toolbox User's Guide. Natick (MA): The MathWorks Inc.; 2024.
6. National Electrical Manufacturers Association. Digital Imaging and Communications in Medicine (DICOM) Standard. Rosslyn (VA): NEMA; 2023.
7. Krlev, K., Sotirov, S., Sotirova, E., Petrova-Geretto, E., & Petkov, D. (2024, July). Modular Convolutional Neural Network for Children Pneumonia Detection via X-ray Images. In International Conference on Intelligent and Fuzzy Systems (pp. 319-323). Cham: Springer Nature Switzerland.