

УДК 004.8

ВИКОРИСТАННЯ МАШИННОГО НАВЧАННЯ ДЛЯ ВИЯВЛЕННЯ ПУХЛИН МОЗКУ

Ейдлін Р.В., Колесник Л.В.

Харківський національний університет радіоелектроніки, Харків

Виявлення пухлин головного мозку є однією з найбільш важливих задач сучасної медицини. Своєчасна діагностика та точне визначення меж пухлин дозволяють розробити ефективніші методи лікування, підвищуючи шанси на одужання пацієнтів та збереження людських життів. Методи машинного навчання (МН) надають широкі можливості у аналізі медичних зображень, що включають знімки МРТ та КТ, та виділення ключових ознак, що сприяє підвищенню точності діагностики. Завдяки використанню автоматизованих алгоритмів можливо значно знизити вплив людського фактору та покращити якість аналізу зображень.

Розглянемо існуючі методи та оцінимо їх вплив на підвищення ефективності діагностики пухлин мозку.

1. Методи обробки та фільтрації зображень

Для процесу виявлення пухлин головного мозку суттєвим етапом є обробка медичних зображень, що включає використання методів фільтрації. Мета фільтрації полягає у зменшенні шуму та покращенні якості вихідних зображень для виділення важливих структур. Використовуючи фільтри є можливим видалення небажаних перешкод, що дозволяє зробити зображення більш придатним для подальшого аналізу [1]. До основних методів фільтрації належать гаусовий фільтр, медіанний фільтр, біквадратний фільтр та перетворення Вейвлета.

Гаусовий фільтр використовується для згладжування зображень і усунення гаусового шуму. Він зберігає основні структури, що є важливими для ідентифікації контурів пухлин. Медіанний фільтр ефективний для видалення імпульсного шуму і збереження деталей, таких як краї та межі

утворень. Біквдратний фільтр забезпечує підвищення контрастності, що робить контури пухлин більш чіткими, а перетворення Вейвлета дозволяє зберігати деталі при багатомасштабному згладжуванні.

Методи фільтрації не лише покращують видимість важливих деталей, але й створюють основу для сегментації зображень, що дозволяє більш точно виділити контури пухлин.

2. Методи порогової обробки

Одним з найбільш простих і ефективних методів для виділення об'єктів на зображенні є порогова обробка. Даний підхід дозволяє розділяти об'єкти на зображеннях, виділяючи області за рівнем інтенсивності пікселів [2].

Серед найпоширеніших методів порогової обробки виділяють глобальну порогову обробку, адаптивну порогову обробку та метод Оцу. Глобальна порогова обробка використовує фіксований поріг для всього зображення, що підходить для зображень з рівномірним освітленням. На відміну від глобальної обробки, адаптивна порогова обробка застосовує різні пороги в різних частинах зображення, що дозволяє працювати з зображеннями, де освітлення варіюється. Метод Оцу є автоматичним методом, що обирає оптимальний поріг для поділу зображення на дві області, мінімізуючи внутрішньокласову дисперсію інтенсивностей.

3. Аналіз текстур

Аналіз текстур допомагає виділяти особливості тканин, які можуть вказувати на наявність пухлин. Текстурні характеристики зображення можуть розкривати деталі, що не завжди помітні при простій візуальній оцінці.

Поміж основних методів аналізу текстур використовують матрицю співвідношень сірості (GLCM), локальні бінарні шаблони (LBP) та перетворення Вейвлета [3-4].

Матриця співвідношень сірості дозволяє оцінювати різноманітні властивості текстури, такі як контрастність, однорідність та енергія. Локальні бінарні шаблони є ефективними для кодування локальних текстурних

характеристик і добре працюють на зображеннях з нерівномірним освітленням. Перетворення Вейвлета забезпечує багатомасштабний аналіз текстури, що дозволяє виявити деталі на різних рівнях.

4. Методи глибокого навчання

У діагностиці пухлин головного мозку використовують різні алгоритми машинного навчання, включаючи згорткові нейронні мережі (CNN), методи трансферного навчання, генеративні змагальні мережі (GAN) та автоенкодери [5].

Згорткові нейронні мережі дозволяють автоматично виокремлювати важливі ознаки та, завдяки здатності виявляти патерни на різних рівнях зображення, демонструють високу ефективність у класифікації медичних зображень. Згорткові шари CNN виділяють локальні особливості, тоді як шари пулінгу знижують розмірність даних, що зменшує обчислювальну складність та покращує продуктивність моделі.

Методи трансферного навчання дозволяють використовувати попередньо натреновані на великих наборах даних моделі і адаптувати їх до специфічних завдань діагностики пухлин. Це, у свою чергу, значно скорочує час і ресурси, необхідні для навчання моделей.

GAN використовуються для генерації синтетичних даних, що допомагає збільшити обсяг тренувальних вибірок і покращити результати сегментації.

5. Алгоритми машинного навчання

Серед алгоритмів машинного навчання, що підходять для задачі аналізу медичних зображень, виділяються: метод Бройдена-Флетчера-Голдфарба-Шанно (BFGS), стохастична дуальна координатна оптимізація (SDCA) та найвний баєсівський класифікатор (NBC). Кожен із цих алгоритмів має специфічні властивості, які роблять його ефективним для певних типів задач.

Метод BFGS відноситься до класу квазі-Ньютонових методів, які використовують інверсію матриці Гессе для оптимізації. Це дозволяє використовувати даний метод для задач з нелінійними залежностями, що є важливим для точного виділення меж пухлини. Алгоритм особливо корисний

у випадках, коли обчислення другої похідної є обчислювально затратним або неможливим. Також BFGS має низьку схильність до перенавчання завдяки ентропійному обмеженню, що робить його цінним інструментом у діагностиці на основі зображень, оскільки медичні дані часто мають високу неоднорідність. Недоліки методу включають залежність від початкових умов і потребу у великій кількості ітерацій для складних задач. Ці фактори можуть ускладнити застосування BFGS для великих масивів даних, однак сучасні обчислювальні платформи дозволяють вирішити ці обмеження.

Метод SDCA використовує стохастичний підхід для оптимізації, що дозволяє обробляти великі обсяги даних за рахунок оновлення параметрів лише для частини об'єктів. Даний метод є особливо ефективним для задач, де необхідно швидко знаходити оптимальні параметри, як-от для обробки масивних баз медичних зображень. SDCA часто застосовується для лінійних моделей і задач класифікації, але обмежений у застосуванні до задач із нелінійними залежностями. Серед обмежень варто відзначити залежність результатів від параметрів навчання та обмежену здатність обробляти нелінійні залежності, що є недоліком при аналізі складних медичних даних.

Наївний байєвський класифікатор є простим та ефективним методом для класифікації, який заснований на теоремі Баєса. Алгоритм припускає незалежність ознак, що значно спрощує обчислення. Хоча це припущення не завжди реалістичне для складних медичних даних, NBC добре працює у задачах класифікації, де необхідно обробити великі обсяги інформації. Основними недоліками є обмежена здатність до обробки нелінійних залежностей і чутливість до неточних апріорних ймовірностей.

Наведена нижче таблиця порівняння алгоритмів показує, що кожен метод має свої сильні та слабкі сторони. Метод BFGS забезпечує високу точність та ефективність для нелінійних моделей, але вимагає більше обчислювальних ресурсів, коли SDCA навпаки добре підходить для лінійних моделей і великих наборів даних, забезпечуючи високу швидкість обчислення. NBC відзначається простотою і швидкістю, проте припущення

про незалежність ознак обмежує його застосовність для складних залежностей у медичних даних.

Таблиця 1 – Порівняння алгоритмів машинного навчання

Алгоритм	Швидкість	Ефективність для великих даних	Стійкість до перенавчання	Обробка нелінійних залежностей
<i>BFGS</i>	Середня	Обмежена	Висока	Так
<i>SDCA</i>	Висока	Висока	Залежить від параметрів	Ні
<i>NBS</i>	Висока	Висока	Обмежена	Ні

Підсумовуючи, можна зазначити, що машинне навчання є потужним інструментом для виявлення пухлин мозку, забезпечуючи точність і ефективність діагностики. Використання сучасних методів обробки зображень та алгоритмів дозволяє підвищити якість діагностичних систем, що сприяє кращому плануванню лікування та збереженню здоров'я пацієнтів.

Література:

1. О. А. Кобилін, та І. В. Творошенко, Методи цифрової обробки зображень: навч. посібник. Харків: ХНУРЕ, 2021.
2. S. Prasanna, S. Soltani, and A. Wong, «A survey of thresholding techniques», Computer Vision Graphics and Image processing, No 41(2), p. 233-260, 1988. DOI:10.1016/0734-189X(88)90022-9.
3. Hall-Beyer M. GLCM texture: a tutorial. Calgary: National Council on Geographic Information and Analysis Remote Sensing Core Curriculum, 2000. DOI: 10.13140/RG.2.2.12424.21767.
4. L. Nanni; A. Lumini; S. Brahmam, «Survey on LBP based texture descriptors for image classification», Expert Systems with Applications, No. 39, p. 3634-3641 2012. DOI:10.1016/j.eswa.2011.09.054.
5. О. О. Дудник, О. Н. Романюк, «Аналіз методів фільтрації текстур», 2015.