

<https://doi.org/10.31891/2219-9365-2024-79-9>

УДК 004.83

МЕЩЕРЯКОВ Олександр

Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського»

<https://orcid.org/0009-0002-6485-9722>

e-mail: [ascellanova@gmail.com](mailto:ascellanova@gmail.com)

## ОГЛЯД МЕТОДІВ ТА ЗАСОБІВ ПІДВИЩЕННЯ ЕФЕКТИВНОСТІ МОДЕЛЕЙ КЛАСИФІКАЦІЇ МЕДИЧНИХ ЗОБРАЖЕНЬ

У статті представлені методи та засоби для покращення ефективності моделей класифікації медичних зображень. Проаналізовано різні підходи до вдосконалення точності та надійності класифікації, зокрема використання нейронних мереж, методів злиття та застосування кумулятивного ефекту від згладжування та покращення зображень на наборах даних, які використовуються для аналізу COVID-19. Розглянуто способи боротьби з аномаліями які виникають при використанні двовимірного гель-електрофорезу (2-DGE) за допомогою системи попередньої обробки. Запропоновані методи можуть бути використані для медичної діагностики, дозволяючи покращити точність та швидкість обробки медичних зображень, що в свою чергу сприяє підвищенню якості медичних послуг та скороченню часу на постановку діагнозу. Представлена в статті інформація має оглядовий характер.

Ключові слова: аналіз даних, машинне навчання, медичні дані, нейронна мережа, класифікація.

MESHCHERIAKOV Oleksandr

National Technical University of Ukraine "Ihor Sikorskyi Kyiv Polytechnic Institute"

## REVIEW OF METHODS AND TOOLS FOR IMPROVING THE EFFICIENCY OF MEDICAL IMAGE CLASSIFICATION MODELS

The article presents methods and tools for improving the efficiency of medical image classification models. It considers various approaches to enhancing classification accuracy and reliability, including the use of deep neural networks, fusion methods and the application of the cumulative effect of image smoothing and enhancement techniques on the datasets used for COVID-19 analysis. The datasets consist of four sets of categorised data, including COVID-19, pneumonia, viral pneumonia and bacterial pneumonia. Different combinations of CLAHE, gamma correction, HE, AMF, TVF, Gaussian and Median filtering methods are used to analyse the cumulative effect to determine the most effective combination of methods. 2-DGE images typically contain several anomalies that hinder spot detection and analysis. The article discusses methods for dealing with anomalies arising from the use of two-dimensional gel electrophoresis (2-DGE) using a pre-processing system consisting of three stages, normalization, noise reduction and background correction, are considered, which allowed to improve the image for a posteriori analysis. The fusion methods such as Uniform Voting, Distribution Summation, Dempster-Shafer, Entropy Weighting, Density-Based Weighting are analysed and compared with the newly developed BitClassification Fusion Model method on 15 benchmark data selected from the UEA and UCR time series classification repository. The proposed methods can be used for medical diagnostics, allowing to improve the accuracy and speed of medical image processing, which in turn contributes to improving the quality of medical services and reducing the time to diagnosis. Presented in the article information is an overview.

Keywords: data analyze, machine learning, medical data, neural network, classification

### ПОСТАНОВКА ПРОБЛЕМИ У ЗАГАЛЬНОМУ ВИГЛЯДІ ТА ЇЇ ЗВ'ЯЗОК ІЗ ВАЖЛИВИМИ НАУКОВИМИ ЧИ ПРАКТИЧНИМИ ЗАВДАННЯМИ

Використання методів машинного навчання, зокрема глибокого навчання, для класифікації медичних зображень має значний вплив на сучасну медицину в питанні діагностики. Необхідність підвищення ефективності моделей класифікації медичних зображень є важливою, оскільки це дозволяє покращити діагностичні можливості та зменшити кількість помилкових діагнозів. Вдосконалення алгоритмів і засобів, що використовуються для аналізу медичних зображень, може значно поліпшити якість медичної допомоги.

Класифікація медичних зображень стикається з багатьма викликами, включаючи варіативність зображень, невеликий розмір вибірок даних, аномалії на медичних зображеннях, шум у зображеннях та необхідність високої точності. Існуючі методи не завжди можуть забезпечити необхідний рівень точності або швидкості обробки, що може призвести до помилкових діагнозів. Потрібно розглянути методи та засоби підвищення ефективності класифікації медичних зображень, зокрема за допомогою використання новітніх алгоритмів обробки зображень.

### АНАЛІЗ ОСТАННІХ ДОСЛІДЖЕНЬ І ПУБЛІКАЦІЙ

Сучасні дослідження в області класифікації медичних зображень використовують різноманітні підходи для підвищення ефективності моделей. Важливу роль відіграє попередня обробка зображень, яка включає нормалізацію, фільтрацію шуму та сегментацію зображень. В межах статті [22] реалізовано та досліджено створений алгоритм бітового злиття який застосовується до навченого класифікатора та порівняно з іншими методами злиття на 15 еталонних даних, вибраних з репозиторію класифікації часових

рядів UEA та UCR. Середня точність запропонованої моделі у відсотках є кращою, за інші методи на всіх 15 наборах даних. У статті [26] розглядається застосування накопичувального ефекту від згладжування та покращення зображень на наборах даних, які використовуються для аналізу COVID-19, що складається з 4 наборів поділених по категоріям, які включають COVID-19, пневмонія, вірусна пневмонія та бактеріальна пневмонія. Для аналізу накопичувального ефекту використовуються різні комбінації методів CLANE, гамма-корекція, HE, AMF, TVF, Gaussian та Median методи фільтрування для визначення найбільш ефективної комбінації методів. Автори статті [27] застосовують методи попередньої обробки для боротьби з аномаліями пов'язаними з процесом отримання аналізу вони виникають у вигляді дифузні плями, плями, що перекриваються, та фоновий шум при протеомному аналізі. Автор порівнює методи зниження шуму на зображеннях таких як Вейвлет-перетворення та геометричною нелінійною дифузійною фільтрацією на різних типах шуму та різною інтенсивністю шуму від 20 децибел до 8 децибел. Також нормалізацію зображень та методи корекції фону такі як порогову, багаторівневу порогову та порогову апроксимацію. На основі порівняння методів нормалізації зображень, зменшення шуму та корекції фону автор реалізує фреймворк попередньої обробки та перевіряє його з використанням реальних двовимірних гелелектрофорез зображень і у результаті кількість хибно позитивних спрацьовувань зменшилася від 71% до 93%.

### **ВИДІЛЕННЯ НЕВИРШЕНИХ РАНІШЕ ЧАСТИН ЗАГАЛЬНОЇ ПРОБЛЕМИ**

Ознайомившись з актуальними дослідженнями було знайдено невіршені питання, зокрема, ефективність моделей на малих вибірках даних. Також не достатньо досліджено вплив використання гібридних методів, які поєднують різні підходи, такі як традиційні методи обробки зображень та глибоке навчання. Ще однією проблемою є розробка методів, які б забезпечували високу точність і стабільність моделей на різноманітних медичних даних.

### **ФОРМУВАННЯ ЦІЛЕЙ СТАТТІ**

Метою статті є огляд методів та інструментів, спрямованих на підвищення ефективності моделей класифікації медичних зображень з метою поліпшення процесу діагностики. Зокрема, дослідження спрямоване на пошук найбільш ефективних технік обробки даних, а також гібридних методів, що поєднують переваги різних підходів. Це дозволить підвищити точність і швидкість класифікації медичних зображень, що, в свою чергу, сприятиме поліпшенню якості медичної діагностики.

### **ВИКЛАД ОСНОВНОГО МАТЕРІАЛУ**

Впровадження передових методів збору даних та методів машинного навчання змінює підхід до медичної інформації. У цій статті розглядаються різні типи медичних даних а також обговорюються методології, що використовуються для покращення їх обробки. Підкреслюючи ключову роль машинного навчання, ми заглиблюємося в алгоритми і моделі, які аналізують величезні масиви даних для виявлення закономірностей, прогнозування результатів і персоналізації лікування. Вивчаючи конкретні приклади та сучасні дослідження, ми підкреслюємо глибокий вплив цих технологій на підвищення точності діагностики. Ця стаття має на меті надати огляд найбільш ефективних методів обробки даних та методів класифікації для підвищення точності машинного навчання.

З поширенням електронних медичних карток, персональних медичних пристроїв, та мобільних медичних додатків обсяг і різноманітність медичних даних, доступних на сьогодні, досягли безпрецедентного рівня. Цей стрімкий ріст даних постає як значний виклик. Проблема полягає у тому, як ефективно збирати, керувати та аналізувати цю інформацію з метою отримання релевантних висновків, для подальшого використання у діагностиці.

В основі цього виклику лежить інтеграція найефективніших методів для збору даних і технологій машинного навчання. Машинне навчання продемонструвало неабиякі можливості в обробці величезних обсягів даних для виявлення закономірностей, прогнозування майбутніх тенденцій і отримання дієвих висновків. У застосуванні до медичних даних ці методи можуть докорінно змінити наше розуміння хвороб, розробку методів лікування та надання персоналізованої медичної допомоги.

Джерела медичних великих даних, такі як записи адміністративних звернень, клінічні реєстри, електронні медичні картки, біометричні дані, інформація отримана від пацієнтів, медична візуалізація, дані біомаркерів та великі клінічні випробування.[2] Інтеграція цих джерел даних призводить до появи додаткових вимірів даних, таких як великий розмір, розрізненість джерел, різні масштаби (від секунд до років), невідповідності, неповнота і складність[1]. Не існує універсального протоколу для моделювання, порівняння або оцінки ефективності різних стратегій аналізу даних.

Необроблені медичні дані є об'ємними і неоднорідними. Медичні дані можуть бути зібрані з різних зображень, інтерв'ю з пацієнтом, лабораторних даних, а також спостережень та персональної інтерпретації лікаря.[5] Всі ці компоненти можуть вплинути на діагноз, прогноз і лікування пацієнта, і їх не можна ігнорувати. Основні сфери неоднорідності медичних даних можна згрупувати під такими заголовками:

**1.Обсяг і складність медичних даних:** Обсяг медичних даних є значним і охоплює різноманітні типи інформації: від медичних зображень і результатів лабораторних досліджень до історій хвороб і даних моніторингу в режимі реального часу. Ця складність підвищується необхідністю інтегрувати різні типи даних, які часто зберігаються в не пов'язаних одна з одною системах, щоб створити цілісне уявлення про стан здоров'я пацієнта. Передові інструменти управління даними та аналітики необхідні для вирішення цієї задачі та отримання релевантних висновків[5].

**2.Інтерпретація лікаря:** Відмінності у інтерпретації медичних даних лікарями вносить додатковий рівень варіативності. Набутий досвід, знання та суб'єктивні судження кожного лікаря можуть впливати на те, як дані розуміються і застосовуються в лікуванні пацієнтів. Ця варіативність може впливати на діагностичні рішення, плани лікування та результати лікування пацієнтів[5]. Послідовне навчання, системи підтримки прийняття рішень і стандартизовані протоколи можуть допомогти пом'якшити ці відмінності, але не можуть усунути їх повністю.

**3.Чутливість і специфічність:** Чутливість і специфічність є ключовими показниками в медичній діагностиці, що відображають точність тестів у виявленні хибно позитивних і хибно негативних результатів відповідно. Висока чутливість гарантує, що більшість пацієнтів з певним захворюванням будуть правильно ідентифіковані, в той час як висока специфічність гарантує, що більшість здорових людей не будуть помилково діагностовано як хворих [5]. Баланс цих показників має вирішальне значення, оскільки надто чутливі тести можуть призвести до хибно позитивних результатів і непотрібного лікування, тоді як надто специфічні тести можуть пропустити справжні випадки захворювання.

З клінічним текстом або записами в електронних картках пацієнтів є специфічні проблеми оскільки вони написані спеціалізованою мовою. Такі записи часто написані у телеграфному стилі, з великою кількістю інформації, для спілкування між лікарями, і не існує розроблених словників, які можна було б використовувати для перевірки орфографії чи граматики. Крім того, лікарі іноді використовують неповні речення, а також часто не згадують про такий об'єкт, як пацієнт, оскільки пацієнт вважається очевидним у тексті. Пацієнт може бути написаний або просто згаданий як «прибув з температурою 38,3 і пульсом 132» [3].

Термін «неструктуровані дані» зазвичай використовується в клінічних умовах для позначення вільного тексту, проте він також охоплює кілька інших типів даних, таких як медичні зображення. Останні охоплюють широкий спектр категорій, від статичних зображень, отриманих за допомогою діагностичних інструментів (наприклад, рентгенографії), до відеозаписів, що фіксують хід медичних процедур, таких як хірургічні втручання.

На початковому етапі медична візуалізація переважно використовувалася для термінового використання, для підтримки процесу пов'язаного з конкретною діагностичною або терапевтичною процедурою для окремого пацієнта. Таким чином, вторинне використання зображень для досліджень не розглядалося. Як наслідок, медичні зображення та відео з ходом процедури після їх первинного використання видалялися. Сьогодні продукти медичної візуалізації відіграють ширшу роль, будучи джерелом даних для клінічних досліджень, а також інструментом для підтримки догляду за пацієнтом. В результаті, клінічні зображення і відео систематично зберігаються в електронних медичних картах разом з відповідними клінічними звітами, що містять оцінки лікарів щодо інтерпретування медичних зображень [7].

Аналіз даних проводиться як на медичних зображеннях, так і на текстах клінічних звітах. Аналіз клінічних звітів відноситься до області клінічного інтелектуального аналізу текстів. Що стосується медичних зображень, їх аналіз може виконуватися з різними цілями. Деякі методи спрямовані на покращення візуальної якості зображень, щоб полегшити їх інтерпретацію людиною-спостерігачем[10]. Наприклад, вони можуть бути використані для зменшення шуму зображень. Інші підходи допомагають у прийнятті рішень щодо пацієнта. За останні кілька років були розроблені методи глибокого навчання для аналізу зображень в декількох клінічних контекстах. Наприклад, в ендоскопії такі методи автоматично виявляють та класифікують ураження[8,9]. У дерматології поширеною темою досліджень є автоматична класифікація уражень шкіри за ступенем злоякісності, а в неврології дослідження присвячені автоматичній класифікації захворювань головного мозку.

Клінічні діагностичні критерії, що використовуються для діагностики та лікування, засновані на суб'єктивному досвіді, а не на об'єктивних біомаркерах захворювань. Ці критерії, розроблені експертами, інтегровані в посібники діагностики. Однак, такий підхід має ряд обмежень. Поставлений діагноз може варіюватися в залежності від методології опитування [18], і клінічно схожі симптоми можуть бути викликані різними основними патологіями. Відтак, універсальні діагностичні критерії, що базуються лише на проявах симптомів, не завжди надійні в клінічному застосуванні. Часто вони є нестабільними в часі, неспецифічними та малоінформативними для визначення оптимальної терапії[10]. Неправильні діагнози та класифікація можуть призводити до неефективної терапії та неадекватного ведення захворювання.

Інтеграція підходів глибокого навчання в комп'ютерних системах діагностики (CAD) сприяє підвищенню точності діагностики захворювань на ранніх стадіях. Важливим етапом після отримання зразків є попередня обробка зображень, яка зменшує час навчання алгоритму, а також знижує ймовірність хибних

результатів. Для покращення зображень найбільш ефективні такі методи, як вирівнювання гістограми, CLAHE та гамма-корекція, а також адаптивний медіанний фільтр (AMF), медіанний фільтр (MF), загальний варіаційний фільтр (TVF) та гауссові фільтри згладжування.

У дослідженні Шарма та інших [26] проаналізовано кумулятивний ефект від застосування методів згладжування та покращення зображень на наборах даних, які використовуються для вивчення COVID-19. Для початкового етапу авторами було обрано модель – DenseNet201. Цю модель навчали та тестували на наборі даних COVIDx, який включає зображення чотирьох категорій: COVID-19, звичайна пневмонія, вірусна пневмонія та бактеріальна пневмонія.

Враховуючи на значний обсяг набору даних та складність їх подальшої обробки, початкові тести проводилися на підмножині набору даних COVIDx. Ця підмножина включала 193 випадків COVID-19, 213 випадків пневмонії, 116 випадків вірусної пневмонії та 116 випадків бактеріальної пневмонії. Це дозволило отримати початкові результати щодо того, які покращення можуть бути досягнуті за допомогою обраної моделі та методів обробки зображень.

На Рис. 1 представлено графік залежності точності тестування від кількості епох у вигляді кривої. Графік відображає результати отримані для різних комбінацій методів покращення зображень: модель навчена на оригінальних зображеннях, вирівнювання гістограми, CLAHE, гамма-корекція, HE + гамма, CLAHE + гамма, AMF + гамма, TVF + гамма, TVF + гауссова + гамма, TVF + медіана + гамма, TVF + CLAHE + гамма і TVF + HE + гамма.

Протягом початкового тестування на підмножині набору даних автори отримали точність для методу гамма-корекції досягла 94,21%. Точність для комбінації TVF + гамма виявилася найефективнішою та складала 95,04%. Це значно перевищувало точність моделі, навченої на оригінальних зображеннях. Усі експерименти проводилися з використання однакових параметрів: швидкості навчання  $10^{-5}$ , розмір вибірки 32, оптимізатор Adam і функція втрат у вигляді зваженої перехресної ентропії [26].




Рис. 1. Послідовність перевірених комбінацій покращення та затушовування зображень для пошуку найкращого методу покращення [26]

Відповідно до отриманих результатів у дослідженні, у верхній частині графіку деяких моделей спостерігається найвищі значення точності та чутливості до COVID-19, що вказує на переваги цих комбінацій покращення зображень у порівнянні з іншими. Застосувавши ці комбінації до повного набору даних COVIDx призводить до значного покращення в порівнянні з використанням плоских зображень. Гамма-корекція, TVF + гамма та CLAHE показали найбільше підвищення чутливості у порівнянні з іншими методами покращення.

Знебарвлення зображень за допомогою TVF перед гамма-корекцією швидше досягає оптимальних результатів у порівнянні з CLAHE і HE. Гамма-корекція демонструє найкращі результати, оскільки вона підвищує точність для всіх класів, а застосування повного варіаційного зашумлення перед гамма-корекцією покращує продуктивність і скорочує час збіжності на еталонних наборах даних. Крім того, гамма-корекція є однаково ефективною для всіх класів.

У дослідженні Мауріціо та інших [27] двовимірний гель-електрофорез (2-DGE) - це ключовий метод для протеомного аналізу, що дозволяє ефективно розділяти білки за їх ізоелектричною точкою та молекулярною масою. Зображення 2-DGE часто містять аномалії, пов'язані з процесом отримання аналізу, такі як: дифузійні плями, перекриваючі плями, та фоновий шум.

У цьому дослідженні авторами пропонується спільна система попередньої обробки, яка поєднує можливості нелінійної фільтрації, корекції фону та методів нормалізації зображень для попередньої обробки 2-DGE зображень. Нормалізація зображень використовується для забезпечення однорідності даних, шляхом регулювання діапазону значень зображень на вході відповідно до цільових зображень.[28] Основним компонентом цієї системи є - спільна нелінійна дифузійна фільтрація, адаптивне кусково-гістограмне вирівнювання та багаторівнева порогова корекція. Ефективність методів оцінювалася як на синтетичних, так і на реальних 2-DGE-зображеннях.[27]

Основною метою нормалізації зображень є підсилення низькопоширених білків тому автори для її тестування використали синтетичне зображення з такими плямами (рис. 1а). Синтетичне зображення розміром 1024 x 1024 пікселів, з непрозорим фоном і 150 плямами, які були згенеровані відповідно до гаусівського розподілу зі стандартним відхиленням між 0,3 і 0,8. Інтенсивність плям контролювалася для відтворення низькопоширених білків з рівнем між 0,1 і 0,8. Автори здійснили порівняння методів вирівнювання гістограми, адаптивного кусково-гістограмне вирівнювання [30] та модифікацію інтенсивності фонових пікселів для нормалізації зображення, і використовували відсоток виявлених низькопоширених білків (LPD) для оцінки ефективності кожного методу.

За результатами LPD що отримали автори у ході дослідження – метод, який базується на інтенсивності фонового пікселя, виявив лише 48,7% плям з низькою щільністю. З іншого боку, гістограма та адаптивне вирівнювання за кусково-гістограмним методом виявили 82,1% та 88,9% плям відповідно. Як видно з рис. 1б і в, методи, засновані на вирівнюванні, покращують контрастність плям з низькою щільністю.




Рис. 1 Синтетичні білкові плями, змодельовані у вигляді 2-вимірного гаусівського розподілу. а - Приклад синтетичного зображення. б - Синтетичне зображення, нормалізоване за допомогою гістограмного вирівнювання. с - Синтетичне зображення, нормалізоване за допомогою адаптивного кусково-гістограмного вирівнювання і d - Синтетичне зображення, нормалізоване за допомогою модифікації інтенсивності фонового пікселя. [27]

Розглянемо порівняння методів корекції фону. У дослідженні було проведено порівняння трьох методів корекції фону: порогову, багаторівневу порогову та апроксимацію поверхню. Для оцінки цих методів було згенеровано синтетичне зображення зі зміною інтенсивності фону (див. рис. 2а). Варіації фону були отримані шляхом збільшення початкової інтенсивності до 155%. Для обох методів порогового значення було на рівні 60%. Рівняння В-сплайна [27] було використано для методів апроксимації поверхні з оптимізацією параметрів шляхом 150 ітерацій. Оцінка ефективності проводилася за допомогою індексу віднімання (SI), який порівнює кількість пікселів фону з їх оціненою кількістю.




Рис. 2 Синтетичні білкові плями, змодельовані у вигляді 2-вимірного гаусівського розподілу з фоном.  
а. Приклад синтетичного зображення. б. Синтетичне зображення з корекцією фону за допомогою порогової апроксимації. с. Синтетичне зображення з корекцією фону за допомогою багаторівневої порогової апроксимації. д. Синтетичне зображення з корекцією фону за допомогою поверхневої апроксимації. [27]

Метод порогової корекції частково усунув фон, як видно з рис. 2б, фон розділено на дві різні області. У порівнянні, багаторівневе порогоування забезпечило рівномірний фон. Наближення до поверхні видалило більшу частину фону, але цей метод не зміг видалити пік селі що розтошовані близько до плям. За допомогою порогової апроксимації було виявлено 71,8% пікселів фону, тоді як за допомогою поверхневої апроксимації та багаторівневої порогової апроксимації було виявлено 97,9% та 98,5% пікселів фону для синтетичних зображень відповідно.

У статті авторами проведено аналіз методів зменшення шуму. Вейвлет-перетворення (WT) яке є одним з нелінійних фільтрів, який показує найкращі результати у зменшенні шуму на 2-DGE зображеннях [29]. Також існують інші не менш ефективні нелінійні методи, які дозволяють зменшити шум без згладжування країв плям. Автори порівняли WT з геометричною нелінійною дифузійною фільтрацією - GNDF. GNDF демонструє хороші результати на різних типах медичних зображень, але не застосовувався для 2-DGE зображень. Для фільтра WT було використано сімейство вейвлетів Даубекіса з п'ятьма рівнями декомпозиції [29]. Для GNDF було використано 35 ітерацій згладжування з коефіцієнтом дифузії 0,2 і вікнами 5x5 пікселів. Ефективність оцінювалася за точковою ефективністю [4]. WT і GNDF тестувалися з

синтезованими зображеннями з гауссівським, релеївським і експоненціальним шумом з SNR від 20 до 8 децибел. Кожне синтетичне зображення має 512x512 пікселів і містить 250 плям.

У таблиці 1 ілюструє порівняння точкової ефективності фільтрів WT і GNDF для синтетичних зображень з різними рівнями шуму. Загалом точкова ефективність обох фільтрів була дуже подібною для більшості рівнів шуму, з різницею в межах 2%. Однак для синтетичного зображення з гауссівським шумом на рівні 8 децибел GNDF показав точкову ефективність 77,86%, тоді як забезпечив ефективність на рівні WT – 67,5%.

Таблиця 1

**Оцінка ефективність методів зниження шуму за допомогою точкової ефективності (%) [27]**

| Тип шуму    | Метод зниження шуму | Інтенсивність шуму (dB) |       |       |       |       |       |       |
|-------------|---------------------|-------------------------|-------|-------|-------|-------|-------|-------|
|             |                     | 20                      | 18    | 16    | 14    | 12    | 10    | 8     |
| Gaussian    | WT                  | 90.36                   | 90.71 | 89.29 | 89.29 | 88.93 | 85.00 | 67.50 |
|             | GNDF                | 88.57                   | 88.21 | 89.64 | 88.57 | 84.29 | 85.36 | 77.86 |
| Rayleigh    | WT                  | 90.00                   | 90.36 | 90.71 | 89.64 | 89.29 | 87.14 | 90.00 |
|             | GNDF                | 90.71                   | 88.93 | 89.29 | 87.86 | 88.21 | 86.43 | 87.14 |
| Exponential | WT                  | 91.07                   | 91.43 | 90.71 | 90.36 | 89.29 | 84.29 | 82.86 |
|             | GNDF                | 90.71                   | 89.64 | 89.29 | 90.71 | 88.57 | 87.86 | 82.87 |

На основі аналізу методів нормалізації зображень, зменшення шуму та корекції фону автори вказують на необхідність застосування комплексного фреймворку попередньої обробки. Запропонований фреймворк включає нормалізації зображень для підвищення контрастності низькопоширених білків, нелінійної фільтрації для зменшення шуму зі збереженням крайової інформації та корекції фону для забезпечення однорідності фонових пікселів. Згідно з попередніми результатами, ми використали кусково-гістограмне вирівнювання для нормалізації зображення, GNDF для фільтрації та багаторівневе порогове вирівнювання для корекції фону. Спільну систему попередньої обробки автори оцінювали, використовуючи як синтетичні, так і реальні 2-DGE зображення.

Оцінка інтегрованої системи попередньої обробки проводилася на синтетичному зображенні, створеному з використанням двовимірного гауссового розподілу, що містить 150 плям зі стандартним відхиленням від 0,1 до 0,8. Зображення характеризується варіацією інтенсивності фону вздовж горизонталі та містить гаусівський шум з медіаною нуль, стандартним відхиленням 1,535 і релеївським шумом з  $a = 0$  і  $b = 0,0539$ . У табл. 2 наведено результати продуктивності з використанням відсотку виявлення низькопоширених білків (LPD), точкової ефективності та індексом віднімання (SI), що порівнює кількість пік селів фону з розрахунковим значенням. Метрику SI обчислювали лише для зображень, отриманих за допомогою методів корекції фону та спільної попередньої обробки, оскільки вона вимірює фон, віднятий від зображення.

Найкращий показник LPD було отримано при використанні спільного фреймворку попередньої обробки, коли на зображенні було виявлено 60% плям з низькою щільністю. Для порівняння, цей відсоток становив 40% при застосуванні лише методу нормалізації. З точки зору ефективності виявлення плям, запропонований фреймворк виявив 63,84% плям, тоді як при використанні однієї методики було отримано нижчі відсотки: 3,57% для нормалізації, 17,69% для відфільтрованого зображення і 6,69% з використанням корекції фону. Крім того, найкращий показник віднімання також було отримано за допомогою запропонованого фреймворку – 78,62% порівняно з 11,37% при використанні лише модифікованої гістограмної техніки для корекції фону.

Таблиця 2

**Оцінка ефективності фреймворку попередньої обробки з використанням LPD, точкової ефективності ( $\Xi$ ) та відсотком пікселів ідентифікованих як фон (BSI) [27]**

| Метод                          | LPD(%) | $\Xi$ (%) | BSI(%) |
|--------------------------------|--------|-----------|--------|
| Original synthetic image       | 0      | 5.87      | N.A    |
| Piece wise equalization        | 40     | 3.57      | N.A    |
| GNDF                           | 3.33   | 17.69     | N.A    |
| Modified histogram-based       | 0      | 6.69      | 11.37  |
| Joint pre-processing framework | 60     | 63.84     | 78.62  |

Інтегрована система попередньої обробки була оцінена на реальних 2-DGE зображень, отриманих з чотирьох зразків апітоксину двох зразків сечі пацієнтів з раком простати і чотирьох 2D зображень з бази даних LECB 2-D PAGE Gel Image Database. Автори зафіксували відсоткове зменшення хибних результатів, порівнюючи оригінальні та попередньо оброблені зображення. Для 2-DGE зображень апітоксину система зменшила кількість хибних спрацьовувань від 43% до 72%. У випадку зразків сечі помилкові

спрацьовування попередньо оброблених зображень знизилася на 91% і 85% відповідно. А для зображень з бази даних селевих зображень LECB 2-D PAGE кількість хибно позитивних спрацьовувань зменшилася 71% до 93%. Отримані дані вказують на ефективність системи у питанні виявлення білків, зменшуючи кількість хибних спрацьовувань, спричинених шумом і неоднорідністю фону.

Зображення, отримані методом двовимірного гель-електрофарезу (2-DGE) характеризуються наявністю кількох аномалій, що ускладнюють процес виявлення та аналізу білкових плям. У даному дослідженні авторами було проведено експериментальну оцінку і підтверджено ефективність застосування трьох етапів цифрової обробки зображень, а саме: нормалізація, зменшення шуму і корекція фону, які значно підвищили якість зображень для подальшого аналізу. Запропоновано новий інтегрований фреймворк попередньої обробки, який об'єднує найкращі методи для кожного з трьох етапів обробки зображень які допомагають у боротьбі з конкретними аномаліями.

На підставі результатів, отриманих для реальних 2-DGE зображень встановлено, що інтегрований фреймворк забезпечує значно кращі результати порівняно з окремими методами. Зокрема, для таких зображень оптимальними є методи адаптивного кусково-гістограмного вирівнювання, GNDF та багаторівневого порогового вирівнювання.

Для оцінки точності моделей застосовується метод перехресної валідації, де навчальний набір даних застосовується для побудови моделі прогнозування, а тестовий набір - для оцінки її ефективності.

K-кратна перехресна валідація є ефективним підходом для мінімізації похибок пов'язаних із випадковими особливостями вибірки навчальних даних[23].

Зазвичай використовується десятикратна перехресна перевірка, яка вважається оптимальною з точки зору обчислювальних ресурсів та часу, який потрібен для перевірки. Цей підхід передбачає розподіл даних на десять частин, де дев'ять з них використовуються як навчальний набір даних для сурогатної моделі, а одна – для її тестування.

У методі десятикратної перехресної перевірки фіксована кількість даних фіксувану кількість вибірок з набору даних розбивають на десять разів. Серед цих десяти вибірок дев'ять вибірок слугуватимуть навчальним набором даних для побудови сурогатної моделі. Для побудови моделі, тоді як решта дев'ять згорток слугуватимуть як тестовим набором даних для перевірки та підтвердження точності сурогатної моделі. Для зменшення варіабельності кожен раунд десятикратного перехресного валідації виконується на різних підмножинах даних. Підсумкову точність моделі можна виразити як середнє значення точності, отримане в результаті десяти циклів валідації.

Алгоритми інтелектуального аналізу даних розрізняються за типом навчання, існують алгоритми для контрольованого, неконтрольованого та напівконтрольованого навчання. Контрольоване навчання спрямоване на прогнозування відомого результату на основі навчальної вибірки, що містить вже класифіковані дані, з метою зробити висновки на результатах або класифікувати нові тестові дані.

У неконтрольованому навчанні відсутні попередньо визначені цільові значення для прогнозування, тому аналізатори намагаються знайти природні закономірності або кластеризацію в немаркованих даних. Напівконтрольоване навчання дозволяє досягти балансу між продуктивністю і точністю за допомогою невеликих за розміром набори маркованих або анотованих даних і використовує їх зі значно більшою колекцією немаркованих даних[8]. Потенційно неконтрольоване навчання можна використати для подолання обмежень, які виникають у підходах керованого навчання для задач візуалізації плоских хвиль (PWI). Враховуючи, що підхід неконтрольованого навчання не може бути безпосередньо використане до реальних даних, він вимагає унікальної стратегії навчання для оптимізації мереж глибокого навчання. Один із можливих варіантів – це використати глибоке когерентне навчання, яке використовує характеристики сигналу візуалізації плоских хвиль у навчальній схемі мережі. Завдяки цьому методу мережа не обмежується якістю даних і стає більш надійно за різних умов не потребуючи еталонних зображень[12].

Моделі машинного навчання ML з контрольованим навчанням застосовуються в випадках, коли цільовий результат чітко визначений, а дані мають маркування, що відповідає цьому результату[11]. Наприклад, таким результатом може бути наявність або відсутність певного захворювання, такого як діабет чи гіпертонія. Однією з ключових вимог до таких моделей є корекція маркування даних, оскільки будь-яка похибка в оцінці результатів може негативно вплинути на продуктивність моделі та зменшити її здатність узагальнювати результати на популяції поза межами навчального набору даних[17]. При використанні контрольованого навчання виникає проблема з збором значних обсягів маркованих навчальних даних. Цю проблему можна вирішити за допомогою слабо контрольованого навчання для маркування немаркованих даних[19].

Процес побудови моделей з контрольованим навчанням є добре відпрацьованим і стандартизованим, оскільки такі моделі широко використовуються. Початковим етапом для формування керованої моделі машинного навчання є постановка задачі, після чого необхідно визначити та підготувати відповідні дані для вирішення цієї задачі[13]. Попередня обробка даних є ключовим етапом, що складається з вилучення зайвих змінних, очищення даних від суперечностей і обмеження їх в рамках необхідних змінних[14]. Для навчання моделі часто обирають випадкові вибірки даних. Спосіб полягає у начинні моделі



з застосуванням відповідних алгоритмів і оцінювати продуктивність моделі за допомогою матриці плутанини та робочої характеристики приймача(ROC-крива).

Створення остаточної моделі це процес що повторюється багато разів, під час чого обирається алгоритм з оптимальною комбінацією параметрів, для забезпечення найвищої прогностичної ефективності моделі[16]. У науковій літературі можна знайти рекомендації щодо використання параметрів за замовчуванням для зменшення витрат часу на налаштування гіперпараметрів і обчислювальних зусиль. У машинному навчанні під наглядом виділяють дві основні категорії задач: класифікація та регресія.

Алгоритми класифікації використовуються для групування даних шляхом передбачення категорійної мітки або змінної на основі наданих даних. Такий підхід застосовується, коли вихідні змінні є категоричними і належать до двох або більше класів. Використання допоміжних даних у поєднанні з контекстними знаннями підвищують загальну точність класифікації[21]. Методи класифікації включають в себе: nearest neighbors, logistic regression, support vector machine (SVM), naive Bayes, linear discriminant analysis (LDA), quadratic discriminant analysis, tree-based models (decision tree, random forest, extremely randomized trees)

Прикладом використання алгоритму класифікації є спам-фільтр в електронній пошті, де модель з навчанням під наглядом використовується для передбачення, чи є повідомлення спамом. Це досягається шляхом аналізу набору даних, що містить позначені приклади спаму та звичайних електронних повідомлень[14]. Алгоритм аналізує інформацію про кожний електронний лист, включаючи дані про відправника, тему, текст та інше. Користуючись цими даними алгоритм вивчає закономірності та надає оцінку, що визначає, чи є повідомлення спамом або ні.

Алгоритми регресії використовуються для прогнозування дійсних або неперервних значень шляхом встановлення зв'язків між кількома або більше змінними. Вони поділяються на: nearest neighbors, linear regression, support vector machine regression, tree-based models (decision tree, random forest, extremely randomized trees), kernel ridge regression. Прикладом може бути прогнозування заробітної плати на основі даних пов'язаних з роботою. У цьому випадку модель навчається на основі таких вхідних даних, як тривалість роботи, галузь, місцезнаходження та інші, для її подальшого використання у прогнозуванні щодо середньої заробітної плати на основі даних щодо працівника.[15].

Метод найближчих сусідів (KNN) є одним з найбільш інтуїтивно зрозумілих підходів до машинного навчання. Він ґрунтується на наступному: для певного входу відповідний вихід, вірогідно, буде схожим на вихід при подібних входах. Наприклад, у пацієнта є симптоми характерні для іншого пацієнта, якому було діагностовано певну хворобу, то, швидше за все, що йому також може бути поставлений такий самий діагноз. Використовується для вирішення завдань неконтрольованої фільтрації, під час якої зберігається структура вихідних даних, але відсутні мітки, тому для опису міток будується матриця графу Лапласіана на основі графу побудованого методом найближчих сусідів з подальшим вивченням псевдо міток класі за допомогою спектрального аналізу[10]

Формально, методи найближчого сусіда використовують навчальні вибірки з околиці заданої точки для виконання прогнозу. У випадку задачі регресії прогноз обчислюється як середньозважене значення цільових величин. У задачах класифікації, передбачена мітка відповідає мітці яка має найбільшу суму входжень кожної мітки.

Ключовим параметром методу найближчих сусідів є метрика, що визначає несхожість. Метрика використовується для визначення околиці будь-якої точки, а також може бути використана для обчислення ваг та позначається як  $d$ .

Рисунок 3 ілюструє концепцію цього алгоритму. Алгоритм  $k$ -середніх розбиває набір з  $n$  вибірок, позначених на набір з  $k$  нез'язаних кластерів, кожен з яких пронумерований. Кожен кластер характеризується своїм центроїдом, позначеним через  $\mu$ , тобто середнім значенням вибірок у цьому кластері. Центроїди повністю визначають набір кластерів, оскільки кожна вибірка відноситься до того кластера, центроїд якого є найближчим до неї.

Мета алгоритму – знайти центроїди, які мінімізують інерцію, також відому як внутрішньокластерний критерій суми квадратів. У цьому прикладі інерційність приблизно дорівнює 184.80 і є мінімально можливою інерційністю.

Оригінальний алгоритм, який використовується для знаходження центроїдів, часто називають алгоритмом Лойда і представлено в алгоритмі. Після ініціалізації центроїдів повторюється двокроковий цикл до збіжності (коли центроїди збігаються на двох послідовних ітераціях), який складається з кроку призначення, на якому кластери оновлюються на основі поточних центроїдів та кроку оновлення, на якому центроїди оновлюються на основі поточних кластерів

Коли кластери чітко визначені, точка з певного кластера, швидше за все, залишиться в цьому кластері. Таким чином, крок призначення можна пришвидшити завдяки нерівності трикутника, відстежуючи нижню та верхню межі відстаней між точками та центрами, але за рахунок більшого використання пам'яті[16].

Некероване навчання передбачає використання алгоритмів, здатних навчатися самостійно, без попереднього маркування чи навчання даних або моделі. Модель аналізує сирі дані і самостійно виводить правила, структуруючи інформацію на основі подібностей і відмінностей без інструкцій, яким чином обробляти кожен з фрагментів даних.




Рис. 3. Ілюстрація алгоритму k-середніх. [16]

Неконтрольоване навчання є особливо корисним для складних задач, однією з таких задач є кластеризація великих наборів даних. Алгоритм допомагає виявляти приховані ознаки, закономірності в значних об'ємах даних, що можна використовувати для подальшої категоризації цих даних.[6]

Наприклад, аналіз значного за об'ємом набору даних про погоду за допомогою такого алгоритму може призвести до групування за температурним показниками або за погодними умовами, що дослідним може інтерпретувати як класифікацію за порами року або типами погоди. До цього підходу належать методи кластеризації які поділяються на *k-means*, *Gaussian mixture model* та зменшення розмірності що в свою чергу поділяються на *principal component analysis (PCA)*, *linear discriminant analysis (LDA)*, *kernel principal component analysis*.

В межах дослідження [22] докладно аналізується алгоритм бітового злиття, застосованого до навченої моделі класифікації. Цей алгоритм злиття має на меті максимізувати точність класифікації шляхом скорочення часу виконання. Припустимо, що є множина з  $k$  класифікаторів  $\text{Classifier} = \{C1, C2, \dots, Ck\}$  та набір вхідних ознак  $X = \{x1, x2, \dots, xn\}$  у кількості  $n$  ознак, кожна з яких має  $m$  умов і набір міток класу позначається як  $\omega = \{\omega 1, \omega 2, \dots, \omega r\}$ . Кожен класифікатор  $Ci$  здійснює прогнозування мітки класу  $\omega$  для вхідного значення  $x_i$ . Для всіх класифікаторів результати формують  $r$ -вимірний вектор, який підтримує мітки  $\omega$ .

У межах набору даних ми отримаємо значення, визначене з вхідного елементу  $C_i(x)$ , яке представляє м'які мітки класів, тобто визначає, наскільки сильно класифікатор  $C_i$  вважає, що його екземпляр  $x$  належить до класу  $\omega_i$ . Він приймає значення від 0 до 1, де 0 означає що екземпляр абсолютно не відповідає класу  $\omega$ , а 1 означає повну відповідність. Методологія об'єднання класифікаторів полягає у визначенні категорії класу для входу  $x$  на основі результатів усіх класифікаторів. Наступним кроком використовується правило максимальної належності для остаточного призначення мітки класу, яке полягає у визначенні до якого класу належить об'єкт який має максимальне значення ймовірностей.

Існує дві стратегії комбінування класифікаторів: вибір класифікатора [22] та злиття класифікаторів. Ідея вибору класифікатора полягає в тому, що кожен класифікатор має досвід у деякій локальній області простору ознак. Коли вектор ознак  $x \in \mathcal{X}^n$  подається на класифікацію, класифікатор, відповідальний за околицю  $x$ , отримує найвищі повноваження для позначення  $\omega$ . Злиття класифікаторів передбачає, що всі

класифікатори мають однаковий доступ до всього простору ознак і рішення всіх  $C$  враховуються для будь-якого  $x$ . [24]

Традиційні методи злиття, до складу яких входять мажоритарне голосування, рівномірний розподіл, підсумовування розподілу, методи Демпстера-Шейфера, ентропійне зважування та зважування на основі щільності, використовують окремі вхідні дані від кожного з базових класифікаторів. Кожен з цих методів мають на меті – підвищення точності класифікації шляхом обробки і узагальнення результатів класифікації. Наприклад, при мажоритарному голосуванні, якщо більшість класифікаторів вказує на те, що екземпляр відноситься до класу 1, то алгоритм злиття автоматично присвоює клас 1 як остаточну мітку для цього екземпляра. Іноді точність може бути знижена у випадку коли реальна категорія даних відрізняється від прогнозованої. Висока часова складність мажоритарного голосування може зменшити загальну ефективність, хоча це компенсовано підвищенням точності системи [25].

Методи злиття є критично важливими для підвищення точності у задачах класифікації. Вибір ефективного методу злиття є одним із ключових чинників у вирішенні проблем розпізнавання образів. У цьому контексті запропонований ансамблевий класифікатор, заснований на бітовому злитті, пропонує значні переваги порівняно з традиційними методами злиття та вирішує проблеми пов'язані з ними, адже він не залежить від кількості класифікаторів або їх вихідних даних. Цей підхід оцінює дані на основі налаштованого власного параметра та приймає рішення відповідно до заданого порогового значення.

Запропонований авторами алгоритм бітового злиття аналізує вхідні дані у вигляді м'яких міток класів, що використовуються на стандартних наборах даних експресії генів. Цей алгоритм представляє собою ефективну та надійну структуру злиття, що перевершує традиційні підходи злиття за показниками точності, коректності та часової складності. Даний алгоритм проводить порівняння даних на основі ознак з заданим пороговим значенням і класифікує кожен ознаку як м'яку мітку класу. Основна увага алгоритму приділяється вимірюванню різноманітності в порівнянні з іншими методологіями. Після завершення класифікації традиційні алгоритми використовуються для подальшого підвищення точності.

У рамках проведеного дослідження було впроваджено і оцінено модель, яка використовує різні традиційні методи злиття. Точність, досягнута за допомогою кожного з методів відображена на Рисунках 4-5 для різних наборів даних, де вісь  $X$  вказує на відсоток даних, що використовується для тестування, а вісь  $Y$  вказує на рівень точності. З метою навчання та тестування було застосовано 10-кратну схему перехресної перевірки. Отримані результати свідчать про те, що класифікація за допомогою бітового злиття демонструє таку ж ефективність як і інші більш складні методи, у поліпшенні швидкості розпізнавання для зазначеного набору даних.

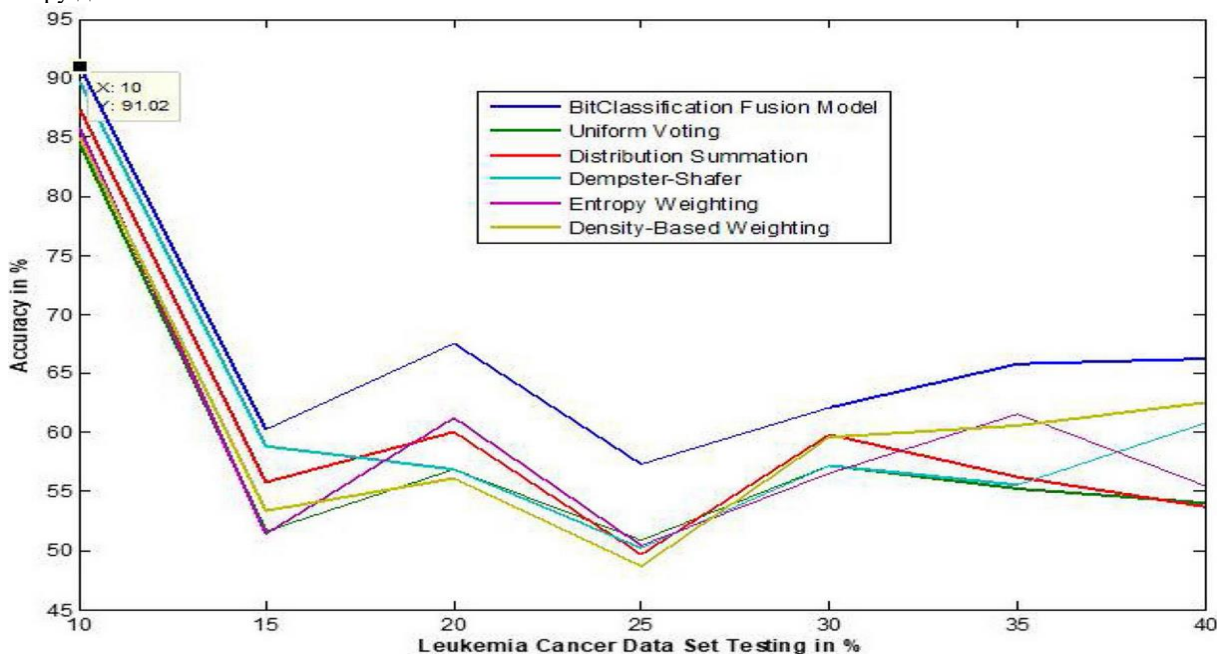


Рис. 4. Точність роботи алгоритму бітового злиття для раку лейкемії порівняно з іншими стандартними методами злиття. [22]

У ході дослідження автори провели порівняння створеного алгоритму з результатами, отриманими на 15 стандартних наборах даних, відібраних з репозиторію класифікації часових рядів UEA та UCR. Для оцінки точності злиття дослідники зіставили її з найкращими показниками інших класифікаторів.

Середня точність запропонованої моделі, виражена у відсотках, перевершила показники інших методів. При найсприятливішому сценарії, запропонована модель продемонструвала найкращі результати на всіх 15 наборах даних. Тоді, як другим найкращим методом виявився метод опорних векторів (SVM).




Рис. 5. Порівняльний аналіз точності всіх наборів даних. [22]

Методологія, що пропонується авторами, сприяє підвищенню точності класифікації шляхом орієнтування на категоризацію окремих значень ознак, а не на ознаки в цілому. Це дозволяє моделі досягати високих показників точності навіть на великих наборах даних, при цьому додаткові обчислювальні ресурси потрібні в незначних обсягах.

На етапі попереднього аналізу даних може бути корисним дослідити дисперсії для  $p$  ознак і виконати розрахунки  $12p(p-1)$  коваріацій або кореляцій. Проте, зі збільшенням значення  $p$  цей процес стає складнішим. Оскільки кожна окрема ознака може пояснювати лише малу частку загальної дисперсії. Тому бажаним варіантом може бути використання іншого представлення даних, яке б дозволило невеликій кількості ознак пояснювати більшу частку загальної дисперсії, тобто шляхом створення адаптованої системи координат до вхідних даних.

Метод аналізу головних компонент (PCA) полягає в побудові репрезентації даних через головні компоненти. Головні компоненти утворюють послідовність одиничних векторів, таким чином, що кожен  $i$ -й вектор забезпечує максимальне пояснення дисперсії даних, при цьому залишаючись ортогональним до перших  $i - 1$  векторів.

### ВИСНОВКИ ТА ПЕРСПЕКТИВИ ПОДАЛЬШОГО РОЗВИТКУ У ДАНОМУ НАПРЯМІ

Застосування машинного навчання в сфері охорони здоров'я передбачає інтеграцію різних типів даних із чисельних джерел для формування всебічного уявлення про стан здоров'я пацієнта. Це потребує ефективних інструментів управління даними та аналітики. Однак, існує проблема у варіативності інтерпретацій медичних даних лікарями, які ґрунтуються на персональному досвіді і судженнях лікарів, що може призвести до варіативності в наданні допомоги пацієнтам. Для ефективного вирішення цієї проблеми найкраще підходить стандартизація.

Машинне навчання відкриває нові горизонти для ідентифікації релевантних ознак, які є важливими для постановки діагнозу, допомагаючи знайти приховані закономірності. Використання моделей, які можна інтерпретувати, таких як машини опорних векторів (SVM) або дерева рішень, дозволяє дослідникам вивчати ознаки, які лежать в основі прийняття рішень алгоритмами. Наступним методом, що може бути використаний для пошуку корисних ознак – глибоке навчання. У випадках коли використовується в поєднанні з методами інтерпретації є опція використання навчання без попередньої обробки зображень. Ще один підхід визначити релевантні ознаки для класифікації – порівняти результати прогнозування різних моделей машинного навчання з різними вхідними ознаками, що надає можливість оцінити внесок кожної окремої ознаки в покращенні класифікації.

Як було зазначено у попередніх розділах, боротьба з аномаліями та артефактами у медичних зображеннях, таких як ті, що виникають при використанні 2-DGE, залишається важливим викликом. Існуючі методи попередньої обробки даних не завжди забезпечують достатню ефективність у випадках складних

аномалій, що може негативно впливати на точність діагностики. Тому що доцільним є проведення дослідження, присвяченого вдосконаленню методів попередньої обробки медичних зображень для підвищення їхньої стійкості до аномалій. Зокрема, необхідно розробити нові алгоритми нормалізації, фільтрації та корекції зображень, що будуть більш ефективними у випадках складних та нетипових даних.

Гамма-корекція, TVF + гамма та CLAHE досягають більшого покращення значення чутливості порівняно з іншими групами методів. Знебарвлення зображення за допомогою TVF перед гамма-корекцією допомагає швидше досягти найкращих результатів порівняно з методами CLAHE і HE. Гамма-корекція є найефективнішим з усіх розглянутих підходів, оскільки вона покращує оцінку точності для всіх класів, а застосування підходу повного варіаційного зашумлення перед гамма-корекцією покращує продуктивність і час збіжності на еталонних наборах даних. При цьому гамма-корекція є однаково сприятливою для всіх класів.

Серед методів корекції фону найбільш ефективними є методи поверхневої апроксимації та багаторівневої порогової апроксимації з результатами 97,9% та 98,5% пікселів фону на синтетичних зображень відповідно.

Згідно з результатами проаналізованої роботи інтегрований фреймворк для реальних 2-DGE зображень, що складається з трьох етапів обробки зображень, кожен з яких вирішує конкретну проблему, показую значно більшу ефективність порівняно з окремими методами. У цьому дослідженні методи що були визначенні як найбільш ефективні: адаптивного кусково-гістограмного вирівнювання, GNDF та багаторівневого порогового вирівнювання.

Методи злиття є критично важливими для підвищення точності у розпізнаванні образів. Класифікатор, заснований на бітовому злитті, пропонує значні переваги порівняно з традиційними методами злиття та вирішує проблеми пов'язані з ними, адже він не залежить від кількості класифікаторів або їх вихідних даних. Цей підхід оцінює дані на основі налаштованого власного параметра та приймає рішення відповідно до заданого порогового значення. У ході дослідження автори провели порівняння створеного алгоритму з результатами, отриманими на 15 стандартних наборах даних, і у кожному з наборів алгоритм показував найбільшу ефективність.

Методи злиття дозволяють значно покращити точність класифікації, особливо коли є доступ до декількох моделей або класифікаторів. Проте залишається відкритим питання оптимального налаштування параметрів таких методів, що забезпечить їх універсальне застосування.

#### Література

- 1 Tayefi M, Phuong D, Dalianis H. (2021, February). «Challenges and opportunities beyond structured data in analysis of electronic health records». doi: <https://doi.org/10.1002/wics.1549>
- 2 Gerard P, Peter V, Frede M. D. (2016, December). «Bigger data, bigger problems. J Orthop Trauma». doi: <https://doi.org/10.1097/bot.0000000000000463>
- 3 Dalianis H. (2018, May). «Evaluation Metrics and Evaluation. In Clinical Text Mining» (pp.45-53) doi: [https://link.springer.com/chapter/10.1007/978-3-319-78503-5\\_6](https://link.springer.com/chapter/10.1007/978-3-319-78503-5_6)
- 4 Tammy J, Jaimie L. Gradus, Anthony J. Rosellini. (2020, May). «Supervised Machine Learning: A Brief Primer». doi: <https://doi.org/10.1016/j.beth.2020.05.002>
- 5 Krzysztof J. Cios, Moore G. W. (2002, September) «Uniqueness of medical data mining». doi: [https://doi.org/10.1016/s0933-3657\(02\)00049-0](https://doi.org/10.1016/s0933-3657(02)00049-0).
- 6 Girish C, Ferat S. (2014, January). «A survey on feature selection methods». doi: <https://doi.org/10.1016/j.compeleceng.2013.11.024>
- 7 Jadczyk T, Kiwic O, Raj M. Khandwalla (2019, September) «Feasibility of a voice-enabled automated platform for medical data collection: CardioCube». doi: <https://doi.org/10.1016/j.ijmedinf.2019.07.001>
- 8 Choong Ho Lee and Hyung-Jin Yoon (2017, March) «Medical big data: promise and challenges» doi: <https://doi.org/10.23876/j.krcp.2017.36.1.3>
- 9 [Maryam Tayefi, Phuong Ngo, Taridzo Chomutare](#), (2021, February) «Challenges and opportunities beyond structured data in analysis of electronic health records». doi: <https://doi.org/10.1002/wics.1549>.
- 10 Han J, Zhengya S, Hongwei H. (2015, September). «Selecting feature subset with sparsity and low redundancy for unsupervised learning». doi: <https://doi.org/10.1016/j.knosys.2015.06.008>
- 11 David A. Nardone. (1990). «Collecting and Analyzing Data: Doing and Thinking. In Clinical Methods: The History, Physical, and Laboratory Examinations. 3rd edition» [H. Kenneth Walker, W. Dallas Hall, J. Willis Hurst](#).
- 12 Hyunwoo C, Seongjun P, Jinbum K, Yangmo Y, (2024, September), «Deep coherence learning: An unsupervised deep beamformer for high quality single plane wave imaging in medical ultrasound», doi:<https://doi.org/10.1016/j.ultras.2024.107408>

- 13 Faouzi J, Colliot O. (2023, July). «Classic Machine Learning Methods. In Machine Learning for Brain Disorders» (pp. 25-74). Available at: <https://www.ncbi.nlm.nih.gov/books/NBK597496/>
- 14 Garcia S, Ramirez-gallego S, Luengo J. (2016, November). «Big data preprocessing: methods and prospect». Available at: <https://link.springer.com/article/10.1186/s41044-016-0014-0>
- 15 Kevin P. Murphy (2012, August) «Machine Learning A Probabilistic Perspective» (pp. 3-16). Available at: [https://doc.lagout.org/science/Artificial%20Intelligence/Machine%20learning/Machine%20Learning\\_%20A%20Probabilistic%20Perspective%20%5BMurphy%202012-08-24%5D.pdf](https://doc.lagout.org/science/Artificial%20Intelligence/Machine%20learning/Machine%20Learning_%20A%20Probabilistic%20Perspective%20%5BMurphy%202012-08-24%5D.pdf)
- 16 David A, Vassilvitskii S. (2007). «k-means++: The Advantages of Careful Seeding». Available at: <https://theory.stanford.edu/~sergei/papers/kMeansPP-soda.pdf>
- 17 Alanazi A. (2022) «Using machine learning for healthcare challenges and opportunities». doi: <https://doi.org/10.1016/j.imu.2022.100924>
- 18 Xie H, Ding Z, Li P, Xu X (2024, July). «An enhanced structural developmental neural network with information saturation for continual unsupervised learning». doi: <https://doi.org/10.1016/j.neucom.2024.127666>
- 19 Liyakathunisa Syed, Abdullah Alsaedi, Lina A. Alhuri, Hutaf R. Aljohani, (2023, September). «Hybrid weakly supervised learning with deep learning technique for detection of fake news from cyber propaganda». doi: <https://doi.org/10.1016/j.array.2023.100309>
- 20 Kavzoglu T. (2009, July). «Increasing the accuracy of neural network classification using refined training data». 24(7):850-858 Available at: [https://www.researchgate.net/publication/223565557\\_Increasing\\_the\\_accuracy\\_of\\_neural\\_network\\_classification\\_using\\_refined\\_training\\_data](https://www.researchgate.net/publication/223565557_Increasing_the_accuracy_of_neural_network_classification_using_refined_training_data)
- 21 Manandhar R, Inakwu O. A, Ancev T. (2009) «Improving the Accuracy of Land Use and Land Cover Classification of Landsat Data Using Post-Classification Enhancement». 1(3), 330-344. doi: <https://doi.org/10.3390/rs1030330>
- 22 Mishra S, Shaw K, Mishra D. (2022 May). « Improving the Accuracy of Ensemble Machine Learning Classification Models Using a Novel Bit-Fusion Algorithm for Healthcare AI Systems». doi: <https://doi.org/10.3389/fpubh.2022.858282>
- 23 I-Tung Yang, Husada W. (2017, March) «Improving Classification Accuracy for Single-loop Reliability-based Design Optimization». IMECS 2017. Available at: [https://www.iaeng.org/publication/IMECS2017/IMECS2017\\_pp1036-1040.pdf](https://www.iaeng.org/publication/IMECS2017/IMECS2017_pp1036-1040.pdf)
- 24 Tsiliki G, Kossida S. (2011, July) «Fusion methodologies for biomedical data». doi: <https://doi.org/10.1016/j.jprot.2011.07.001>
- 25 Kilic E, Alpaydin E. (2010, December) «Learning the areas of expertise of classifiers in an ensemble». doi: <https://doi.org/10.1016/j.procs.2010.12.014>
- 26 Sharma A, Pramod Kumar Mishra. (2022, August) «Image enhancement techniques on deep learning approaches for automated diagnosis of COVID-19 features using CXR images». doi: <https://doi.org/10.1007/s11042-022-13486-8>
- 27 Mauricio Goetz M, Maria C. Torres-Madronero, (2020, August) «Joint pre-processing framework for two-dimensional gel electrophoresis images based on nonlinear filtering, background correction and normalization techniques» . doi: <https://doi.org/10.1186/s12859-020-03713-0>
- 28 McCombe D. K, Craig G. S. (2021, Aug) «HistoClean: Open-source software for histological image pre-processing and augmentation to improve development of robust convolutional neural networks» doi: <https://doi.org/10.1016/j.csbj.2021.08.033>
- 29 Goetz M. M, Torres-Madroño M. C, Röthlisberger S, Delgado-Trejos E. (2018, February) «Preprocessing of 2-Dimensional Gel Electrophoresis Images Applied to Proteomic Analysis: A Review». doi: <https://doi.org/10.1016%2Fj.gpb.2017.10.001>
- 30 [Zhigang Ling, Yan Liang, Yaonan Wang, He Shen, Xiao Lu](#), (2015, November). «Adaptive extended piecewise histogram equalisation for dark image enhancement » doi: <https://doi.org/10.1049/iet-ipr.2014.0580>

## References

1. Tayefi M, Phuong D, Dalianis H. (2021, February). «Challenges and opportunities beyond structured data in analysis of electronic health records». doi: <https://doi.org/10.1002/wics.1549>
2. Gerard P, Peter V, Frede M. D. (2016, December). «Bigger data, bigger problems. J Orthop Trauma». doi: <https://doi.org/10.1097/bot.0000000000000463>
3. Dalianis H. (2018, May). «Evaluation Metrics and Evaluation. In Clinical Text Mining» (pp.45-53) a. doi: [https://link.springer.com/chapter/10.1007/978-3-319-78503-5\\_6](https://link.springer.com/chapter/10.1007/978-3-319-78503-5_6)
4. Tammy J, Jaimie L. Gradus, Anthony J. Rosellini. (2020, May). «Supervised Machine Learning: A Brief Primer». doi: <https://doi.org/10.1016/j.beth.2020.05.002>
5. Krzysztof J. Cios, Moore G. W. (2002, September) «Uniqueness of medical data mining». doi: [https://doi.org/10.1016/s0933-3657\(02\)00049-0](https://doi.org/10.1016/s0933-3657(02)00049-0)

6. Girish C, Ferat S. (2014, January). «A survey on feature selection methods». doi: <https://doi.org/10.1016/j.compeleceng.2013.11.024>
7. Jadczyk T, Kiwic O, Raj M. Khandwalla (2019, September) «Feasibility of a voice-enabled automated platform for medical data collection: CardioCube». doi: <https://doi.org/10.1016/j.ijmedinf.2019.07.001>
8. Choong Ho Lee and Hyung-Jin Yoon (2017, March) «Medical big data: promise and challenges» doi: <https://doi.org/10.23876/j.krcp.2017.36.1.3>
9. [Maryam Tayefi, Phuong Ngo, Taridzo Chomutare](#), (2021, February) «Challenges and opportunities beyond structured data in analysis of electronic health records». doi: <https://doi.org/10.1002/wics.1549>.
10. Han J, Zhengya S, Hongwei H. (2015, September). «Selecting feature subset with sparsity and low redundancy for unsupervised learning». doi: <https://doi.org/10.1016/j.knosys.2015.06.008>
11. David A. Nardone. (1990). «Collecting and Analyzing Data: Doing and Thinking. In Clinical Methods: The History, Physical, and Laboratory Examinations. 3rd edition» [H. Kenneth Walker, W. Dallas Hall, J. Willis Hurst](#).
12. Hyunwoo C, Seongjun P, Jinbum K, Yangmo Y, (2024, September), «Deep coherence learning: An unsupervised deep beamformer for high quality single plane wave imaging in medical ultrasound», doi:<https://doi.org/10.1016/j.ultras.2024.107408>
13. Faouzi J, Colliot O. (2023, July). «Classic Machine Learning Methods. In Machine Learning for Brain Disorders» (pp. 25-74). Available at: <https://www.ncbi.nlm.nih.gov/books/NBK597496/>
14. Garcia S, Ramirez-gallego S, Luengo J. (2016, November). «Big data preprocessing: methods and prospect». Available at: <https://link.springer.com/article/10.1186/s41044-016-0014-0>
15. Kevin P. Murphy (2012, August) «Machine Learning A Probabilistic Perspective» (pp. 3-16). Available at: [https://doc.lagout.org/science/Artificial%20Intelligence/Machine%20learning/Machine%20Learning\\_%20A%20Probabilistic%20Perspective%20%5BMurphy%202012-08-24%5D.pdf](https://doc.lagout.org/science/Artificial%20Intelligence/Machine%20learning/Machine%20Learning_%20A%20Probabilistic%20Perspective%20%5BMurphy%202012-08-24%5D.pdf)
16. David A. Vassilvitskii S. (2007). «k-means++: The Advantages of Careful Seeding». Available at: <https://theory.stanford.edu/~sergei/papers/kMeansPP-soda.pdf>
17. Alanazi A. (2022) «Using machine learning for healthcare challenges and opportunities». doi: <https://doi.org/10.1016/j.jmu.2022.100924>
18. Xie H, Ding Z, Li P, Xu X (2024, July). «An enhanced structural developmental neural network with information saturation for continual unsupervised learning». doi: <https://doi.org/10.1016/j.neucom.2024.127666>
19. Liyakathunisa Syed, Abdullah Alsaeedi, Lina A. Alhuri, Hutaf R. Aljohani, (2023, September). «Hybrid weakly supervised learning with deep learning technique for detection of fake news from cyber propaganda». doi:<https://doi.org/10.1016/j.array.2023.100309>
20. Kavzoglu T. (2009, July). «Increasing the accuracy of neural network classification using refined training data». 24(7):850-858 Available at: [https://www.researchgate.net/publication/223565557\\_Increasing\\_the\\_accuracy\\_of\\_neural\\_network\\_classification\\_using\\_refined\\_training\\_data](https://www.researchgate.net/publication/223565557_Increasing_the_accuracy_of_neural_network_classification_using_refined_training_data)
21. Manandhar R, Inakwu O. A, Ancev T. (2009) «Improving the Accuracy of Land Use and Land Cover Classification of Landsat Data Using Post-Classification Enhancement». *J(3)*, 330-344. doi: <https://doi.org/10.3390/rs1030330>
22. Mishra S, Shaw K, Mishra D. (2022 May). « Improving the Accuracy of Ensemble Machine Learning Classification Models Using a Novel Bit-Fusion Algorithm for Healthcare AI Systems». doi: <https://doi.org/10.3389/fpubh.2022.858282>
23. I-Tung Yang, Husada W. (2017, March) «Improving Classification Accuracy for Single-loop Reliability-based Design Optimization». IMECS 2017. Available at: [https://www.iaeng.org/publication/IMECS2017/IMECS2017\\_pp1036-1040.pdf](https://www.iaeng.org/publication/IMECS2017/IMECS2017_pp1036-1040.pdf)
24. Tsiliki G, Kossida S. (2011, July) «Fusion methodologies for biomedical data». doi: <https://doi.org/10.1016/j.jprot.2011.07.001>
25. Kilic E, Alpaydin E. (2010, December) «Learning the areas of expertise of classifiers in an ensemble». doi: <https://doi.org/10.1016/j.procs.2010.12.014>
26. Sharma A, Pramod Kumar Mishra. (2022, August) «Image enhancement techniques on deep learning approaches for automated diagnosis of COVID-19 features using CXR images». doi: <https://doi.org/10.1007/s11042-022-13486-8>
27. Mauricio Goetz M, Maria C. Torres-Madronero, (2020, August) «Joint pre-processing framework for two-dimensional gel electrophoresis images based on nonlinear filtering, background correction and normalization techniques» . doi: <https://doi.org/10.1186/s12859-020-03713-0>
28. McCombe D. K, Craig G. S. (2021, Aug) «HistoClean: Open-source software for histological image pre-processing and augmentation to improve development of robust convolutional neural networks» doi: <https://doi.org/10.1016/j.csbj.2021.08.033>
29. Goetz M. M, Torres-Madronero M. C, Röthlisberger S, Delgado-Trejos E. (2018, February) «Preprocessing of 2-Dimensional Gel Electrophoresis Images Applied to Proteomic Analysis: A Review». doi: <https://doi.org/10.1016/j.2fj.gpb.2017.10.001>
30. [Zhigang Ling, Yan Liang, Yaonan Wang, He Shen, Xiao Lu](#), (2015, November). «Adaptive extended piecewise histogram equalisation for dark image enhancement » doi: <https://doi.org/10.1049/iet-ipr.2014.0580>