

УДК 004.932.2:616-073.75

КЛАС-БАЛАНСНИЙ ВІДБІР ІНТЕНСИВНОСТЕЙ У КТ-ЗОБРАЖЕННЯХ ЛЕГЕНЬ

Давидович Ілля Вікторович¹

davydovych@lil.kpi.ua

Настенко Євген Арнольдович^{1,2}

bk-nastenko-fbmi@lil.kpi.ua

¹Національний технічний університет України

«Київський політехнічний інститут імені Ігоря Сікорського»

м. Київ, Україна,

²ДУ «Національний інститут серцево-судинної хірургії

імені М.М. Амосова НАМН України»

м. Київ, Україна

Анотація – Інформативні ділянки на медичних КТ-зображеннях займають невелику частку, тоді як фон та інші тканини здебільшого домінують та впливають на якість подальшого аналізу й класифікації. Глибокі нейронні мережі здатні самостійно вилучати інформативні ознаки, проте дисбаланс класів, мала вибірка та неоднорідна якість даних ускладнюють навчання та інтерпретацію моделей комп'ютерної діагностики. Рішенням може стати використання класичних методів машинного навчання з ручною процедурою формування ознак, що вимагає певних кроків попередньої обробки даних. Метою роботи є обґрунтування користі етапу попередньої обробки зображень, який концентрує увагу на змістовних частинах зображення, пом'якшує дисбаланс класів і робить дані придатнішими для подальшого текстурного аналізу та побудови моделей. У даній роботі пропонується метод клас-балансного відбору, що узагальнює розподіли яскравості пікселів, шляхом послідовного переходу від рівня окремого зрізу до рівня пацієнта та класу, в результаті чого формується узгоджений профіль поширених значень. Далі відбирається обмежений набір інтервалів яскравості, що покривають заздалегідь визначену частку загальної маси інтенсивностей. Фільтровані зображення зберігаються у вигляді теплової карти частот значень пікселів, зважаючи їх відповідно до типовості в межах набору. Результати показали, що запропонований клас-балансний фільтр робить інформативні структури компактнішими та виразнішими, а представлення різних класів більш рівномірною. Теплові карти зберігають змістовну частину сигналу при помітному скороченні зайвої інформації, що спрощує побудову інформативних ознак. Ефект зберігається для різних налаштувань відбору та є узгодженим на рівні пацієнта. Клас-збалансований відбір інтервалів яскравості можна розглядати як практичний стартовий крок попередньої обробки для задач аналізу КТ-зображень. Він фокусує обробку на найважливіших ділянках, вирівнює внесок класів і підвищує придатність даних до подальшої інтерпретації та моделювання, особливо в умовах малої вибірки.

Ключові слова: КТ-зображення; попередня обробка зображень; відбір інтервалів яскравості; дисбаланс класів; текстурний аналіз.

І. ВСТУП

Комп'ютерна томографія (КТ) та інші методи візуалізації є ключовими інструментами діагностики в різних галузях медицини. Однак інтерпретація цих зображень все ще залишається складною задачею для лікарів-радіологів.[1] Це зумовлено складною організацією самих даних, що відображають детальні анатомічні структури, де візуальні ознаки патологій можуть сильно варіюватися, накладаючись на нормальні ділянки. Шум та артефакти сканування через рух пацієнта, обмеження інструментів візуалізації, характеристики апаратів додатково ускладнюють аналіз [2]. Як наслідок цього, навіть досвідчені фахівці можуть дійти різних висновків щодо одного і того ж зображення [3]. Така неоднозначність

трактувань підкреслює потребу в більш об'єктивних підходах до аналізу медичних зображень.

За останні роки обсяги медичних даних стрімко зросли завдяки цифровізації, що переважує лікарів інформацією [4]. Це в свою чергу стимулювало розвиток методів комп'ютерного аналізу зображень, які можуть автоматизувати рутинні процеси та підвищити точність діагностики [5]. Застосування штучного інтелекту (ШІ), зокрема методів глибокого навчання, дозволило виявляти приховані закономірності у медичних зображеннях і надавати кількісну оцінку їхніх характеристик [6]. Наприклад, сучасні алгоритми здатні розпізнавати складні патерни на знімках КТ і виокремлювати тонкі патологічні зміни, які

можуть лишитися непоміченими при візуальному огляді [4].

Більше того, глибокі згорткові нейронні мережі зарекомендували себе як провідний підхід для аналізу медичних зображень, досягаючи високих результатів у задачах класифікації та сегментації зображень. [7, 8, 9]

Водночас впровадження подібних автоматизованих систем пов'язане з низкою викликів. По-перше, обсяги медичних наборів даних зазвичай невеликі, оскільки отримання якісної розмітки зображень від експертів потребує значних ресурсів і часу [10]. Це обмежує можливості навчання глибоких моделей і підвищує ризик перенавчання на малих вибірках. По-друге, дані часто мають дисбаланс класів, критичні патологічні ознаки (скажімо, дрібні пухлини) займають мізерну частку пікселів у зображенні, тоді як більшу частину складають здорові тканини [11]. Алгоритми, навчені на таких невірноважених даних можуть ігнорувати рідкісні, але важливі патології. По-третє, моделі, тренувані на зображеннях з одного медичного центру, нерідко втрачають точність на даних з інших установ через відмінності протоколів сканування чи популяції пацієнтів [12].

Значну роль також відіграє попередня обробка медичних зображень. Зазвичай перед подачею знімків в класифікаційну модель, їх піддають низці процедур покращення якості та виділення інформативних областей [13]. Серед типових методів можна виділити фільтрацію шумів з збереження, та виділення важливих структурних деталей з зображення. Одними з найпоширеніших підходів є згладжування гаусовим та медіанним фільтрами, які ефективно зменшують імпульсні та гаусові шуми, водночас мінімізуючи спотворення контурів анатомічних об'єктів [14]. Не менш важливим кроком є сегментація областей інтересу – автоматична або ручна розмітка контурів зони ураження на знімках, щоб сконцентрувати подальший аналіз лише на релевантних пікселях [15]. Крім цього, у деяких випадках може бути здійснена нормалізація інтенсивностей пікселів та підсилення контрасту. Для КТ-знімків це реалізується шляхом встановлення відповідного вікна яскравості (діапазону HU) для легеневої тканини [16].

У рамках аналізу медичних зображень не менш цікавим є метод генерування теплових карт, візуалізації, що підсвічують найбільш значущі області, зокрема, в задачах глибокого навчання подібні карти (наприклад Grad-CAM) дозволяють інтерпретувати, на які зони зображення модель звертає увагу при прогнозуванні класу [17].

Крім глибоких нейромережових підходів в медичній візуалізації також традиційно використовуються методи класифікації засновані на власноруч побудованих ознаках та шаблонах. Вони передбачають ручне конструювання дескрипторів зображення з подальшою подачею їх у класичні алгоритми машинного навчання, такі як логістична регресія, машина опорних векторів, випадковий ліс тощо [18]. Зокрема, відомим методом є локальні бінарні шаблони (LBP), це текстурний дескриптор, що кодує локальні патерни яскравості пікселів і узагальнює їх у вигляді гістограми частот появи певних бінарних шаблонів [19]. Подібні ознаки успішно застосовувалися для класифікації медичних зображень, так, наприклад, у випадку КТ-зображень легень дослідники вилучили десятки текстурних характеристик, серед яких статистичні характеристики Гаралика на основі матриць співвідношення сірих рівнів та ознаки LBP, і використовували їх для розрізнення типів вузлів за допомогою традиційних класифікаторів [20]. Часто перед подачею в класифікатор застосовують методи відбору найбільш інформативних ознак, щоби відкинути корельовані або нерелевантні та зменшити розмірність. Перевага подібних підходів у тому, що вони є ефективними на малих вибірках, зменшують ризики перенавчання і дозволяють інтерпретувати внесок кожної ознаки у рішення. Недоліками ж є сильна залежність якості ознак від обраних методів і зниження надійності у разі неправильного відбору.

Беручи до уваги викладені проблеми, у даній роботі пропонується власний підхід до попередньої обробки КТ-зображень, ідея якого полягає в побудові універсального фільтра який відсіюватиме з зображення неінформативні пікселі за інтенсивністю.

II. МЕТА РОБОТИ

Обґрунтування корисності клас-балансного відбору інтенсивностей, як

універсального етапу попередньої обробки КТ-зображень легень, що концентрує сигнал в інформативних ділянках, пом'якшує дисбаланс класів і підвищує придатність даних для подальшого текстурного аналізу та класифікації.

III. МЕТОДИ РЕАЛІЗАЦІЇ

У даній роботі використано клінічний набір даних КТ-зображень легень з наявними ураженнями ракових пухлин, наданий Національним науковим центром фтизіатрії, пульмонології та алергології імені Ф.Г. Яновського (опис набору клінічного матеріалу наведено у таблиці 1).

Таблиця 1 Опис набору клінічних даних

ID	К-ть зрізів	К-ть масок	Діагноз	Клас
1_0000	446	44	Низькодиференційована аденокарцинома	1 - adeno
1_0001	245	25	Бронхогенна диференційована плоскоклітинна карцинома	1 - adeno
1_0002	391	19	Інвазивна аденокарцинома змішаної будови-муцинозної та колоїдні	1 - adeno
1_0003	80	48	Плоскоклітинна карцинома без ороговіння	3 - flatNO
1_0004	456	26	Первинна плоско клітинна карцинома	1 - adeno
1_0005	436	23	Плеоморфна веретено клітинна та гігантоклітинна карцинома	1 - adeno
1_0006	416	30	Бронхогенна плоско клітинна карцинома з ороговінням	2 - flatO
1_0007	401	56	Інвазивна аденокарцинома змішаної гістологічної структури	1 - adeno
1_0008	411	23	Карциноїд (доброякісна пухлина)	4 - carc
1_0009	523	18	Протокова карцинома слинної залози (аденокарцинома)	1 - adeno
1_0010	531	22	Низькодиференційована плеоморфна веретено клітинна карцинома	1 - adeno
1_0011	461	7	Аденоїд-кістозна карцинома	1 - adeno
1_0012	638	34	Аденокарцинома колоїдного типу	1 - adeno
1_0013	582	36	Атиповий карциноїд (доброякісна пухлина)	4 - carc
1_0014	451	39	Плоскоклітинна карцинома із ороговінням	2 - flatO
1_0015	441	14	Плоскоклітинна карцинома без ороговіння	3 - flatNO
1_0020	472	25	Дрібноклітинний рак	0 - small
1_0021	492	70	Дрібноклітинний рак	0 - small

3.1 Загальний опис роботи алгоритму

Кожне значення інтенсивності в градаціях сірого на КТ-знімках оцінюється з огляду на його внесок у розрізнення класів на основі всього навчального набору, після чого обчислюється певна глобальна вага класової значущості для цього рівня яскравості. Інтенсивності, що мають низьку вагу, тобто майже однаково часто трапляються у всіх класах і не несуть дискримінаційної інформації, виключаються з подальшого розгляду. Натомість інтенсивності з високою класовою вагою зберігаються, оскільки саме вони містять найбільше інформації для розрізнення. Подібно до методу Оцу, який у випадку двокласової

Усі зображення були переведені у легеневий режим відображення (рівень -600 HU, ширина вікна 1500 HU, значення в одиницях Гаунсфілда) та конвертовані з формату DICOM у .tiff з градацією сірого від 0 до 255 (8-бітне сірошкальне зображення).

Визначення областей інтересу було здійснено вручну у присутності лікаря-пульмонолога. У підсумку збережені бінарні маски, які надалі накладаються на оригінальні зрізи з ураженням та приховують усю непотрібно інформацію крім самої зони ураження. Знімки за типом патології були агреговані у більш крупні класи.

сегментації автоматично підбирає поріг інтенсивності, максимізуючи міжкласову варіацію [21], підхід, описаний у даній статті, поширює ідею порогування за інтенсивністю у багатокласовому сценарії. Саме такий підхід визначається як клас-балансний відбір інтенсивностей, що відбирає інформативні діапазони яскравості та дозволяє на глобальному рівні збалансувати вклад різних класів та відсіяти нерелевантні області зображень. Виходом алгоритму є перетворення вхідних зображень на теплові карти (з англ. heatmaps), що зважають збережені пікселі за частотою або рідкісністю інтенсивностей на глобальному рівні. Очікується, що така універсальна попередня обробка підвищить стійкість подальшої

класифікації, особливо в умовах обмежених даних, за рахунок фокусування моделі на найбільш показових ознаках кожного класу. Детальна покрокова робота алгоритму описана далі.

3.2 Попередня обробка та побудова локальних частот

На вхід алгоритму подаються зображення пацієнтів згруповані по класах (типах патології). Кожному знімку привласнено код пацієнта та класу до якого він належить, аби уникнути перемішування вибірки. Зображення приймається у сірошкальному каналі і подальші розрахунки спираються на одну скалярну інтенсивність. За необхідності застосовується рівномірне квантування, щоб зменшити варіативність і стабілізувати оцінки на невеликих вибірках, а також щоб нівелювати вплив шуму зображення.

Нехай L — кількість рівнів після квантування (деяке ціле число від 2 до 255), тоді $s_q = (L - 1)/255$ — коефіцієнт масштабування; $I_x(u) \in \{0, \dots, 255\}$ — інтенсивність пікселя з координатами u на зображенні x . Квантизована інтенсивність задається формулою:

$$I_x^{(Q)}(u) = \frac{1}{s_q} \text{round}(s_q I_x(u)), \quad (1)$$

що стискає близькі значення до спільних інтенсивностей (бінів) і підвищує узгодженість гістограми. Далі для кожного зображення обчислюється 256-бінова гістограма $h_x(i)$, де $i \in \{0, \dots, 255\}$ — індекс біну, а $h_x(i)$ — кількість пікселів із інтенсивністю i . Задля того щоб зробити оцінки між зображеннями співставними, вводиться нормований локальний розподіл частот $\chi = \{1, \dots, 255\}$, значення фону, тобто $i = 0$, ігнорується.

Позначимо кількість пікселів, що входить у нормування:

$$N_x = \sum_{i \in \chi} h_x(i), \quad (2)$$

а також локальну частоту бінів i для зображення x :

$$t_x(i) = \begin{cases} \frac{h_x(i)}{N_x}, & i \in \chi \\ 0, & i = 0 \text{ і фон ігнорується} \end{cases} \quad (3)$$

Операція нормування на даному етапі є важливою, адже прибирає залежність від розміру виділеної зони інтересу, а виключення нульового біна запобігає домінуванню тривіально великих темних областей (фон поза межами зони інтересу).

3.3 Агрегація на рівні пацієнта та класу

Кількість зрізів із зонами інтересу певного діагнозу для певного пацієнта може відрізнятися, що безумовно впливатиме на представленість класу. Щоб один пацієнт не переважив іншого, частки всередині кожного пацієнта усереднюються, після чого та сама операція здійснюється між пацієнтами в межах класу. У результаті маємо для кожного класу один акуратний профіль інтенсивностей (під профілем мається на увазі вектор інтенсивностей), де кожен пацієнт важить однаково.

Отже, для нейтралізації даного ефекту розподіли спершу усереднюються всередині кожного пацієнта окремо, за наступним принципом, нехай $\chi_{c,j}$ — множина зображень класу c , що належить пацієнту j , тоді середнє визначається як:

$$t'_{c,p} = \frac{1}{|\chi_{c,j}|} \sum_{x \in \chi_{c,j}} t_x \quad (4)$$

де $|\chi_{c,j}|$ — це кількість знімків даного пацієнта. Наступним кроком є агрегація на рівні класу. Репрезентативний розподіл для класу отримується шляхом усереднення середніх по пацієнтах даного класу.

Нехай P_c — множина пацієнтів у класі c , тоді:

$$t^{(c)} = \frac{1}{|P_c|} \sum_{j \in P_c} t'_{c,j} \quad (5)$$

після чого вводиться повторне нормування і весь вектор масштабується так, щоб $\sum_{i=0}^{255} t^{(c)}(i) = 1$. Отриманий вектор є масштабно-інваріантним описом типового розподілу інтенсивностей у класі, нечутливим до внутрішньокласових дисбалансів.

3.4 Глобальна клас-балансна гістограма

Ключовим агрегатом є середнє по класах, яке інтерпретується як маса біну інтенсивності з погляду рівноправного врахування всіх класів, тобто усі класи ставляться в рівні умови через рівноправне усереднення їхніх розподілів. Глобальна маса для кожного рівня сірого володіє атрибутами спільного голосування: якщо інтенсивність важлива в різних класах — вона отримає вищу вагу, якщо вона трапляється нечасто — буде низькою, в інших випадках вага буде посередньою. Нехай C — множина всіх класів, $|C|$ — кількість класів, $s_{global}(i)$ — глобальна збалансована оцінка між класами важливості бінів i . Визначається як:

$$s_{global}(i) = \frac{1}{|C|} \sum_{c \in C} t^{(c)}(i), \sum_i s_{global}(i) = 1 \quad (6)$$

s_{global} трактується як глобальна маса інтенсивностей у сенсі класового балансу, де великі класи не домінують, оскільки кожен з них робить однаковий внесок. Паралельно акумулюється сукупна глобальна гістограма $H(i)$ — загальна кількість пікселів у всьому наборі, які мають інтенсивність із індексом i . Формально:

$$H(i) = \sum_{c \in C} \sum_{x \in \chi_c} h_x(i) \quad (7)$$

3.5 Відбір набору інтенсивностей за масою

Метою є відібрати якомога менше інтенсивностей (бінів), водночас, зберегти задану частку глобальної маси пікселів. Іншими словами це відповідь на питання: як обрати мінімальний набір рівнів сірого, який зберігає потрібну частку змісту. Нехай $\alpha \in (0,1]$ — деяка бажана частка маси, $S_{base} \subseteq \{0, \dots, N\}$ — шуканий набір індексів бінів. Базовий набір визначається як найменша за потужністю (частотою) множина, для якої виконується нерівність:

$$\sum_{i \in S_{base}} s_{global}(i) \geq \alpha \quad (8)$$

Практично виконується процедура жадібного алгоритму, де інтенсивності пікселів впорядковуються за спаданням $S_{base}(i)$ відносно їх частоти і послідовно додаються до моменту, поки кумулятивна сума не перевищуватиме поріг α .

3.6 Фільтрація інтенсивностей зображень

Після визначення найбільш представлених градацій на глобальному наборі зображення фільтрується маскою інтенсивностей, тобто пікселі, значення яких належать множині S_{base} , зберігаються, решта ігнорується. Фактично це є операцією фільтрації де знімок очищується від усього, що є малозначущим для задачі. Якщо визначити операцію фільтрації як $F_x(u)$, тоді:

$$F_x(u) = \begin{cases} I_x(u), & \text{якщо } I_x(u) \in S_{base} \\ 0, & \text{інакше} \end{cases} \quad (9)$$

Щоб якось інтерпретувати збережені пікселі й підкреслити їхню інформативність, за визначеним глобальним набором будується теплова карта через вагову таблицю "інтенсивність-вага". Для цього використовується частотний профіль, вага біну з індексом i дорівнює глобальному лічильнику $L_i^{frequency} = H(i)$. На основі цього формується теплова карта для зображення x , як $M_x(u) = L_{I_x(u)}^{frequency}$ для пікселів, інтенсивність яких належить до S_{base} та $M_x(u) = 0$ поза межами набору. Дана карта відображає наскільки часто певна інтенсивність трапляється у всьому наборі, чим частіше зустрічається бін, тим більша вага.

У підсумку весь процес виглядає як конвеєр. Дані перетворюються в простішу форму, прибирається вплив фону та розміру, урівноважуються пацієнти та класи, визначається, які рівні сірого справді важливі, відбираються найнеобхідніші й зображення очищується таким чином, щоб залишити тільки ці рівні. Теплова карта додає пояснювальний шар, показує де саме на зображенні присутні типові або, навпаки, рідкісні для всього набору інтенсивності.

Результати та обговорення

Для тестування роботи запропонованого алгоритму фільтрації, було використано клінічний набір КТ-зображень легень із гістологічно підтвердженими типами раку (табл. 1). У цьому підрозділі основний фокус спрямований на тому, як саме налаштовується й працює фільтр, які величини він змінює в зображеннях та які показники при цьому можна отримати.

При завантаженні знімків з'являється можливість переглянути розподіл частот відтінків сірого на суміші усіх зображень в межах класу. Вже на цьому етапі було помічено розбіжності у амплітуді розподілів (рис. 1). Пікові значення частот для суміші зображень дрібноклітинного раку у 1.5 рази більші у порівнянні з аденокарцинома, у 3.5 рази у порівнянні з плоскоклітинним раком без ороговіння, та майже у 5.8 разів у порівнянні з плоскоклітинним раком з ороговінням та карциноїдом. Це зумовлено за рахунок більшої кількості зрізів з визначеною зоною інтересу та більшою їх площею на

знімках (рис. 1А). Саме тому критично важливо нормувати частоти, аби нівелювати цей ефект (рис. 1Б). Тим не менш, одразу можна побачити, що форма розподілу для дрібноклітинного раку істотно відрізняється від підтипів недрібноклітинного та карциноїда, що одразу говорить про те, що профіль інтенсивностей для першого відрізняється.

Також можна спостерігати дію операції квантування до рівня $L=128$ (рис. 1В) та $L=64$ (рис. 1Г), що дозволяє пригасити дрібні флуктуації між сусідніми рівнями, зменшити кількість унікальних бінів і, відповідно, розмір майбутнього базового набору S_{base} . Це також стабілізує класові профілі $t^{(c)}(i)$, спростить відбір і прискорить подальшу обробку та візуалізацію.

Водночас надто грубе квантування (зокрема при малих L) може зливати вузькі піки й тонкі структури, тож потрібен помірний компроміс між згладжуванням та збереженням деталей.




Рисунок 1. Гістограма частот розподілу градацій сірого по класах патологій: (А розподіл абсолютних значень частот; Б розподіл нормованих частот; В розподіл нормованих частот із квантуванням $L=128$; Г розподіл нормованих частот із квантуванням $L=64$)

Подальша обробка здійснювалась на трьох різних наборах налаштувань. За фіксованих умов, при яких $i = 0$ як фон, ігнорується, квантування встановлене на $L=128$, розглянуто три пороги маси α .

За агресивного відбору $\alpha \approx 0.3$ алгоритм повертає лише два біни у S_{base} , що дає глобальне покриття 30.08%. Така компресія різко підсилює класи карциноїда з покриттям, що сягає 47.23%, аденокарциноми 35.83%, для двох підтипів плоскоклітинного — 32.69% та 31.98%. Натомість клас дрібноклітинного раку майже не представлений 2.65%. При встановленому порозі до $\alpha \approx 0.5$, базовий набір розширюється до чотирьох бінів і глобальне покриття зростає до 50.82%. Покриття для окремих класів також збільшується, 61.96% для аденокарциноми, 62.11% для плоскоклітинного раку з ороговінням, 52.37% для плоскоклітинного без ороговіння та 71.68% для карциноїда. Водночас клас дрібноклітинного раку усе ще залишається слабко покритим 5.99%. При встановленому порозі $\alpha \approx 0.7$ маємо вісім бінів у S_{base} і глобальне покриття 71.87%. Саме на цьому кроці баланс між класами суттєво поліпшується: дрібноклітинний зростає до 55.17%, аденокарцинома — 78.25%, плоскоклітинні підтипи — 82.86% і 61.79%, карциноїд — 81.26%. Зведені результати по кожному набору налаштувань наведені у таблиці 2.

Таблиця 2 Параметри та покриття яскравості пікселів на глобальному наборі

Параметри			
α	0.3	0.5	0.7
К-ть бінів	2	4	8
Маса покриття, %	30,08	50,82	71,87
Покриття по класах, %			
0 - small	2,65	5,99	55,17
1 - adeno	35,83	61,96	78,25
2 - flatO	32,69	62,11	82,86
3 - flatNO	31,98	52,37	61,79
4 - carci	47,23	71,68	81,26

У випадку встановленого параметра $\alpha \approx 0.7$ можна спостерігати, як додавання ще кількох наймасивніших бінів добирає характерні інтенсивності для класів з іншим

профілем і фактично прибирає головний дисбаланс. Таким чином відсоток покриття по класу визначається тим, наскільки його розподіл інтенсивностей перетинається з базовим набором, якщо моди класу лежать у найбільш представлених бінах глобального набору, покриття високе. Це наочно демонструє різницю між профілями інтенсивностей зображень різних класів, водночас запропонований метод дозволяє сформулювати універсальне правило фільтрації зображень для інференсу, де мітка класу буде заздалегідь невідомо, гарантуючи що, щонайменше визначений відсоток покриття інтенсивностей для певного класу буде забезпечений. При цьому істотно зменшується розмірність, що безумовно вплине на обчислювальну складність при подальшому аналізі.

Відібрані інтенсивності застосовуються до зображень та зберігаються у вигляді теплових карт, де значення інтенсивності пікселя у своїй позиції заміщуються значенням його частоти на глобальному профілі (рис. 2).




Рисунок 2. Застосування операції клас-балансної фільтрації на КТ-зображеннях; А1) зріз з ураженням дрібноклітинного раку; А2) теплова карта з ураженням дрібноклітинного раку; В1) зріз з ураженням аденокарциноми; В2) теплова карта з ураженням аденокарциноми; Г1) зріз з ураженням плоскоклітинного раку з ороговінням; Г2) теплова карта з ураженням плоскоклітинного раку з ороговінням; Г1) зріз з ураженням плоскоклітинного раку без ороговіння; Г2) теплова карта з ураженням плоскоклітинного раку без ороговіння; Д1) зріз з ураженням карциноїда; Д2) теплова карта з ураженням карциноїда;

Щоб кількісно оцінити роботу фільтра, було обрано вихідний набір даних з алгоритму при встановленому рівні квантування $L = 128$ та параметра $\alpha \approx 0.7$. Розраховано набір показників, що охоплює п'ять вимірювань, а саме: баланс представленості класів — наскільки рівною є частка збережених пікселів або їхньої сумарної ваги у кожному класі відносно інших (CV(coverage) та max/min між класами); селективність відбору — міра, з якою фільтр відсікає нерелевантні інтенсивності (coverage в межах класу); концентрацію ваги — де вагами є скалярні значення карти, присвоєні кожному

збереженому пікселю, що відображають його внесок (Energy concentration, Gini, entropy, mean non-zero, sum values); просторову організацію — ступінь злитності, розмірності, гладкості контурів і топологічної складності збережених областей маски (Boundary Density, CompCount, Largest Component Ratio, Compactness Median, Euler, додатково просторова узгодженість за Moran's I); ознаки Гараліка (GLCM) — що характеризують повторюваність, однорідність, контраст і лінійну кореляцію сусідніх інтенсивностей.

Зведені результати по кожній з метрик наведені у таблиці 3

Таблиця 3 Показники текстурних характеристик між оригінальними зображеннями та тепловими картами

Метрика	Оригінальне зображення (медіана по класах)	Теплова карта (медіана по класах)	Різниця, %	Медіана Δ	Типовий діапазон	Опис
Баланс покриття (між класами)	CV=0.737; max/min=5.687	CV=0.447; max/min=3.207	-	CV -39.38%; max/min=43.60%	[0-100%]	Сильне вирівнювання представленості класів
Coverage (в межах класів)	0.00275421	0.00211334	-23.27%	-0.00050354	[0, 1]	Жорсткіший відбір у межах класів
Energy concentration	0.00138542	0.00190052	+37.18%	0.0005151	[0, 1]	Більша частка маси на меншій кількості пікселів
Gini	0.00994549	0.125489	+1161.77%	0.115544	[0, 1]	Посилення концентрації ваги (нерівномірність розподілу)
Entropy	6.58189	6.28873	-4.45%	-0.29316	> 0	Розподіл став більш піковим
Moran's I (маска)	0.937494	0.886506	-5.44%	-0.0389143	[-1, 1]	Менше суцільних плям
Boundary density	0.156724	0.573943	+266.21%	0.378327	≥ 0	Більше меж на площу
Largest component ratio	1	1	0.00%	0	[0, 1]	Домінантна компонента не зросла
GLCM energy	0.993428	0.993839	+0.04%	0.000411385	[0, 1]	Більше повторюваних локальних пар
GLCM contrast	0.41709	0.370998	-11.05%	-0.0456058	≥ 0	Менше різких локальних переходів
GLCM homogeneity	0.998582	0.997539	-0.10%	-0.00104255	[0, 1]	Невелике зниження однорідності
Compactness	1.33834	1.27324	-4.86%	-0.0651025	≥ 1	Форми окремих осередків трохи компактніші

З результатів можна спостерігати, що фільтрація суттєво вирівняла міжкласове

покриття (CV -39.38%, max/min -43.60%). Вага стала більш зосередженою на невеликій

підмножині пікселів (зростання Energy Concentration та Gini, зниження ентропії), але просторово ці осередки лишилися дрібнозернистими, про що свідчить зниження Moran's I та зростання Boundary Density, без приросту частки найбільшої компоненти. За текстурними ознаками спостерігається більше повторюваності пар зростання GLCM-energy, менше різких переходів зниження GLCM-contrast і невелике зниження однорідності GLCM-homogeneity. Отже у підсумку можна зазначити, що фільтр досягає мети, а саме підсвічує компактні "ядра" інтенсивностей, без утворення великих суцільних сегментів. Акцент у подальшому аналізі теплових карт доцільно робити на локальних/частотних патернах, які потенційно можуть слугувати структурними ознаками притаманними певному класу.

V. ВИСНОВКИ

Існуючі методи попередньої обробки медичних зображень переважно не застосовуються для комплексного аналізу вибірки, не усувають дисбаланс між класами та домінування фону. Запропонований універсальний клас-балансний фільтр, що на рівні всього набору даних формує базовий піднабір інтенсивностей. На відміну від класичних процедур згладжування, підхід цілеспрямовано пригнічує нерелевантні інтенсивності та підсвічує компактні ядра ознак. Результати фільтрації зберігаються у вигляді теплової карти, які можна використовувати для подальших текстурних чи класифікаційних методів.

Результати показали, що фільтр зберігає значну, але не всю частину змістовного сигналу (тобто фокусується на найтипівіших інтервалах яскравості), загальне покриття пікселів, що залишаються після фільтрації, досягає приблизно 72%, а покриття для окремих класів стає більш збалансованим (зокрема, для найбільш відмінного — близько 55%), при цьому варіативність між класами помітно зменшується (коефіцієнт варіації — на рівні близько 40% менший). Це свідчить, що відбір концентрує увагу на інформативних структурах і пригнічує фонові та випадкові значення, полегшуючи подальший аналіз.

Подальші дослідження будуть спрямовані на застосування отриманих теплових карт для

пошуку унікальних структур, які в свою чергу можуть слугувати унікальними диференціальними ознаками, що притаманні певному класу.

Фінансування. Даний проект не отримував зовнішнього фінансування.

Конфлікт інтересів. Автор статті заявляє про відсутність конфлікту інтересів.

Згода на публікацію. Усі особи, що мають відношення до рукопису дали згоду на публікацію даної роботи.

Подяка. Автори статті висловлюють окрему подяку д.б.н. Линнику Миколі Івановичу, за наданий набір клінічних даних та консультації.

ORCID ID та внесок авторів.

(A, B, C, D) Illia Davydovych [0000-0001-9987-8267](https://orcid.org/0000-0001-9987-8267)

(E, G) Ievgen Nastenka [0000-0002-1076-9337](https://orcid.org/0000-0002-1076-9337)

A – концепція роботи та дизайн; B – аналіз інформації; C – реалізація алгоритму через написання програмного коду; D – написання статті; E – критичний огляд статті.; G – остаточне схвалення статті.

ПЕРЕЛІК ПОСИЛАНЬ

- [1] World Health Organization. (n.d.). Strengthening medical imaging. World Health Organization. Retrieved November 1, 2025, from [\[who.int/activities/strengthening-medical-imaging/strengthening-medical-imaging\]](https://who.int/activities/strengthening-medical-imaging/strengthening-medical-imaging)
- [2] Alzain, A. F., Elhussein, N., Fadulelmulla, I. A., & others. (2021). Common computed tomography artifact: source and avoidance. *Egyptian Journal of Radiology and Nuclear Medicine*, 52, 151. <https://doi.org/10.1186/s43055-021-00530-0>
- [3] Brady, A., Laoide, R. Ó., McCarthy, P., & McDermott, R. (2012). Discrepancy and error in radiology: concepts, causes and consequences. *The Ulster medical journal*, 81(1), 3–9.
- [4] Pesapane, F., Codari, M., & Sardanelli, F. (2018). Artificial intelligence in medical imaging: Threat or opportunity? *Radiologists again at the forefront of innovation in medicine. European Radiology Experimental*, 2, 35. <https://doi.org/10.1186/s41747-018-0061-6>
- [5] Rehman, A., Khan, A., Fatima, G., et al. (2023). Review on chest pathologies detection systems using deep learning techniques. *Artificial Intelligence Review*, 56, 12607–12653. <https://doi.org/10.1007/s10462-023-10457-9>
- [6] Hosny, A., Parmar, C., Quackenbush, J., Schwartz, L. H., & Aerts, H. J. W. L. (2018). Artificial intelligence in radiology. *Nature reviews. Cancer*, 18(8), 500–510. <https://doi.org/10.1038/s41568-018-0016-5>
- [7] Hang Yu, Laurence T. Yang, Qingchen Zhang, David Armstrong, M. Jamal Deen, (2021) Convolutional neural networks for medical image analysis: State-of-the-art, comparisons, improvement and perspectives. *Neurocomputing*, 428, 1-15. <https://doi.org/10.1016/j.neucom.2020.04.157>
- [8] Chen, C., Isa, N. A. M., & Liu, X. (2024). A review of convolutional neural network based methods for medical image

- classification. *Computers in Biology and Medicine*, 185, 109507. <https://doi.org/10.1016/j.compbio.2024.109507>
- [9] Chen, X., Wang, X., Zhang, K., Fung, K.-M., Thai, T. C., Moore, K., Mannel, R. S., Liu, H., Zheng, B., & Qiu, Y. (2022). Recent advances and clinical applications of deep learning in medical image analysis. *Medical Image Analysis*, 79, 102444. <https://doi.org/10.1016/j.media.2022.102444>
- [10] Edelmers, E., Kazoka, D., Bolocko, K., Sudars, K., & Pilmane, M. (2024). Automatization of CT Annotation: Combining AI Efficiency with Expert Precision. *Diagnostics*, 14(2), 185. <https://doi.org/10.3390/diagnostics14020185>
- [11] Schutera, M., Rettenberger, L., Pylatiuk, C., & Reischl, M. (2022). Methods for the frugal labeler: Multi-class semantic segmentation on heterogeneous labels. *Plos one*, 17(2), e0263656.
- [12] Liang, X., Nguyen, D., & Jiang, S. B. (2020). Generalizability issues with deep learning models in medicine and their potential solutions: illustrated with cone-beam computed tomography (CBCT) to computed tomography (CT) image conversion. *Machine Learning: Science and Technology*, 2(1), 015007.
- [13] Trojani, V., Bassi, M. C., Verzellesi, L., & Bertolini, M. (2024). Impact of Preprocessing Parameters in Medical Imaging-Based Radiomic Studies: A Systematic Review. *Cancers*, 16(15), 2668. <https://doi.org/10.3390/cancers16152668>
- [14] Bobby, S. M., & Sharmin, S. (2021). Medical image denoising techniques against hazardous noises: An IQA metrics-based comparative analysis. *International Journal of Image, Graphics and Signal Processing*, 13(2), 25–43. <https://doi.org/10.5815/ijigsp.2021.02.03>
- [15] Wang, C., Liu, L., Fan, C. et al. Lung adenocarcinoma subtype classification based on contrastive learning model with multimodal integration. *Sci Rep* 15, 30404 (2025). <https://doi.org/10.1038/s41598-025-13818-2>
- [16] Masoudi, S., Harmon, S. A. A., Mehravand, S., Walker, S. M., Raviprakash, H., Bagci, U., Choyke, P. L., & Turkbey, B. (2021). Quick guide on radiology image pre-processing for deep learning applications in prostate cancer research. *Journal of Medical Imaging*, 8(1), 010901. <https://doi.org/10.1117/1.JMI.8.1.010901>
- [17] Mastoi, Q.-u.-a., Latif, S., Brohi, S., Ahmad, J., Alqhatani, A., Alshehri, M. S., Al Mazroa, A., & Ullah, R. (2025). Explainable AI in medical imaging: An interpretable and collaborative federated learning model for brain tumor classification. *Frontiers in Oncology*, 15, 1535478. <https://doi.org/10.3389/fonc.2025.1535478>
- [18] Lin, W., Hasenstab, K., Moura Cunha, G., & Schwartzman, A. (2020). Comparison of handcrafted features and convolutional neural networks for liver MR image adequacy assessment. *Scientific Reports*, 10, 20336. <https://doi.org/10.1038/s41598-020-77264-y>
- [19] Li, H., Mukundan, R., & Boyd, S. (2021). Novel Texture Feature Descriptors Based on Multi-Fractal Analysis and LBP for Classifying Breast Density in Mammograms. *Journal of Imaging*, 7(10), 205. <https://doi.org/10.3390/jimaging7100205>
- [20] Saied, M., Raafat, M., Yehia, S. et al. Efficient pulmonary nodules classification using radiomics and different artificial intelligence strategies. *Insights Imaging* 14, 91 (2023). <https://doi.org/10.1186/s13244-023-01441-6>
- [21] Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 62–66. <https://doi.org/10.1109/TSMC.1979.4310076>

UDC 004.932.2:616-073.75

CLASS-BALANCED SELECTION OF INTENSITY INTERVALS FOR PREPROCESSING LUNG CT IMAGES

*Illia Davydovych*¹

davydovych@ill.kpi.ua

Ievgen Nastenko^{1,2}

bk-nastenko-fbmi@ill.kpi.ua

¹National Technical University of Ukraine
“Igor Sikorsky Kyiv Polytechnic Institute”
Kyiv, Ukraine

²State Institution “National Amosov
Institute of Cardiovascular Surgery of the
National Academy of Medical Sciences of Ukraine”
Kyiv, Ukraine

Abstract – Informative regions in medical CT images occupy only a small portion of the frame, while the background and other tissues largely dominate and affect the quality of subsequent analysis and classification. Deep neural networks are capable of automatically extracting informative features; however, class imbalance, small sample size, and heterogeneous data quality complicate both the training and interpretation of computer-aided diagnostic models. A possible solution is to employ classical machine-learning methods with manual feature-formation procedures, which require specific steps of data preprocessing. The aim of this study is to justify the usefulness of an image-preprocessing stage that focuses attention on meaningful parts of the image, mitigates class imbalance, and makes the data more suitable for further texture analysis and model building. The proposed method of class-balanced selection generalizes pixel-intensity distributions by sequentially aggregating them from the level of individual slices to that of the patient and the class, thus forming a consistent profile of prevalent values. A limited set of intensity intervals is then selected to cover a predefined fraction of the total intensity mass. The filtered images are stored as heatmaps of pixel-value frequencies, weighted according to their typicality within the dataset. The results showed that the proposed class-balanced filter makes informative structures more compact and distinctive while ensuring a more uniform representation of different classes. The heatmaps preserve the meaningful part of the signal while substantially reducing redundant information, which simplifies the extraction of informative features. The effect remains stable across various selection settings and is consistent at the patient level. The class-balanced selection of intensity intervals can thus be regarded as a practical preprocessing step for CT image analysis tasks. It focuses processing on the most relevant regions, balances class contributions, and enhances the interpretability and modeling suitability of the data, especially under small-sample conditions.

Keywords: CT images; image preprocessing; intensity-interval selection; class imbalance; texture analysis