

ЧАБАН ОЛЕКСАНДР

Хмельницький національний університет

<https://orcid.org/0009-0001-4710-3336>e-mail: entee94@gmail.com

МАНЗІЮК ЕДУАРД

Хмельницький національний університет

<https://orcid.org/0000-0002-7310-2126>e-mail: eduard.em.km@gmail.com

ДУКА ОЛЕКСАНДР

Хмельницький національний університет

<https://orcid.org/0009-0001-8231-856X>e-mail: s4n1220@gmail.com

МЕТОД ІНТЕГРУВАННЯ ДОМЕННИХ ЗНАТЬ У БАГАТОСТРАТЕГІЧНУ КЛАСИФІКАЦІЮ МЕДИЧНИХ ЗОБРАЖЕНЬ

Інтеграція доменних знань у процес класифікації медичних зображень має важливе значення для підвищення точності діагностування. У цій роботі запропоновано новий метод багатостратегічної класифікації, що інтегрує медичне доменне знання, та призначений для підвищення точності класифікації медичних зображень. У межах методу класифікатор навчався на прикладах, які були некоректно класифіковані іншими базовими класифікаторами, що сприяло колаборативному навчанню. Для навчання класифікаторів використовувались мультимодальні набори даних, які включали візуальні та табличні характеристики медичних зображень. Новий метод застосовувався до 160 зображень, тоді як контрольна група застосовувала традиційний одностратегічний метод до інших 160 зображень. Результати експериментів продемонстрували результативність запропонованого методу, зокрема, значення чутливості, специфічності та точності становили 98 %, 97 % та 96 % відповідно. У підсумку, результати дослідження підтверджують необхідність інтеграції експертних медичних знань у машинне навчання для підвищення прогностичної точності та надійності медичних діагностичних систем.

Ключові слова: аналіз медичних зображень, МРТ-зображення мозку, машинне навчання, доменні знання; багатостратегічна класифікація зображень.

CHABAN OLEKSANDR, MANZIUK EDUARD, DUKA OLEKSANDER

Khmelnytskyi National University

METHOD OF DOMAIN KNOWLEDGE INTEGRATION IN MULTI-STRATEGIC CLASSIFICATION OF MEDICAL IMAGES

The integration of domain-specific knowledge into medical image classification systems presents a promising approach to enhance the accuracy and interpretability of diagnostic models, particularly in the field of medical imaging. This study aimed to evaluate the efficacy of incorporating domain knowledge into multi-strategic classification algorithms for medical images, with a focus on magnetic resonance imaging (MRI) of the brain. This was a comparative, explorative study utilizing a newly developed multi-strategic classification framework that integrates medical domain knowledge into the classification process. The dataset comprised MRI scans of the brain, collected from three different medical institutions, totaling 320 images, which were annotated by expert radiologists. The framework employed basic classifiers, where each classifier was trained on examples incorrectly classified by another, fostering a collaborative learning environment. Performance was compared against traditional single-strategy classification methods. The integrated multi-strategic classification model demonstrated superior performance, achieving higher sensitivity, specificity, and accuracy with 98 %, 97 %, and 96 %, respectively. Furthermore, the model significantly improved the interpretability of diagnostic predictions, aligning closely with expert radiologists' assessments. The incorporation of domain-specific knowledge into the classification of medical images significantly enhances both the accuracy and the interpretability of the results. The multi-strategic approach allows for a more robust and nuanced understanding of complex medical images, such as MRI scans of the brain, potentially leading to improved diagnostic processes and outcomes in clinical settings. Future research should focus on expanding the types of medical images analyzed and further refining the integration techniques to encompass a broader spectrum of domain knowledge.

Keywords: medical image analysis, MRI brain images, machine learning, domain knowledge; multi-strategy image classification.

Вступ

Упродовж останніх років прогрес у технологіях отримання, аналізу та зберігання зображень призвів до значного зростання великих та деталізованих баз даних зображень [1]. Дослідження в галузі інтелектуального аналізу зображень, зокрема машинного навчання (МН), зазвичай класифікують у два основні напрями [2]. Перший напрям включає специфічні застосування, які ґрунтуються на вилученні найбільш відповідних та значущих ознак зображень для їхнього подальшого інтелектуального аналізу [3]. До другого напрямку варто віднести застосування генерації шаблонів зображень, що можуть бути корисними для розуміння взаємодії між високорівневими людськими сприйняттями зображень і низькорівневими ознаками зображень. Задача класифікації медичних зображень належить до першого напрямку.

Класифікація є класичною проблемою в галузі МН. Здебільшого методи класифікації ґрунтуються на одностратегічному підході з використанням одного алгоритму класифікації [4, 5]. Проте реальні об'єкти є занадто складними, щоб їх можна було правильно розпізнати з використанням лише одностратегічного підходу. Тому під час оброблення зображень із погано вираженими об'єктами на них, як от, медичні зображення комп'ютерної томографії (КТ) або магнітно резонансної томографії (МРТ), необхідно використовувати багатомодальний підхід із різними ознаками [6]: візуальними, текстовими, табличними

тощо. Досвід та експертне знання, що накопичені в процесі клінічної роботи лікарів, можуть позитивно сприяти медичному діагностуванню. Відповідно доцільним є введення доменних знань у процес класифікації медичних зображень. Отже, ця робота присвячена покращенню якості класифікації медичних зображень через інтегрування медичних доменних знань у багатостратегічну класифікацію медичних зображень.

Аналіз досліджень та публікацій

За останнє десятиліття різними науковими групами були запропоновані різноманітні методи виявлення аномалій у медичних зображеннях, зокрема вейвлети [7], статистичні методи [8] та нейронні мережі [9]. Здебільшого такі методи ґрунтуються на вилученні візуальних ознак за допомогою різноманітних способів оброблення зображень. Проте подібні підходи не можуть забезпечити високу точність виявлення за умови малих обсягів зображень у наборах даних.

У роботі [10] запропоновано метод класифікації медичних зображень на основі підсилення деревом рішень. Цей метод використовує структуру «дерево ймовірнісного підсилення», вузли якого відповідають класифікаторам, а зображення класифікуються на основі їхньої апостеріорної ймовірності, що розраховується кожним вузлом. Проте цей метод ґрунтується на одностратегічному підході. В іншій роботі [11] запропонували багатостратегічне візуальне навчання з поєднанням двох типів методів класифікації зображень: дерево рішень та дискримінантний аналіз. У цьому підході кілька класифікаторів за вилученням прихованих ознак інтегруються в ансамблевий класифікатор. Проте подібний підхід інтегрування через голосування є досить простим із погляду вилучення ціннісної інформації із зображень, а тому точність класифікації є досить низькою. Автори роботи [12] запропонували багатостратегічний метод класифікації зображень за допомогою багатостратегічного візуального навчання. Цей метод спільно здійснює навчання та інтегрування кількох візуальних навчальних модулів. Тут точність класифікації є вищою проти традиційних одностратегічних підходів до візуального навчання. Заразом обчислювальна складність методу в роботі [12] виявляється зависокою за умови значної кількості базових навчальних модулів. У нещодавній роботі [13], автори продемонстрували, що включення медичних доменних знань суттєво підвищує точність та інтерпретованість нейромережових моделей класифікації медичних зображень. Заразом однією з проблем такого підходу є залежність від якості та точності доменних знань, які використовуються для навчання моделей. Крім того, подібний підхід також збільшує складність нейромережових моделей, що призводить до збільшення обчислювальних витрат та часу для навчання.

Отже, з огляду на наявні складнощі в задачах класифікації зображень, дана робота присвячена підвищенню точності класифікації медичних зображень через інтегрування доменних знань медичної галузі в процес класифікації зображень у вигляді нового методу багатостратегічної класифікації.

Експериментальні дані та попереднє оброблення даних

У цій роботі використано набір даних МРТ-зображень мозку під назвою [14]. Спершу за допомогою методу поступового занурення [15] та з використанням знань медичної галузі були визначені області інтересу (ОІ) на МРТ-зображеннях мозку (рис. 1)




Рис. 1. Оригінальні МРТ-зображення мозку подано на а) та в); на рисунках б) та г) позначено обрані ОІ, що були визначені за допомогою адаптивного алгоритму

Далі було виконано попереднє оброблення зображень через усунення небажаних спотворень та покращення цільових ознак зображення для подальшого оброблення. За допомогою техніки попередньої обробки було усунуто нерелевантні дані, присутні на зображенні.

Насамкінець, проведено комбінування покращених ОІ за їхнім розташуванням, розміром та іншими описами, що в підсумку дало таблицю ознак. У цій роботі використано такі приховані ознаки: рівень сірого кольору об'єкта інтересу, площа об'єкта інтересу, розташування об'єкта інтересу, подовженість об'єкта інтересу, напрям об'єкта інтересу, симетрія об'єкта інтересу. У роботі [15] ці ознаки детально описані та формалізовані.

Метод інтегрування доменних знань (МІДЗ)

У цьому розділі формалізовано запропонований МІДЗ та описано два базові класифікатори в межах МІДЗ.

Onuc МІДЗ. Для першого класифікатора в межах МІДЗ використано алгоритм AdaBoost [16].

Вхідними даними AdaBoost є набір даних $\{(x_1, y_1), \dots, (x_m, y_m)\}$, де m – кількість прикладів у навчальному наборі, x_i є елементом простору ознак X , а y_i – елемент простору міток Y , $Y = \{0, 1\}$. У задачах класифікації медичних зображень зразок класифікації відповідає зображенню, x_i відповідає вектору ознак, наприклад, вектору інтенсивностей пікселів, а y_i відображає результат (нормальний або аномальний); тут ми позначаємо клас «нормальний» – 1, «аномальний» – 0.

Алгоритм AdaBoost використано для багатостратегічної класифікації, а кожен базовий класифікатор поміж усіх класифікаторів кількістю n позначено як L , $L = \overline{1, n}$. Коли ваги всіх навчальних зразків оновлюються в кожному раунді, результат класифікації розглядається для кожного базового класифікатора. Коли слабка гіпотеза H_{t+1}^L для L генерується на $(t + 1)$ -му раунді, ваги D_{t+1}^K зразків, що були неправильно класифіковані слабкими гіпотезами H_{t+1}^K , $k \neq L$, збільшуються. Отже, правило ваг для L -го базового класифікатора L визначається так

$$D_{t+1}^L(i) = \frac{\sum_{j=t+1}^n D_t^L(j) \exp(\alpha_t^j [y_i \neq h_t^j(x_i)])}{Z_t^L}, \quad (1)$$

де Z_t^L – це фактор нормалізації, за якого $\sum_{i=1}^m D_{t+1}^L(i) = 1$, та

$$\alpha_t^L = \frac{1}{2} \ln \left(\frac{1 + \gamma_t^L}{1 - \gamma_t^L} \right). \quad (2)$$

$$\gamma_t^L = \sum_{i=1}^m D_t^L(i) [y_i \neq h_t^L(x_i)]. \quad (3)$$

Для будь-якого предиката $[y_i \neq h_t^L(x_i)]$: якщо умова $[y_i \neq h_t^L(x_i)]$ виконана, то предикат дорівнює 1, в іншому випадку – 0. З рівняння (1) випливає, що D_{t+1}^L залежить від результатів навчання інших базових учнів J , $J \neq L$, та L інтенсивно вчить приклади, які були неправильно класифіковані J . Відповідно остаточну гіпотезу H^L базового учня L визначено так

$$H^L(x) = \arg \max_{c \in Y} H_T^L(x). \quad (4)$$

$$H_T^L(c, x) = \sum_{T=1}^t \alpha_T^L [h_T^L(x) = c], \quad (5)$$

де T є кількістю раундів.

Остаточна гіпотеза передбачає мітку класу прикладу на основі слабких гіпотез базових класифікаторів. Остаточна гіпотеза H розраховується через поєднання результатів навчання базових класифікаторів у такий спосіб:

$$H(x) = \arg \max_c \sum_{L=1}^n H_T^L(x). \quad (6)$$

Два базові класифікатори

1) Класифікатор С4.5. У цій роботі за перший базовий класифікатор використано С4.5 [5] як класифікатор на основі дерева рішень. Тут розглядається ОІ на зображенні, де кожен вузол дерева рішень С4.5 вибирає поміж ознак ОІ.

Після побудови дерева рішень використано алгоритм обрізання дерева зі зменшенням помилок [16]. Процес обрізання є таким: для вузла, що не є листком, обчислюється номер кожного класу в піддереві, де кореневий вузол не є листковим вузлом. Вузол обрізається до листового вузла, клас вузла є більшим класом. Далі обчислюється точність класифікації: якщо вона вища, ніж у попередньому дереві, вузол обрізається. Процес триває, доки будь-який вузол збільшує кількість помилок у тестовому наборі.

2) Класифікатор на основі зовнішнього вигляду (КоЗВ). Під час попереднього оброблення медичних зображень було зафіксовано кількість ОІ для кожного зображення. Зображення класифікуються за кількістю ОІ в кожному зображенні, а однакова кількість зображень розміщується в одну групу. Якщо зображення в одній групі мають однакове значення класу, то кількість ОІ використовується як метрика класифікації, інакше форма ОІ слугує якістю класифікації. Форма зразка є важливою ознакою для розпізнавання зразка. В іншій групі вилучаються фрагменти контуру ОІ за алгоритмом β -сходження до вершини [5]. Далі відбувається пошук значущих комбінацій. Описаний вище процес подано на рис. 2.

Взаємно суміжні фрагменти контуру визначаються як значущі комбінації на основі групування. Для пошуку значущих комбінацій встановлено умову взаємної суміжності двох фрагментів контуру в такий спосіб:

$$\min \{L_{11}, L_{12}, L_{21}, L_{22}\} < d, \quad (7)$$

де d є порогом, що визначається експериментально та приймає однакове значення для всіх зразків.




Рис. 2. Приклад процесу вилучення візуальних ознак: а) приклад взаємно суміжних фрагментів контуру; б) взаємно суміжні фрагменти контуру з вилученого фрагменту б)

Позначимо два фрагменти контуру як F_1 та F_2 , та кінцеві точки фрагмента контуру F_i як e_{i1} та e_{i2} , $i = \overline{1,2}$. Тоді L_{ij} є довжиною перпендикулярної лінії від e_{ij} до (продовженої лінії) іншого фрагмента контуру. Наприклад, L_{11} – це довжина перпендикулярної лінії від e_{11} до продовженої лінії F_2 . На рис. 2а) подано приклад взаємно суміжних фрагментів контуру. Якщо два фрагменти контуру F_1 та F_2 задовольняють умові, вони є взаємно суміжними і, отже, розглядаються як значуща комбінація. набір взаємно суміжних фрагментів контуру називаємо шаблоном; наприклад, три шаблони P_1 , P_2 та P_3 також показані на рис. 2б).

Ми визначаємо частотний шаблон як шаблон, який часто трапляється в прикладах у c -му класі. Зокрема, частота задовольняє умову:

$$\frac{n_c}{N_c} > p_0. \tag{8}$$

де n_c – кількість прикладів у c -му класі, які містять частотний шаблон, N_c – кількість ОІ у c -му класі, p_0 – значення порогу частоти, що визначається експериментально та має однакове значення для всіх c .

Якщо шаблон задовольняє умову (8), він вважається частотним шаблоном. Щоб знайти корисні частотні шаблони, ми визначаємо критерії для оцінювання корисності U частотного шаблону p для c -го класу так:

$$U_c(p) = \frac{n_c}{n_c + n_c^-}, \tag{9}$$

де n_c та n_c^- відображають кількість ОІ, які включають і не включають частотний шаблон p відповідно.

Значення корисності (9) використовується як вага для обчислення схожості та використовується для прогнозування класу даного зразка. Щоб визначити, чи є шаблон p схожим на шаблон q , ми визначаємо умови для кожного фрагмента контуру l_i^p та l_i^q в p та q відповідно так:

$$\text{Умова 1: } n_p = n_q = n.$$

$$\text{Умова 2: } \frac{1}{r} < |l_i^p| = |l_i^q| < r, \quad i = \overline{1, n}.$$

$$\text{Умова 3: } A(l_i^p, l_i^q) < \mu, \quad i = \overline{1, n}.$$

Тестовий приклад розпізнається за корисністю частотних шаблонів. Коли подається тестовий приклад, частотні шаблони $\{p_i\}$, $i = \overline{1, m}$ вилучаються з об'єкта, відповідно до нерівності (8), де m – кількість частотних шаблонів. Кожен шаблон p_i порівнюється з кожним корисним частотним шаблоном q_i^c , $i = \overline{1, m_c}$ для кожного класу $c \in Y$, де m_c – кількість частотних шаблонів у c -му класі. Значення схожості $\sigma(p_i, q_i)$ між p_i та q_i обчислюється для кожного частотного шаблону. Далі обчислюється впевненість S_c тестового ОІ для c -го класу. S_c відповідає ймовірності, що мітка класу прикладу відповідає c . S_c визначається як сума значень схожості в такий спосіб:

$$S_c = \sum_{i=1}^M \sigma(p_i, q_i), \tag{10}$$

де $M = \min\{m, m_c\}$.

Якщо p схожий на q , то значення $\sigma(p, q_i)$ дорівнює значенню $U_c(q_i)$, інакше $\sigma(p, q_i)$ дорівнює 0. Тоді впевненість зображення S_c^* є сумою S_c від його ОІ. Мітка класу зображення прогнозується як C^* так, що

$$C^* = \arg \max_c \{S_c^*\}. \quad (11)$$

З формули (11) маємо, що зразок відноситься до класу, який має найвищу впевненість. Запропонований МІДЗ добре працює під час пошуку більш частотних та унікальних шаблонів для зразків, які потрібно розпізнати.

Насамкінець, результативність МІДЗ була оцінена за допомогою таких статистичних показників:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}; \quad (12)$$

$$\text{Sensitivity} = \frac{TP}{TP + FN}; \quad (13)$$

$$\text{Specificity} = \frac{TN}{TN + FP}, \quad (14)$$

де TP, TN, FP і FN – кількість випадків істинно позитивних (аномальні випадки, правильно класифіковані), істинно негативних (нормальні випадки, правильно класифіковані), хибно позитивних (нормальні випадки, класифіковані як аномальні) і хибно негативних (аномальні випадки, класифіковані як нормальні) відповідно.

Точність (12) відображає співвідношення правильно діагностованих випадків від загальної кількості випадків, чутливість (13) вимірює здатність МІДЗ виявляти аномальні випадки, специфічність (14) – здатність МІДЗ виявляти нормальні випадки.

Результати обчислювальних експериментів

Для проведення обчислювальних експериментів із запропонованим МІДЗ використано набір реальних МРТ-зображень з онкологічної лікарні [19]. Відповідні медичні записи узагальнені як нормальні та аномальні. Два базових класифікатори C4.5 та КоЗВ були використані в межах МІДЗ. Кількість обчислювальних ітерацій була встановлена 25.

Результати обчислювальних експериментів свідчать про те, що запропонований МІДЗ демонструє високі значення чутливості, специфічності та точності, такі як 98 %, 97 %, та 96 %. Для підтвердження отриманих результатів МІДЗ було порівняно з методом, який використовує лише C4.5 та КоЗВ відповідно (рис. 3).

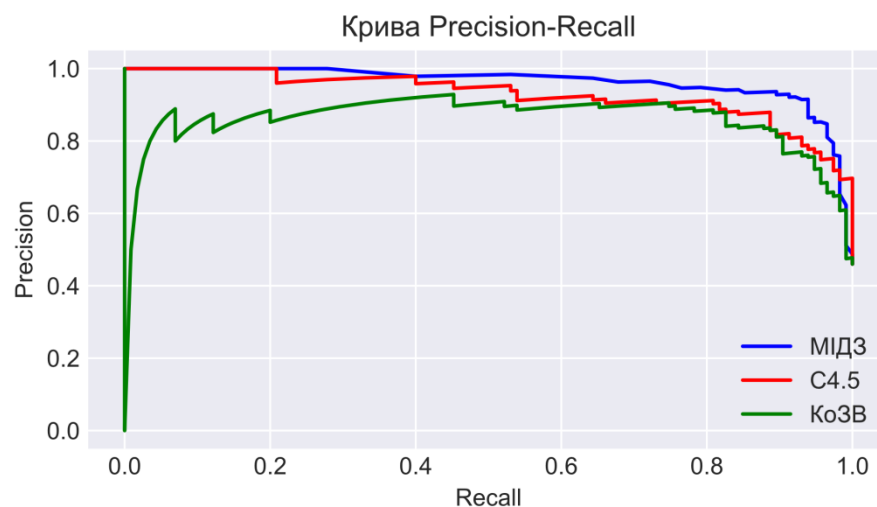


Рис. 3. Криві Precision-Recall, що демонструють точність класифікації МРТ-зображень мозку різними методами класифікації: МІДЗ – синій колір, C4.5 – червоний колір, КоЗВ – зелений колір

Запропонований МІДЗ показує кращі результати проти двох базових підходів з огляду на криві Precision-Recall, як показано на рис. 3.

Висновки

У цій статті проведено кількісне оцінювання доменних знань щодо МРТ-зображень мозку, результати якого були інтегровані в процес класифікації МРТ-зображень. У роботі запропоновано новий багатостратегічний метод на основі класифікатора AdaBoost та двох базових класифікаторів, C4.5 та зовнішнього вигляду. Результати експериментів продемонстрували відмінну запропонованого методу, зокрема, значення чутливості, специфічності та точності становили 98 %, 97 % та 96 % відповідно. МІДЗ також показав кращі результати проти двох базових класифікаторів з огляду на криві Precision-Recall.

Майбутні дослідження будуть присвячені інтегруванню медичного доменного знання в багатопарові нейронні мережі для мультимодальної класифікації медичних зображень.

Література

1. Challenges and issues of data analytics in emerging scenarios for big data, cloud and image mining / A. Madhuri et al. *Annals of the Romanian Society for Cell Biology*. 2021. Vol. 25, no. 1. P. 412–423. URL: <http://annalsofrscb.ro/index.php/journal/article/view/128>
2. Wang P., Fan E., Wang P. Comparative analysis of image classification algorithms based on traditional machine learning and deep learning. *Pattern Recognition Letters*. 2021. Vol. 141. P. 61–67. URL: <https://doi.org/10.1016/j.patrec.2020.07.042>
3. Feature extraction methods: A review / W. K. Mutlag et al. *Journal of Physics: Conference Series*. 2020. Vol. 1591, no. 1. P. 012028. URL: <https://doi.org/10.1088/1742-6596/1591/1/012028>
4. Approach to piecewise-linear classification in a multi-dimensional space of features based on plane visualization / I. Krak et al. *Advances in Intelligent Systems and Computing* / ed. by V. Lytvynenko et al. Cham, 2020. P. 35–47. URL: https://doi.org/10.1007/978-3-030-26474-1_3
5. Sen P. C., Hajra M., Ghosh M. Supervised classification algorithms in machine learning: A survey and review. *Advances in Intelligent Systems and Computing* / ed. by J. K. Mandal, D. Bhattacharya. Singapore, 2020. P. 99–111. URL: https://doi.org/10.1007/978-981-13-7403-6_11
6. Robust R-peak detection using deep learning based on integrating domain knowledge / O. Kovalchuk et al. *The 6th International Conference on Informatics & Data-Driven Medicine (IDDM-2023)* : CEUR-Workshop Proceedings. Vol. 3609. (Bratislava, Slovakia, 17–19 November 2023) / ed. by N. Shakhovska et al. CEUR-WS.org, Aachen, 2024. P. 1–14. URL: <https://ceur-ws.org/Vol-3609/paper1.pdf>
7. Yadav S. P., Yadav S. Fusion of medical images using a wavelet methodology: A survey. *IEIE Transactions on Smart Processing & Computing*. 2019. Vol. 8, no. 4. P. 265–271. URL: <https://doi.org/10.5573/IEIESPC.2019.8.4.265>
8. Going deep in medical image analysis: concepts, methods, challenges, and future directions / F. Altaf et al. *IEEE Access*. 2019. Vol. 7. P. 99540–99572. URL: <https://doi.org/10.1109/ACCESS.2019.2929365>
9. Krak Iu., Barmak O., Radiuk P. Detection of early pneumonia on individual CT scans with dilated convolutions. *The 2nd International Workshop on Intelligent Information Technologies & Systems of Information Security (IntellTISIS-2021)* : CEUR-Workshop Proceedings. Vol. 2853. (Khmelnyskyi, Ukraine, 24–26 March 2021) / ed. by T. Hovorushchenko et al. CEUR-WS.org, Aachen, 2021. P. 214–227. URL: <http://ceur-ws.org/Vol-2853/>
10. Tumula S., Fathima S. S. Probabilistic graphical models for medical image mining challenges of new generation. *Knowledge Computing and its Applications: Knowledge Computing in Specific Domains: Volume II* / ed. by S. Margret Anouncia, U. K. Wiil. Singapore, 2018. P. 3–28. URL: https://doi.org/10.1007/978-981-10-8258-0_1
11. AugFPN: Improving multi-scale feature learning for object detection / C. Guo et al. *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition* : Proceedings, 14–19 June 2020. New York, NY, USA, 2020. P. 12595–12604. URL: https://openaccess.thecvf.com/content_CVPR_2020/papers/Guo_AugFPN_Improving_Multi-Scale_Feature_Learning_for_Object_Detection_CVPR_2020_paper.pdf
12. Self-supervised learning for medical image analysis using image context restoration / L. Chen et al. *Medical Image Analysis*. 2019. Vol. 58. P. 101539. URL: <https://doi.org/10.1016/j.media.2019.101539>
13. Classification of chest X-ray images by incorporation of medical domain knowledge into operation branch networks / T. Tsuji et al. *BMC Medical Imaging*. 2023. Vol. 23, no. 1. URL: <https://doi.org/10.1186/s12880-023-01019-0>
14. Chaki J., Wozniak M. Brain Tumor MRI Dataset. IEEE, 2023. (Preprint. IEEE ; 10.21227/1jny-g144). URL: <https://iee-dataport.org/documents/brain-tumor-mri-dataset>
15. A survey on incorporating domain knowledge into deep learning for medical image analysis / X. Xie et al. *Medical Image Analysis*. 2021. Vol. 69. P. 101985. URL: <https://doi.org/10.1016/j.media.2021.101985>
16. Sonavane R., Sonar P. Classification and segmentation of brain tumor using Adaboost classifier. *2016 International Conference on Global Trends in Signal Processing, Information Computing and Communication (ICGTSPICC)* : Proceedings, Jalgaon, 22 December 2016. New York, NY, USA, 2016. P. 396–403. URL: <https://doi.org/10.1109/ICGTSPICC.2016.7955334>