

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ



МЕТОДИ ТА ЗАСОБИ ІНТЕГРАЦІЇ ЗНАНЬ
В МОДЕЛІ ШТУЧНОГО ІНТЕЛЕКТУ
МЕДИЧНИХ ДІАГНОСТИЧНИХ КОМПЛЕКСІВ

Доповідач:

Чабан Олександр Романович

Наукові керівники:

Манзюк Едуард Андрійович, д.т.н., професор
Кльоц Юрій Павлович, к.т.н., доцент

Хмельницький – 2026

Аналіз проблеми зсуву домену та інтеграції знань

Актуальність: Визначено, що експоненціальне зростання обсягів діагностичних даних вимагає надійних CAD-систем.

Ключові проблеми Data-Driven підходів

- **Брак даних:** Обмеженість анотованих наборів.
- **Зсув домену (Domain Shift):** Падіння точності при зміні сканера (див. Рисунок 1).
- **Семантичний розрив:** Ігнорування знань.




Рисунок 1: Ілюстрація проблеми зсуву домену: відмінності у розподілі даних призводять до деградації точності.

Шляхи вирішення проблеми

Створення *гібридних архітектур*, які поєднують нейромережі з верифікованими анатомічними, фізіологічними, патологічними та процедурними знаннями.

Об'єкт дослідження

Об'єктом дослідження є процеси інтеграції знань та опрацювання даних у системах штучного інтелекту медичних діагностичних комплексів.

Предмет дослідження

Предметом дослідження є методи та засоби інтеграції експертних знань у моделі глибокого навчання для задач сегментації, класифікації медичних зображень та аналізу текстових клінічних даних.

Мета дослідження

Метою дослідження є підвищення точності та клінічної обґрунтованості процесу прийняття рішень у медичних діагностичних комплексах через створення методів та засобів інтеграції експертних знань у моделі штучного інтелекту.

1. Провести аналіз сучасного стану методів глибокого навчання та підходів до формалізації медичних знань, виявити наявні обмеження статистичних підходів та визначити перспективи створення гібридних архітектур.
2. Розробити метод адаптивної дистиляції знань від моделей-вчителів до моделі-учня для забезпечення точності процесу діагностування в умовах зсуву домену та обмеженої розмітки даних.
3. Розробити метод встановлення смислових зв'язків у медичних текстах через інтеграцію онтологічних знань та аналізу тональності в архітектуру нейронної мережі для підвищення точності інтерпретації клінічних записів.
4. Розробити метод сегментації зображень магнітно-резонансної томографії серця, що ґрунтується на синергетичному поєднанні механізму експертно-керованої уваги та спеціалізованої функції втрат із топологічними обмеженнями для забезпечення анатомічної коректності результатів.

5. Розробити метод ідентифікації патологій із використанням графової згорткової мережі, який інтегрує реляційні діагностичні знання та дає змогу моделювати взаємозв'язки між анатомічними структурами.
6. Спроекувати архітектуру інтелектуальної інформаційної системи інтеграції знань, яка забезпечує гнучке оброблення гетерогенних медичних даних та підтримку модульної взаємодії між компонентами сегментації, класифікації та аналізу текстів.
7. Виконати програмну реалізацію інтелектуальної інформаційної системи інтеграції знань на основі спроектованої архітектури, здійснити постановку експерименту та провести комплексні експериментальні дослідження для підтвердження підвищення точності та клінічної обґрунтованості процесу прийняття рішень у медичних діагностичних комплексах на еталонних медичних наборах даних.

1. Удосконалено *метод адаптивної дистиляції знань від моделей-вчителів до моделі-учня (EMTKD)*, який відрізняється від аналогів використанням динамічного ансамблю моделей-вчителів зі спеціалізованою моделлю для змагальної адаптації домену та механізмом селективної фільтрації, що дає змогу накопичувати досвід із різних клінічних доменів та передавати його компактній моделі-учню, підвищуючи в такий спосіб точність процесу прийняття рішень за варіативності вхідних даних.
2. Удосконалено *метод встановлення смислових зв'язків у медичних текстах (OPNI)*, який, на відміну від наявних, поєднує інтеграцію онтологічних знань та явне кодування інформації про тональність і заперечення, що підвищує точність інтерпретації клінічних записів та забезпечує логічну узгодженість висновків.

3. Розроблено новий *метод сегментації зображень магнітно-резонансної томографії серця (SKIF-Seg)*, який ґрунтується на синергетичному поєднанні механізму експертно-керованої уваги для фокусування на складних ділянках та спеціалізованої функції втрат із топологічними обмеженнями на основі знакової відстані, який, на відміну від наявних підходів, дає змогу явно кодувати вкладеність та суміжність анатомічних структур, що забезпечує підвищення точності визначення меж органів та усунення топологічних артефактів.
4. Розроблено новий *метод ідентифікації патологій серця за зображенням магнітно-резонансної томографії із використанням графової згорткової мережі, орієнтованої на знання (KI-GCN)*, який, на відміну від відомих рішень, реалізує парадигму реляційного міркування на графах, де вузли об'єднують гібридні візуальні та морфологічні ознаки, а матриця суміжності формується як суперпозиція просторових зв'язків та клінічних кореляцій із медичних настанов, що дає можливість підвищити точність класифікації діагнозів та забезпечити інтерпретованість прийнятих рішень.

Проблема

Медичні зображення з різних сканерів, протоколів та груп пацієнтів мають різні статистичні характеристики, що формує *доменний зсув*. Класичне тонке налаштування потребує значної розмітки в цільовому домені.




Рисунок 2: Адаптивна передача знань до моделі-учня за умов гетерогенності клінічних даних і дефіциту розмітки.

Ідея EMTKD

Як показано на рисунку 2, *Enhanced Multi-Teachers Knowledge Distillation* переносить узагальнену інформацію від колективу спеціалізованих моделей-вчителів до компактної моделі-учня: 1) ансамбль моделей-вчителів, 2) спеціалізований вчитель доменної адаптації та 3) селективна фільтрація помилкових знань.




Рисунок 3: Детальна структура методу: **блок 1** – динамічний ансамбль вчителів з адаптацією домену; **блок 2** – адаптивна дистилляція з агрегацією ознак; **блок 3** – компактна модель-учень (SSL).

Мета: Формування простору ознак, у якому мінімізується розбіжність між розподілами різних доменів і виділяються універсальні діагностичні шаблони.

Реалізація принципу змагального навчання (**DANN**), де модель оптимізується за двома конфліктними критеріями:

- **Діагностична точність:** Мінімізація помилки класифікації патології.
- **Доменна ентропія:** Екстрактор ознак намагається “обманути” дискримінатор домену.




Рисунок 4: Архітектура T_{DA} : розгалуження на класифікатор міток та дискримінатор домену з інверсією градієнта.

Ключовий механізм

Рисунок 4 ілюструє використання шару **градієнтної інверсії** (Gradient Reversal Layer), що змінює знак градієнта при зворотному поширенні, змушуючи мережу вивчати універсальні патерни.

1. Селективна фільтрація – захист від помилок: Механізм запобігає *негативному трансферу* знань.

Індикаторна функція відключає вчителів, прогноз яких не збігається з істинною міткою на валідаційній вибірці (Рівняння (1)).

$$m_{ij} = \mathbb{I} \left(\arg \max T_j(z_i; \theta_j^*) = y_i' \right), \quad z_i \in D_{S'}. \quad (1)$$

2. Агрегація знань (Knowledge Fusion) – формування еталону: Побудова узагальненого вектора через нелінійну проєкцію. Об'єднуються лише валідні ознаки вчителів та ознаки моделі адаптації домену (Рівняння (2)).

$$e_i^{KD} = \text{ReLU}(\mathbf{W}_2 \cdot \text{ReLU}(\mathbf{W}_1 \cdot \text{concat}(m_{ij}e_{ij}, e_{i,DA}) + b_1) + b_2). \quad (2)$$

3. Функція втрат дистилляції – навчання учня: Мінімізація відстані між простором ознак агрегатора та учня (Рівняння (3)), що змушує компакту модель відтворювати структуру знань ансамблю.

$$\mathcal{L}^{\text{Dist}} = \|e^{KD} - e^{ST}\|_2^2. \quad (3)$$

Сценарій експерименту: Моделювання умов «холодного старту» в новій клініці. Порівнюється ефективність адаптації при критичному дефіциті розмічених даних (від 500 до 2000 знімків) проти методів трансферного навчання.

Таблиця 1: Порівняння AUC-ROC (%) методів адаптації на тестовій вибірці.

Метод	500 зразків	1000 зразків	2000 зразків
Target Only (ResNet-18)	72,15 ± 1,20	75,40 ± 0,95	78,10 ± 0,80
Source Only (ResNet-50)	74,80 ± 0,00	74,80 ± 0,00	74,80 ± 0,00
Fine-tuning	76,50 ± 0,85	79,20 ± 0,70	81,50 ± 0,60
DANN [58]	77,10 ± 1,05	79,80 ± 0,90	82,20 ± 0,75
EMTKD (запроп.)	81,45 ± 0,65	83,90 ± 0,55	86,10 ± 0,50

Аналіз результатів (див. Таблицю 1):

- ▶ На мінімальній вибірці EMTKD перевершує змагальну адаптацію на **4,35%**, а класичне донавчання – на **4,95%**.
- ▶ Використання «темних знань» забезпечує вищу стабільність порівняно з навчанням на жорстких мітках.

Таблиця 2: Час навчання та складність моделей для адаптації домену.

Модель	год.	млн. параметрів
STM	5	25
DANN	6	30
MTKD	7	60
MTMS	9	65
EMTKD	12	70

Таблиця 4: Вплив AW, DA та SSL на результативність цільового домену (%).

Варіант	Accuracy	Precision	Recall	F1	AUC
без AW	84,0	83,0	83,5	83,2	88,5
без DA	81,2	80,0	80,5	80,2	85,0
без SSL	85,5	84,5	85,0	84,7	89,5
EMTKD	88,5	87,5	88,0	87,7	92,5

Таблиця 3: Інференс ONNX-провайдерів.

EP	медіана	P95	ГБ
CPU	5,3	6,6	3,2
CUDA	0,8	1,1	4,1
DirectML	1,2	1,6	3,8

Інтерпретація

Згідно з Таблицею 2, навчання ресурсомістке, але одноразове; під час інференсу (Таблиця 3) система не потребує вчителів, тому компактна модель придатна для практичної експлуатації.




Рисунок 5: Візуалізація адаптивних ваг для трьох вчителів на вибірці з 200 зразків цільового домену.

Зміст результату

Рисунок 5 ілюструє, що адаптивне зважування дає змогу системі враховувати компетентність кожного вчителя для конкретного зразка, а неперервні розподіли ймовірностей ансамблю діють як регуляризатор.

Постановка задачі (Medical Natural Language Inference, MedNLI)

Елемент набору MedNLI складається з пари текстових фрагментів: “*засновок*” (*premise*) та “*гипотеза*” (*hypothesis*). Завдання полягає у визначенні класу логічного відношення між цими твердженнями.

Фундаментальні виклики обробки:

- ▶ **Семантичний розрив (Implicit Knowledge):**
Суто текстові моделі не володіють фактами, що не вказані явно.
Приклад: Зв'язок “Лазикс → Діуретик” є очевидним для лікаря, але прихованим для неймережі.
- ▶ **Критичність заперечень:** Стандартні моделі часто плутають стани “Є пневмонія” та “Немає пневмонії” через високу лексичну схожість.

Запропонована гібридна архітектура:

Синергія трьох потоків інформації:

1. **Лінгвістичний контекст:** *BioELMo* – модель на базі PubMed.
2. **Структуровані знання:** *MultE* – векторизація графів знань UMLS.
3. **Аналіз тональності:** *Sentiment Vector* – явне кодування заперечень (інструмент MetaMap).



Рисунок 6: Загальна схема: Підготовка → Генерація мультимодальних векторів → Механізм уваги → Глибоке навчання (ESIM).

Вектор токена:

Відповідно до рисунка 6, формується як зважена сума компонентів (Рівняння (4)):

1. Знання UMLS (MultE): Вбудовування графів знань (див. Рисунок 7). Функція правдоподібності трійки (Рівняння (5)):

$$\phi(h, r, t) = \text{ReLU}(\mathbf{W}_r \mathbf{r} + b_r) \odot \dots \quad (5)$$

Моделює семантичні типи (Drug, Disease).





Рисунок 7: Фрагмент онтології.

2. Вектор тональності (MetaMap): Явне бінарне кодування. Як показано на рисунку 8:

- ▶ $s^w = 1$: Токен під запереченням.
- ▶ $s^w = 0$: Ствердження.



Експериментальна база: *MedNLI* – золотий стандарт клінічного NLI (1422 пари речень для тестування).

Таблиця 5: Порівняльна характеристика моделей на тестовому наборі MedNLI (%).

Модель	Accuracy	Precision	Recall	F1
BioELMo (Baseline)	79,73 ± 0,45	78,55 ± 0,50	78,15 ± 0,48	78,23 ± 0,46
ESIM-know (UMLS)	80,22 ± 0,40	79,05 ± 0,42	78,67 ± 0,45	78,76 ± 0,41
BioELMo + Sentiment	80,60 ± 0,38	79,48 ± 0,35	79,30 ± 0,39	79,19 ± 0,37
Гібридна модель (запроп.)	81,14 ± 0,31	80,08 ± 0,35	79,62 ± 0,40	79,85 ± 0,33

Інтерпретація результатів (Таблиця 5)

- **Приріст точності:** Гібридний підхід перевершує базову модель на **1,41%**, що є значущим для задач NLP.
- **Синергія:** Комбінація знань UMLS та тональності ефективніша за їх окреме використання.
- **Висновок:** точність інтерпретації клінічних записів зросла до **81,14%**, а F1 – до **79,85%**.




Рисунок 9: Підграф MultE: семантичний шлях “Лазикс” – “Діуретик”.

Рисунок 9 наочно демонструє, як інтеграція графів знань дозволяє моделі розпізнати приховані семантичні зв'язки між медикаментами та їхніми фармакологічними групами.

Обмеження стандартних CNN (U-Net)

Оптимізація піксельних метрик ігнорує глобальну топологію:

- **Розриви** в кільці міокарда.
- **“Острівці”** шуму в порожнинах.
- Некоректні **перетини** (ЛШ/ПШ).

Рішення: *Synergistic Knowledge Integration Framework (SKIF-Seg)* – поєднання уваги та топологічних обмежень.




Рисунок 10: Типові топологічні помилки (зліва) та їхнє виправлення запропонованим методом (справа).




Рисунок 11: Архітектура неймережевої моделі за методом SKIF-Seg з інтегрованими модулями **EGA** та функцією втрат **TAAC**.

Згідно з рисунком 11, архітектура включає:

- **EGA (Expert-Guided Attention; укр. “Експертно-керована увага”)**: Використовує зовнішні карти пріорів для фокусування на складних зонах.
- **TAAC**: Функція втрат на основі знакової відстані (SDF) для топологічної коректності.

Інтеграція апріорної карти

Нехай $x^{(l)}$ – карта ознак, $g^{(l)}$ – сигнал стробування, а $\pi^{(l)}$ – карта експертних знань.

$$q_{att}^{(l)} = \sigma_1(W_x x^{(l)} + W_g g^{(l)} + W_\pi \pi^{(l)} + b_g) \quad (6)$$

$$\alpha^{(l)} = \sigma_2(W_\alpha q_{att}^{(l)} + b_\alpha) \quad (7)$$

$$\hat{x}^{(l)} = \alpha^{(l)} \odot x^{(l)} \quad (8)$$

Обчислення уваги здійснюється через послідовність Рівнянь 6–8.







Рисунок 12: Деталізація модуля EGA: апріорна карта знань модулює потік ознак через пропускові з'єднання.




а) Бінарна маска M_k




б) Карта SDF Φ_k



Спрямовані всередину сили втрат, що коригують вихід ЛШ



Притягання до межі (Adjacency)



Запобігання перекриттю (Overlap)

Червоний: ЛШ, Зелений: Mio, Синій: ПШ, Оранжеві стрілки: Сили ТААС, Чорні стрілки: Сили відштовхування

Компоненти цільової функції

$$\mathcal{L}_{base} = \mathcal{L}_{Dice} + \lambda_{CE} \mathcal{L}_{CE} \quad (9)$$

$$\mathcal{L}_{contain} = \sum_x P_{LV}(x) \text{ReLU}(\phi_{Myo}^{out}(x)) \quad (10)$$

$$\mathcal{L}_{adj} = \sum_x P_{RV}(x) \text{dist}(x, \partial Myo) \quad (11)$$

$$\mathcal{L}_{SKIF} = \mathcal{L}_{base} + \lambda_{top} (\mathcal{L}_{contain} + \mathcal{L}_{adj}) \quad (12)$$

Анатомічна логіка

Згідно з рівняннями (10) та (11), втрата вкладеності штрафує пікселі ЛШ за межами міокарда, а втрата суміжності підтримує коректне прилягання ПШ.

Умови експерименту: Набір ACDC (100 пацієнтів), 4-кратна крос-валідація. Метрики: точність перекриття (DSC, %) та якість меж (HD95, мм).

Таблиця 6: Результати сегментації структур серця на ACDC за DSC (%) та HD95 (мм).


Модель	Лівий шлуночок		Правий шлуночок		Міокард	
	DSC	HD95	DSC	HD95	DSC	HD95
U-Net	93,0 ± 1,6	8,0 ± 2,2	90,0 ± 2,1	8,5 ± 2,5	85,5 ± 2,5	9,8 ± 3,1
U-Net + EGA	93,8 ± 1,5	7,2 ± 2,0	91,0 ± 2,0	7,8 ± 2,3	86,5 ± 2,4	8,9 ± 2,9
U-Net + TAAC	94,5 ± 1,4	6,5 ± 1,9	92,0 ± 1,8	7,0 ± 2,1	87,8 ± 2,2	7,5 ± 2,5
SKIF-Seg	95,5 ± 1,2	5,5 ± 1,8	93,0 ± 1,7	6,0 ± 2,0	89,0 ± 2,0	6,5 ± 2,3

Аналіз метрик (Таблиця 6):


- **Топологічна коректність:** Зниження HD95 для міокарда з 9,8 до **6,5 мм** свідчить про усунення розривів кільця.
- **Статистична значущість:** Покращення підтверджено ($p < 0,01$).

Ефект синергії:


- **EGA:** Локалізує складні межі.
- **TAAC:** Гарантує глобальну зв'язність.
- **Разом:** SKIF-Seg працює краще за суму компонентів.



(a) Базова U-Net: розриви міокарда



(b) SKIF-Seg: відновлена топологія



(c) Карта помилок

Рисунок 13: Візуальне порівняння: (a) базова U-Net з розривом міокарда; (b) SKIF-Seg з відновленою топологією; (c) візуальне подання карти помилок.

Як видно з рисунка 13, відновлення топологічної цілісності кільця міокарда усуває критичні артефакти, які інакше потрапляють у наступний етап класифікації за допомогою KI-GCN.

Метод KI-GCN: постановка задачі та концепція

Мотивація (Обмеження Pixel-based CNN):

Традиційні мережі ефективно вивчають локальні текстури, але ігнорують *глобальні анатомічні відношення*.

Запропоноване рішення: Перехід від пікселів до **графа пацієнта**:

- **Вузли:** Семантичні об'єкти (ЛШ, ПШ, 6 секторів міокарда), отримані після сегментації.
- **Редра:**
 - *Просторові:* фізична суміжність.
 - *Часові:* зв'язок фаз.




Рисунок 14: Схема побудови графа: перетворення масок сегментації у топологічну структуру для аналізу взаємозв'язків.

KI-GCN: інтеграція знань у структуру графа

1. Побудова матриці суміжності A :

Топологія графа визначається як суперпозиція фізичної суміжності та діагностичних правил за рівнянням (13)):

$$A = A_{\text{spatial}} + \gamma A_{\text{knowledge}}. \quad (13)$$

Механізм: $A_{\text{knowledge}}$ – це матриця з медичних настанов, яка “підсвічує” зв’язки між клінічно залежними структурами.




Рисунок 15: Формування матриці суміжності: накладання матриці експертних знань на матрицю просторової суміжності.

2. Гібридний вектор ознак вузла h_v :


$$h_v = [f_{\text{morph}}(v) \parallel f_{\text{deep}}(v)]. \quad (14)$$

Згідно з рівнянням (14), вузол агрегує явні морфометричні параметри та глибокі візуальні патерни.

Механізм інтерпретації: дає змогу визначити вклад кожного анатомічного сегмента у фінальний діагноз: **НН4**

$$h_{\text{graph}} = \sum_{i=1}^N \alpha_i h_i^{(L)}, \quad \alpha = \text{Softmax} \left(w_{\text{gate}}^T \tanh(W_{\text{gate}} H^{(L)T}) \right). \quad (15)$$

Механізм глобального пулінгу уваги (GAP)



Ілюстративний приклад: трансформація графа пацієнта під час інференсу




Рисунок 16: Візуалізація ваг α : для ARV модель фокусується на ПШ, для HCM – на міокарді.




Рисунок 17: Блок-схема графового логічного виведення за методом KI-GCN: динамічний процес перетворення піксельних масок у вузли графа пацієнта та обчислення фінальних ймовірностей діагнозів.

Умови: 5-кратна крос-валідація, 5 діагностичних класів (Норма, Інфаркт, DCM, HCM, ARV).

Таблиця 7: Класифікація 5 патологій серця на ACDC, 5-кратна перехресна перевірка.

Модель	Accuracy	Precision	Recall	F1	AUC
Базова CNN (3D ResNet)	$0,85 \pm 0,04$	$0,85 \pm 0,04$	$0,84 \pm 0,05$	$0,84 \pm 0,04$	$0,92 \pm 0,03$
Базова морфологія (SVM)	$0,89 \pm 0,03$	$0,89 \pm 0,03$	$0,88 \pm 0,04$	$0,88 \pm 0,03$	$0,94 \pm 0,02$
Класична GCN	$0,91 \pm 0,03$	$0,91 \pm 0,03$	$0,90 \pm 0,03$	$0,90 \pm 0,03$	$0,95 \pm 0,02$
KI-GCN	$0,94 \pm 0,02$	$0,94 \pm 0,02$	$0,94 \pm 0,02$	$0,94 \pm 0,02$	$0,97 \pm 0,01$

Висновок

Як видно з таблиці 7, введення матриці знань та гібридних ознак забезпечило приріст точності **+3,5%** порівняно зі стандартним GCN та **+9,0%** порівняно з CNN, забезпечуючи водночас прозорість рішень.

Архітектурна основа

Система ґрунтується на *модульній мікросервісній архітектурі* і здійснює масштабовану обробку гетерогенних медичних даних.

- ▶ рівень абстракції DICOM/NIFTI;
- ▶ обчислювальне ядро SKIF-Seg і KI-GCN;
- ▶ модуль інтеграції знань та аналізу клінічних текстів;
- ▶ інтерфейси завантаження, налаштування та візуалізації.




Рисунок 18: Блок-схема архітектури інтелектуальної інформаційної системи інтеграції знань програмного комплексу “IDK Medical AI”.

Програмна реалізація системи “IDK Medical AI”




Рисунок 19: Головне меню та інтерфейс імпорту й анонімізації DICOM-даних.




Рисунок 20: Меню сегментації з ймовірностями діагнозів.

Рисунки 19 та 20 ілюструють реалізацію завантаження даних, сегментацію, класифікацію та експорт результатів.

Таблиця 8: Час обробки одного 3D-об'єму.

Пристрій	Час (с)	Пам'ять (ГБ)
CPU (Xeon)	5,3	3,2
GPU (CUDA)	0,8	4,1
DirectML	1,2	3,8

Технічні висновки (за Таблицею 8):

- **Low Overhead:** Архітектурне ускладнення (EGA) додає лише **+5%** до часу інференсу.
- **Real-time:** GPU забезпечує діагностику менш ніж за 1 секунду.

Throughput vs. batch size by execution provider




Рисунок 21: Залежність пропускної здатності від розміру пакету даних.

Аналіз складності модулів “IDK Medical AI”

Таблиця 9: Аналіз обчислювальної складності для всіх розроблених модулів інтелектуальної системи.

Компонент / модель системи	Параметри, млн	GFLOPs	Цільове призначення
<i>Етап 1: Модуль дистиляції (EMTKD)</i>			
Ансамбль 3-х вчителів (ResNet-50)	$3 \times 25,5 = 76,5$	$3 \times 4,1 = 12,3$	Формування м'яких міток
Модель-учень (ResNet-18)	11,6	1,8	Інференс на слабких пристроях
<i>Етап 2: Модуль оброблення природної мови</i>			
BioELMo	93,6	15,2	Контекстуальне розуміння синтаксису
MultE	12,4	0,5	Вбудовування бази знань UMLS
<i>Етап 3: Модуль сегментації (SKIF-Seg)</i>			
Базова U-Net	31,0	65,5	Екстракція візуальних ознак
EGA + TAAC	+0,8	+1,2	Забезпечення анатомічної топології
<i>Етап 4: Модуль ідентифікації патологій (KI-GCN)</i>			
GCN (2 шари)	2,4	0,1	Фінальна клінічна класифікація

Висновок

Як узагальнено в таблиці 9, основне навантаження припадає на навчальні модулі, тоді як інференс підтримує практичне застосування як “друга думка”.

Статті у періодичних виданнях, включених до категорії «А» Переліку наукових фахових видань України, або у закордонних виданнях, проіндексованих у базах даних Web of Science Core Collection та/або Scopus

1. **Chaban O.**, Manziuk E., Radiuk P. Method of adaptive knowledge distillation from multi-teacher to student deep learning models. *Journal of edge computing*. 2025. Vol. 4, no. 2. P. 159–178. URL: <https://doi.org/10.55056/jec.978> (індексована в наукометричній базі Scopus)

Статті у наукових виданнях, включених до Переліку наукових фахових видань України:

2. **Чабан О. Р.** Метод інтеграції доменних знань на основі графових нейронних мереж для сегментації зображення МРТ серця. *Вісник Хмельницького національного університету. Серія: технічні науки*. 2026. Т. 361, № 1. С. 452–457.
3. **Чабан О. Р.** Метод поєднання контекстних векторних представлень слів із векторним поданням медичного домену. *Вимірювальна та обчислювальна техніка в технологічних процесах*. 2025. Вип. 82, № 2. С. 297–301.
4. **Чабан О.**, Манзюк Е., Дука О. Метод інтегрування доменних знань у багатостратегічну класифікацію медичних зображень. *Вісник Хмельницького національного університету. Серія: технічні науки*. 2024. Т. 337, № 3(2). С. 231–236.

Праці, які засвідчують апробацію матеріалів дисертації

5. Intelligent information system for knowledge integration into artificial intelligence models / **O. Chaban** et al. *Proceedings of the 2nd International Workshop on Advanced Applied Information Technologies: AI & DSS : CEUR-Workshop Proceedings*, Khmelnytskyi, Ukraine, Zilina, Slovakia, 5 December 2025. Aachen, 2026. P. 145–161. ([Scopus](#))
6. Knowledge-integrated graph networks for interpretable cardiac MRI analysis / **O. Chaban** et al. *Proceedings of the 8th international conference on informatics & data-driven medicine : CEUR-Workshop Proceedings*, Lviv, Ukraine, 19–20 November 2025. Aachen, 2025. P. 1–15.
7. EMTKD at the edge: An adaptive multi-teacher knowledge distillation for robust cardiac MRI classification / **O. Chaban** et al. *Proceedings of the 5th edge computing workshop (doors 2025) : CEUR-Workshop Proceedings*, Zhytomyr, Ukraine, 4 April 2025. Aachen, 2025. P. 42–57. ([Scopus](#))
8. **Чабан О. Р.**, Манзюк Е. А. Підхід до інтегрування експертних знань в модель U-Net для сегментування зображень МРТ серця. *Нейромережні технології та їх застосування НМТЗ-2024 : матеріали XXII Міжнар. наук. конф., м. Краматорськ-Вінниця-Тернопіль, 11–12 груд. 2024 р. Краматорськ, 2024. С. 145–149.*

9. **Чабан О. Р.**, Манзюк Е. А. Метод дистиляції знань від моделей-вчителів до моделі учня глибокого навчання. *Актуальні проблеми комп'ютерних наук АПКН-2024* : матеріали XVI Всеукр. науково-практ. конф., м. Хмельницький, 15–16 листоп. 2024 р. Хмельницький, 2024. С. 196–199.
10. **Chaban O.**, Manziuk E. Enhancing medical NLI with integrated domain knowledge and sentiment analysis. *Proceedings of the 12th international conference information control systems & technologies (ICST 2024)* : CEUR-Workshop Proceedings, Odesa, Ukraine, 23–25 September 2024. Aachen, 2024. P. 262–272. (Scopus)

Публікації, які додатково відображають наукові результати дисертації

11. Комп'ютерна програма “Інтелектуальна інформаційна система інтеграції знань в моделі штучного інтелекту медичних діагностичних комплексів” : а. с. 141364 Україна : CR3113021225 / **О. Р. Чабан**, Е. А. Манзюк, П. М. Радюк. № с202508817 ; заявл. 10.10.2025 ; опубл. 31.01.2026, Бюл. № 97. 20 с.
12. **Chaban O.** Integrating diagnostic models: a revolutionary approach in AI-driven healthcare. *AI-Driven Transformation: Mapping the Course for Future Business Landscapes* : Monograph / Gen. edit. O. Prokopenko, M. Jarvis, Tallinn: Teadmus OÜ, 2024, P. 204–216.

1. Проведено системний аналіз сучасних методів глибокого навчання, який засвідчив межі ефективності класичних підходів в умовах дефіциту даних. Виявлено ключові проблеми, зокрема «семантичний розрив» та зсув домену, що знижують довіру до систем. Обґрунтовано необхідність **створення гібридних архітектур**, які поєднують обчислювальну потужність нейромереж із верифікованими медичними знаннями.
2. Удосконалено метод адаптивної дистиляції знань EMTKD. Навчання на обмеженій цільовій вибірці (лише 500 зразків) дало змогу подолати проблему зсуву домену, забезпечивши загальний приріст якості адаптації на 8,8 % та підвищивши метрику **AUC-ROC до 81,45%** на наборі MIMIC-CXR. Складність навчання повністю компенсується високою швидкістю під час інференсу.
3. Удосконалено метод встановлення смислових зв'язків, що інтегрує онтологічні знання UMLS та аналіз тональності. Явне кодування заперечень дало змогу досягти **точності 81,14%** та показника F1-міри 79,85 % на еталонному наборі MedNLI, суттєво покращивши розпізнавання суперечностей і логічну узгодженість висновків.

4. Розроблено метод сегментації SKIF-Seg, що поєднує механізм експертно-керованої уваги та спеціалізовані топологічні обмеження. Це дало змогу зменшити відстань Хаусдорфа для міокарда з 9,8 мм до 6,5 мм та підвищити **коефіцієнт Дайса до 95,5%** для лівого шлуночка, математично гарантуючи анатомічну коректність масок.
5. Розроблено метод ідентифікації патологій KI-GCN, що моделює просторові та клінічні взаємозв'язки між структурами серця. Завдяки матриці суміжності досягнуто **точності класифікації 94,0%** (що на 9,0 % перевершує базові моделі CNN) та забезпечено інтерпретованість рішень через механізм глобальної субдискретизації уваги.
6. Спроектовано архітектуру інтелектуальної системи “IDK Medical AI”, що забезпечує гнучку обробку гетерогенних медичних даних. Наявність рівня абстракції даних та високопродуктивного ядра гарантує **ефективну взаємодію модулів** сегментації, класифікації та аналізу текстів у єдиному середовищі підтримки прийняття рішень.
7. Створено програмний комплекс “IDK Medical AI” та проведено емпіричні випробування на еталонних наборах даних MIMIC-CXR, ACDC та MedNLI. Інтеграція розроблених методів дала змогу **знижити часові витрати** на опрацювання клінічних випадків і підвищити точність ідентифікації патологій, що підтверджує технічну готовність системи до клінічної практики.

Доповідь завершено.

Доповідач: Чабан Олександр Романович
chabanolek@khnmu.edu.ua



Хмельницький національний університет