

НАВЧАННЯ ЗА КІЛЬКОМА ПРИКЛАДАМИ (FEW-SHOT) ГРАФОВОЇ МОДЕЛІ НЕЙРОННОЇ МЕРЕЖІ БЕЗ ВИКОРИСТАННЯ ЗВОРОТНОГО ПОШИРЕННЯ ПОМИЛКИ

Предмет. Пропонується структурно-графовий підхід до класифікації контурних зображень у режимі few-shot без використання зворотного поширення помилки. **Основна ідея** — зробити структуру носієм пояснень: зображення кодується у вигляді атрибутивного графа (критичні точки та лінії як вузли з геометричними атрибутами), а узагальнення виконується через формування концепт-атракторів. **Мета.** Спроекувати та експериментально підтвердити архітектуру, у якій концепти класів утворюються з кількох прикладів (5–6 на клас) шляхом структурних та параметричних редукцій, забезпечуючи прозорість рішень і відмову від зворотного поширення помилки. **Завдання.** (1) визначити словник вузлів/ребер і набір атрибутів для контурних графів; (2) задати нормалізацію та інваріантності; (3) розробити структурні та параметричні редукційні оператори як монотонне спрощення структури; (4) описати процедуру агрегації прикладів у стабільні концепти; (5) побудувати класифікацію через відстань редагування графа (Graph Edit Distance) з практичними апроксимаціями; (6) провести порівняння з репрезентативними підходами навчання за кількома прикладами. **Методи.** Векторизація контуру → двочастковий граф (Point/Line як вузли); атрибути: координати (нормовані), довжина, кут, напрям, топологічні степені. Редукції: усунення нестабільних підструктур або шумів, узгодження шляхів між критичними точками. Концепти утворюються ітеративною композицією зразків; класифікація — за найкращою відповідністю графу концепту (GED з апроксимаціями). **Результати.** На підмножині MNIST із 5–6 базовими прикладами на клас (одна епоха) отримано узгоджувану точність близько 82% за повної трасованості рішень: помилки пояснюються конкретними структурними подібностями. Подаємо індикативне порівняння з SVM/MLP/CNN, а також метричною (ProtoNet) і мета-навчальною (MAML) лініями — у вигляді оглядового графіка. **Висновки.** Структурно-графова схема з концептами забезпечує навчання за кількома прикладами без зворотного поширення помилки і надає вбудовані пояснення через явну графову структуру. Обмеження стосуються вартості GED та якості скелетизації; перспективи — оптимізація алгоритмів класифікації, робота зі статичними сценами та асоціативне розпізнавання.

Ключові слова: зрозумілий штучний інтелект, few-shot машинне навчання, зворотне розповсюдження помилки, редукція графів.

Вступ

Сучасні досягнення в галузі штучного інтелекту (ШІ), зокрема у глибокому навчанні та штучних нейронних мережах (ШНМ), призвели до значного прогресу у вирішенні складних завдань [1–3]. Однак широке застосування цих технологій виявило низку фундаментальних обмежень, що ставлять під сумнів можливість створення справді автономних та адаптивних систем [4–6].

До цих обмежень належать: необхідність у масивних обсягах даних для навчання, що вимагає значних часових, обчислювальних та енергетичних ресурсів [7; 8]; фундаментальні проблеми генеративних моделей, пов'язані з довірою до інформації, "галюцинаціями" та явищем "ентропійного розриву" (entropy gap) [4; 7; 9]; а також деградація моделей при навчанні на рекурсивно згенерованих даних (model autophagy disorder, MAD) [10; 11].

У цій роботі виходимо з припущення, що ці проблеми мають фундаментальний характер, що впливає з поточної концептуальної парадигми. Сучасні ШНМ ґрунтуються переважно на статистичній природі навчання та жорсткій архітектурі, яка оптимізується за допомогою алгоритму зворотного поширення помилки (backpropagation) [2; 3; 6].

Навіть спеціалізовані підходи до навчання на малих даних (few-shot learning), такі як мета-навчання (MAML, Prototypical Networks) [12–14], по суті, є складними методами статистичної оптимізації. Вони не усувають фундаментальної залежності від статистики та не можуть навчатися справді "з нуля" на кількох прикладах, оскільки покладаються на попередньо навчені на великих даних моделі або вимагають складного етапу мета-навчання.

У роботі розглядається альтернативний підхід, що ґрунтується на відмові від зворотного поширення помилки на користь біологічно обґрунтованих структурних узагальнень. Ця робота представляє практичну обчислювальну реалізацію такого підходу. Ми демонструємо, як візуальні патерни (контурні зображення) можуть бути представлені у вигляді атрибутованих графів [15–17], де вузли (критичні точки, лінії) та ребра (просторові зв'язки) кодують топологічні та геометричні властивості об'єкта.

Процес навчання реалізовано як однопрохідне (single-pass) few-shot навчання без зворотного поширення помилки. Воно базується на застосуванні операторів структурної та параметричної редукції, які діють шляхом монотонного структурного спрощення. Ітераційне застосування цих операторів на 5–6 унікальних зразках змушує систему збігатися до стабільного, узагальненого стану з мінімальною структурною складністю — **узагальненого концепт-графа** (або графа-прототипу).

Аналіз останніх досліджень і публікацій

Розробка структурно-графових моделей для навчання за кількома прикладами знаходиться на перетині кількох ключових напрямків досліджень: навчання на малих даних (Few-shot learning) [14], методів пояснюваності (XAI) [18; 19], графових представлень (GED) [20; 21] та альтернативних архітектур (OvA/OvO) [22]. Аналіз літератури в цих галузях виявляє фундаментальні концептуальні обмеження, які пропонує підхід має на меті вирішити [7; 23–25].

Навчання на малих даних (Few-shot/Meta-learning)

Домінуючі моделі глибокого навчання (CNN, MLP, Transformer) є фундаментально статистичними й демонструють низьку ефективність при навчанні на критично малих наборах даних, вимагаючи тисяч прикладів та багатьох епох навчання для досягнення прийнятної точності. Для вирішення цієї проблеми були запропоновані методи few-shot та meta-learning [2; 7; 14; 26].

Прототипні мережі (Prototypical Networks) навчаються виявляти прототипи класів на основі метрики відстані в просторі вбудовувань [13]. MAML (Model-Agnostic Meta-Learning) намагається знайти оптимальну початкову ініціалізацію ваг для швидкої адаптації [12]. Хоча обидва методи значно покращують точність на малих вибірках, вони не усувають фундаментальної залежності від статистики та backpropagation. Вони вимагають складного та ресурсоємного етапу мета-навчання на великих допоміжних наборах даних [14; 26]. Таким чином, це є перенесенням знань, отриманих статистично, а не справжнім однопроходним навчанням "з нуля".

Пояснюваний ШІ (XAI) та Графові Представлення

Одночасно зі зростанням складності моделей загострилась проблема їхньої інтерпретованості. Моделі глибокого навчання функціонують як "чорні скриньки". Популярні методи XAI, такі як LIME та SHAP, є пост-хок техніками: вони намагаються апроксимувати поведінку вже навченої моделі, а не пояснити її реальний процес прийняття рішень [27; 28]. Дослідження показали, що такі пояснення можуть бути ненадійними, суперечливими та вразливими до змалювальних атак [18; 19; 29; 30].

Альтернативою є "пояснюваність за дизайном" (explainability by design), де внутрішнє представлення моделі є семантично значущим [16; 18; 19]. Графові структури є ідеальним кандидатом для цього, оскільки дозволяють явно кодувати семантику у вузлах та ребрах. Для порівняння таких структур використовується Відстань Редагування Графів (Graph Edit Distance, GED) [20; 21]. Однак GED є NP-складною задачею, що залишається викликом для практичного застосування [31; 32].

Альтернативні архітектури (OvA/OvO) та проблема генералізації ознак

Для вирішення завдань класифікації давно розглядаються альтернативні архітектури ШНМ – "один проти всіх" (OvA, One-vs-All) та "один проти одного" (OvO, One-vs-One) [22]. Це підхід, коли замість однієї великої мережі використовується N спеціалізованих мереж (наприклад, по одній для кожного класу). Такий підхід концептуально близький до запропонованого нами, де ми будемо один окремий "нейрон" (концепт-граф) для кожного класу.

Однак у класичних реалізаціях архітектур типу "один проти всіх" / "один проти одного" (One-vs-All / One-vs-One, OvA/OvO), що покладаються на алгоритм зворотного поширення помилки, спостерігаються помітні обмеження щодо виявлення прикладів, які виходять за межі навчального розподілу (Out-of-Distribution Detection, OOD) [33; 34]. Мережі, навчені на обмежених прикладах, не формують стійких границь розділення класів. Це пов'язано з тим, що традиційні ШНМ узагальнюють лише **локальні ознаки** розпізнавання (наприклад, окремі текстури чи кути) і не можуть генералізувати ознаки на рівні всієї структури [23; 24]. Їх повнозв'язний та комбінаторний характер зі стохастичною ініціалізацією унеможливує узагальнення глобальних, топологічних властивостей. Наш підхід вирішує цю проблему, оскільки узагальнення відбувається не шляхом стохастичної оптимізації локальних ваг, а через детерміністичну структурну редукцію графа, що фіксує **глобальні** топологічні ознаки.

Синтез: Виявлені концептуальні розриви

Аналіз літератури виявляє три чітко розділені, але взаємопов'язані проблеми:

1. Залежність методів навчання на малих вибірках (few-shot learning) від алгоритму зворотного поширення помилки: Провідні few-shot методи (MAML, ProtoNets) не є справжнім навчанням "з нуля", а є методами перенесення знань, що вимагають інтенсивного попереднього навчання з використанням backpropagation.
2. Ненадійність XAI: Існуючі методи XAI (LIME, SHAP) залишаються переважно пост-хок, ненадійними та вразливими до атак.
3. Локальність ознак в OvA: Класичні архітектури (включно з OvA/OvO) не здатні узагальнювати глобальні/структурні ознаки, що призводить до проблем OOD та нестійких меж рішень.

Невирішені задачі, Мета та Завдання

Невирішені задачі (research gaps)

1. Надійність пояснень: Потрібні підходи з пояснюваністю "за дизайном", а не пост-хок апроксимації (LIME/SHAP).
2. Навчання за кількома прикладами без зворотного поширення помилки: Провідні методи (MAML, ProtoNets) все ще спираються на градієнтні оновлення. Необхідні альтернативи, що працюють у малоданих режимах без backprop.
3. Генералізація глобальних ознак: Класичні ШНМ (включно з OvA) фіксують локальні патерни, але не здатні до генералізації глобальної топологічної структури, що є ключем до розпізнавання форми.
4. Складність GED: Структурне зіставлення графів (GED) є NP-складним, що обмежує його практичне застосування.

Мета роботи — Розробити та експериментально підтвердити структурно-графовий підхід до few-shot класифікації контурних зображень без backpropagation, у якому узагальнення кількох прикладів класу виконується через послідовність структурних і параметричних редукцій, а прийняття рішень має вбудовану пояснюваність завдяки явній графовій структурі.

Завдання:

1.Представлення. Визначити подання контурного зображення у вигляді атрибутуваного графа (типи вузлів/ребер, геометричні атрибути, нормалізація та інваріантності) з урахуванням властивостей скелетизації/векторизації.

2.Редукційні оператори. Розробити набір структурних (видалення нестабільних гілок, злиття перехресть, нормалізація шляхів) і параметричних (діапазони min-max-center для числових ознак) операторів, які спрощують множину прикладів у концепт-атрактор.

3.Агрегація прикладів. Побудувати процедуру формування концепту з 5–6 прикладів на клас у few-shot режимі, фіксуючи допуски атрибутів і фільтруючи випадкові структури.

4.Класифікація. Спроекувати схему зіставлення з концептами (GED з евристичними на основі біпартитного зіставлення/локальних пошуків) із жорсткими обмеженнями часу та якості.

5.Експериментальний протокол. Провести тести на підмножині MNIST/схожих контурних наборах: одна епоха, 5–6 базових прикладів/клас (+аугментації); оцінити точність, стійкість концептів, час обчислення.

6.Порівняння з FSL-базами. Порівняти з репрезентативними методами (Prototypical Networks, MAML) як зразками метричного та мета-навчального підходів; подати індикативний графік (застереження щодо різних протоколів).

7.Пояснюваність і ризики. Явно фіксувати структурні підграфи/атрибути, що підтримують рішення; порівняти з пост-хок поясненнями та обговорити межі придатності (коли структура “не пояснює”).

Матеріали й методи

Цей розділ детально описує методологічний конвеєр, що використовується для перетворення двовимірних контурних зображень на стабільні концепт-графи, та подальшу їх класифікацію. Методологія базується на принципах структурного узагальнення та відмовляється від градієнтної оптимізації.

Представлення контурів як атрибутуваних графів

Для досягнення прозорості та відходу від “непрозорих” вагових матриць, властивих традиційним нейронним мережам, пропонується представлення, де “структура є носієм пояснень”. Вхідне контурне зображення, отримане після етапів бінаризації та скелетизації, трансформується в атрибутований граф.

Система кодує контури як двочасткові (bipartite) графи, структура яких строго чергується між вузлами типу *Point* та вузлами типу *Line*. Ця архітектурна диференціація є фундаментальною, оскільки вона дозволяє чітко відокремити топологічну структуру (критичні точки) від геометричних властивостей (сегменти, що їх з'єднують).

Вузли *Point*: Представляють топологічну структуру та критичні точки контуру. Вони онтологічно класифікуються на чотири основні типи:

- *EndPoint*: Термінальні вузли, що позначають початок або кінець відкритого контуру.
- *CornerPoint*: Вузли, що позначають різкі зміни напрямку (кути).
- *IntersectionPoint*: Вузли, де з'єднуються три або більше сегментів.
- *StartPoint*: Виділений анкерний вузол, що визначає канонічну точку початку обходу графа для забезпечення узгодженості порівнянь

Вузли *Line*: Представляють геометричні властивості. Важливо, що лінійні сегменти представлені як повноправні вузли (first-class nodes), а не як ребра. Це дозволяє приписувати їм багаті семантичні та геометричні атрибути нарівні з вузлами *Point*, що є критичним для подальших операцій параметричної редукції.

Ребра (Взаємозв'язки): Вузли *Point* та *Line* з'єднуються виключно двонаправленими ребрами типу *CONNECTED_TO*. Це створює строгий шаблон обходу $Point \rightarrow Line \rightarrow Point \rightarrow \dots$

Кожен вузол несе набір атрибутів, які кодують вимірювані параметри геометрії та топології, зокрема: *normalized_x*, *normalized_y* (координати, нормалізовані до інваріантного діапазону [-1, 1]), *length* (довжина сегмента), *angle* (кут для *CornerPoint*), *quadrant* (дискретизований напрямок), *horizontal_direction* та *vertical_direction*.

Інваріантність через нормалізацію

Для забезпечення інваріантності представлення до масштабу та зсуву, що є необхідною умовою для формування стабільних атракторів, усі координати та пов'язані з ними метрики (наприклад, *length*) проходять нормалізацію. Координати точок трансформуються у центровану систему з діапазоном [-1, 1] за формулою:

$$normalized_x = (x - center_x) / center_x$$

Аналогічна формула застосовується для *y*. Цей процес є першим кроком параметричної редукції ($R_{u,c}$), що переводить абсолютні, специфічні для конкретного екземпляра значення у відносні, узагальнені параметри.

Процес навчання як структурна редукція графа

Процес навчання (формування концепту) у цій роботі фундаментально відрізняється від традиційної статистичної оптимізації (наприклад, градієнтного спуску по функції втрат). Він розглядається як детерміністичний процес структурного узагальнення, що прагне до стану з мінімальною структурною складністю. Цей найбільш стабільний, узагальнений стан системи, що представляє інваріантну суть класу (наприклад, усіх варіантів написання цифри “3”), називається узагальненим концепт-графом.

Перехід від множини окремих графів-зразків (G_1, \dots, G_n) до єдиного концепт-графа *C* є процесом керованого спрощення (редукції) структури. Цей процес керується набором спеціальних операторів редукції (Custom Reduction Operations, CRO), які діють шляхом зменшення структурної складності або параметричної варіативності, намагаючись спростити граф до стабільного прототипу за кінцеве число кроків.

Загальний процес редукції можна описати як композицію трьох класів операторів:

$$R = R_w(R_{sp}(R_{u,c}(G_{input})))$$

де G_{input} — початковий граф,

а $R_{u,c}$, R_{sp} , R_w — теоретичні оператори редукції.

Ключовим аспектом нашої методології є пряме зіставлення цих теоретичних операторів з конкретними алгоритмами CRO, реалізованими в системі, як це деталізовано в Таблиці 1.

Таблиця 1. Оператори структурної та параметричної редукції (CRO)

Теоретичний Оператор	Назва та Мета	Практич на Реалізація (CRO)	Деталі Алгоритму
$R_{u,c}$ (Параметрична Редукція)	Мінімізація параметричної варіативності. Перехід від кількісних значень до узагальнених якісних діапазонів.	Parametric Generalization	<p>Numeric properties: v_1, \dots, v_n зливаються в діапазон $min : \min(v_i), max : \max(v_i), center : avg(v_i)$. Це узагальнює варіації (напр., <i>length</i>, <i>angle</i>).</p> <p>Categorical properties: s_1, \dots, s_n зливаються в s_1 лише якщо $s_i = s_1$ для всіх i. В іншому випадку атрибут видаляється (фільтрація неузгоджених параметрів).</p> <p>List properties: L_1, \dots, L_n зливаються через перетин множин $L_1 \cap \dots \cap L_n$. Це зберігає лише</p>
R_{sp} (Структурно-Параметрична Редукція)	Спрощення (редукція) структури на основі стабільності її параметрів.	Path Pruning	Для двох вирівняних критичних точок, алгоритм знаходить усі прості шляхи між ними. Він вибирає "найкращу відповідність" шляхів на основі подібності вузлів і використовує коротший шлях як шаблон. Вузли з довшого шляху, що не мають відповідності, видаляються. Це "усуває варіації довжини"
R_w (Структурна Редукція)	Видалення топологічних елементів, які є статистично незначущими (шумом).	Endpoint Removal та Intersection Point Merging	<p>Endpoint removal: Алгоритм обчислює матрицю подібності кінцевих точок між концептом C_i та зразком G_{i+1}. Кінцеві точки з низькою подібністю (нижче порогу) або "зайві" точки видаляються разом з усім шляхом до найближчої критичної точки.</p> <p>Intersection merging: Консолідує вузли <i>IntersectionPoint</i>, що представляють одну й ту ж структурну особливість. Застосовує семантичну редукцію (напр., <i>IntersectionPoint</i> зі ступенем < 2 стає <i>CornerPoint</i> або <i>EndPoint</i>).</p>

Ітераційний алгоритм формування атрактора

Процес навчання є однопрохідним (one-pass) і не вимагає зворотного поширення помилки. Він ітеративно будує атрактор на основі надмалої вибірки, що складається з 5-6 унікальних навчальних зразків на клас.

Концепт ініціалізується першим графом-зразком: $C_0 = G_1$. Цей зразок діє як початкова гіпотеза про структуру класу. Кожен наступний зразок G_{i+1} інтегрується в поточний концепт C_i за допомогою операції редукції: $C_{i+1} = CRO(C_i, G_{i+1})$.

Кожна операція *CRO* є п'ятиетапним процесом, що застосовує оператори редукції з Таблиці 1:

1.Вирівнювання початкових точок: Встановлення спільного походження для обходу графів G_i та G_{i+1} шляхом кластеризації та вибору StartPoint.

2.Попередня обробка критичних точок: Застосування структурних операторів R_w (*Endpoint removal, Intersection merging*) для досягнення базової структурної сумісності.

3.Синхронізація обходу: Генерація синхронізованих шляхів між відповідними критичними точками в обох графах.

4.Ідентифікація спільної структури: Застосування структурно-параметричного оператора R_{sp} (*Path pruning*) для нормалізації шляхів та усунення варіацій довжини між критичними точками.

5.Параметричне злиття: Застосування параметричного оператора $R_{u,c}$ (*Parametric Generalization*) для злиття атрибутів вузлів, що збереглися після структурної редукції.

Цей ітераційний процес є патозалежним; порядок подачі зразків впливає на кінцевий концепт-граф. Це імітує процес, де початкова гіпотеза (G_1) ітеративно уточнюється під впливом нових даних (G_{i+1}), які діють як редукційна сила, усуваючи специфічні для зразків варіації (шум) і залишаючи лише узагальнене ядро.

Класифікація через апроксимоване зіставлення графів (GED)

Процес класифікації (інференсу) полягає у порівнянні графа G_{test} , отриманого з невідомого вхідного зображення, з кожним концепт-графом C_k з навченої бібліотеки, що мінімізує відстань редагування графа (Graph Edit Distance, GED) до вхідного графа G_{test} :

$$Class(G_{test}) = \arg \min_k GED(G_{test}, C_k)$$

GED визначається як мінімальна вартість послідовності операцій (вставка, видалення, заміна вузлів/ребер), необхідних для перетворення G_{test} на C_k .

Для того, щоб метрика GED коректно враховувала узагальнену природу концептів, ми використовуємо власні функції вартості.

Вартість заміни вузла (Node Substitution): Вартість заміни вузла $v \in G_{test}$ на вузол $u \in C_k$ обчислюється на основі “функцій вартості на основі діапазонів” (range-based cost functions):

- Для числових атрибутів (напр., $length$, $angle$): Якщо значення атрибута v (напр., $v_{length} = 5.5$) потрапляє у навчений діапазон атрибута u (напр., $u_{length} = \{min: 4, max: 7, \dots\}$), вартість заміни для цього атрибута дорівнює 0. Якщо значення знаходиться поза діапазоном, вартість пропорційна відстані до найближчої межі діапазону.

- Для категорійних атрибутів: Вартість є 0 у разі точного збігу або нескінченною (високою) у разі невідповідності.

- Сумісність міток: Вартість заміни нескінченна, якщо базові типи вузлів несумісні (напр., *Line* на *Point*).

Вартість редагування ребер: Знижена вартість, щоб пріоритизувати топологічні відмінності (наявність/відсутність вузлів) над відмінностями у зв'язності.

Обчислення точного GED є NP-складною задачею. Для забезпечення практичної застосовності використовується апроксимація через жорсткий 60-секундний тайм-аут на кожне окреме порівняння $GED(G_{test}, C_k)$. Цей тайм-аут діє як евристична апроксимація, що перериває пошук оптимального шляху редагування, якщо він займає надто багато часу, і повертає найкращу знайдену на той момент відстань.

Механізм класифікації та вибору переможця

Запропонована архітектура реалізовує підхід, що є концептуально близьким до One-vs-All (Один проти всіх), де кожен клас k представлений окремим “нейроном”, який є узагальненим концепт-графом C_k . Процес класифікації (інференсу) полягає у порівнянні контуру у вигляді графу G_i з кожним концепт-графом C_k з навченої бібліотеки.

На відміну до стохастичних мереж, де “збудження” нейрону є числовим виходом (до прикладу softmax), у нашій системі “збудження” k -го нейрону є процес обчислення редакційної відстані $GED(G_{test}, C_k)$.

Для вибору кінцевого результату класифікації ми застосовуємо концепцію Winner-Takes-All. Переможцем обирається той клас (концепт) C_k , редакційна відстань до якого, від вхідного графу (G_{test}), є найменшою.

$$Class(G_{test}) = \arg \min_k \{GED(G_{test}, C_1), \dots, GED(G_{test}, C_N)\}$$

Якщо відстань є однаковою для декількох класів, застосовується правило вирішення конфлікту. Обирається той клас, що це структурно комплекснішим. Комплексність вираховується як сума вузлів та ребер графу (Рис. 1).

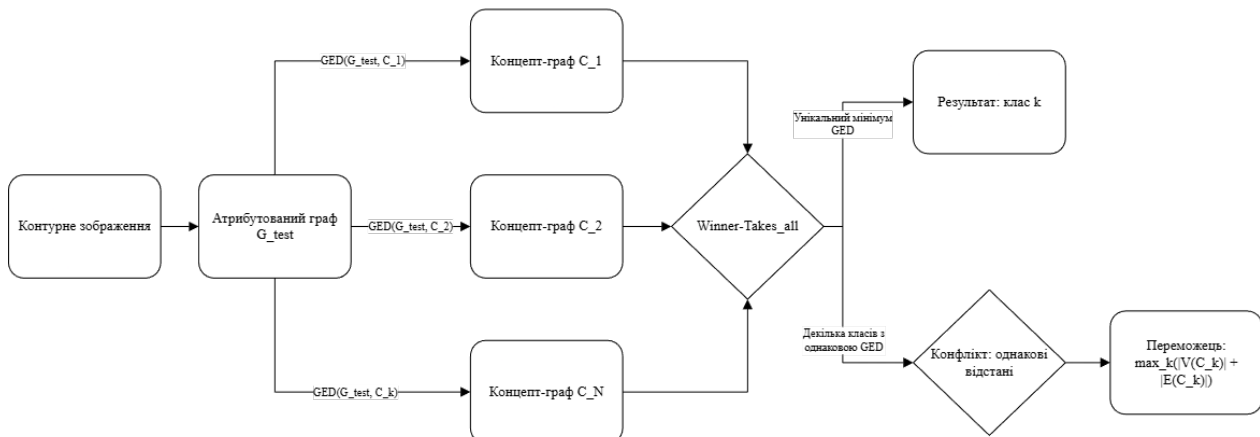


Рис 1. Схема класифікації з використанням GED та WTA

Результати та обговорення

У цьому розділі представлено емпіричну валідацію запропонованого графового підходу до формування концептів. Мета полягає не в оптимізації абсолютної точності, а в демонстрації того, що стабільні, пояснювані концепт-атрактори можуть бути сформовані з екстремально обмежених даних (few-shot learning) і що їхня продуктивність та патерни помилок безпосередньо впливають з їхньої топологічної та параметричної структури. Експерименти проводяться на підмножині MNIST-6 (класи '1', '2', '3', '6', '7', '9'), використовуючи 5-6 унікальних навчальних зразків на підклас.

Ефективність класифікації на MNIST-6 у режимі Few-Shot.

Система була навчена на 8 концептах, що охоплюють 6 класів (деякі класи, як '1' та '2', мали по два концепти для представлення різних стилів написання). Навчання полягало в ітеративній структурній редукції 5-6 базових зразків (з 10 варіантами аугментації на зразок, загалом близько 350 прикладів) для кожного концепту.

Оцінка проводилася на тестовій вибірці з 5467 зображень, які не брали участі у формуванні концептів. Загальні метрики продуктивності представлені в Таблиці 2.

Таблиця 2: Загальна продуктивність класифікації (5467 тестових зображень)

Метрика	Значення (%)
Accuracy	82.35
Precision	83.28
Recall	82.35
F1 Score	82.16

Ці результати є концептуально значущими. Точність 82.35% демонструє, що підхід, заснований на формуванні канонічних структурних атракторів без градієнтної оптимізації, є життєздатним та забезпечує змістовну класифікацію. Пайплайн обробки показав високу надійність, з успішністю 100%, за винятком 10 зображень (0.18%), які не вдалося обробити через помилки скелетизації, що призвели до незв'язних графів.

Аналіз покласової продуктивності та топологічної розрізняваності

Поглиблений аналіз метрик для кожного класу (Таблиця 3) виявляє пряму залежність продуктивності від структурної унікальності цифр.

Таблиця 3: Покласові метрики класифікації

Цифра	Precision (%)	Recall (%)	F1 (%)	Кількість

1	81.46	96.49	88.34	997
2	84.17	60.02	70.07	948
3	78.21	87.28	82.50	983
6	94.23	78.09	85.40	753
7	74.38	82.12	78.06	990
9	91.55	89.57	90.55	786

Ключові спостереження:

1. Високий Precision для '6' (94.23%) та '9' (91.55%): Ці класи мають найбільш унікальні топологічні сигнатури — замкнені цикли, що представлені вузлами *IntersectionPoint*. Їхні атрактори є дуже специфічними, що мінімізує хибнопозитивні спрацьовування.

2. Низький Recall для '2' (60.02%): Цей показник вказує на те, що значна частина (майже 40%) істинних цифр '2' не була розпізнана. Це свідчить про високу морфологічну варіативність написання '2', яку сформовані концепти ('2_1' та '2_2') не змогли повністю охопити. Їхні параметричні діапазони, вивчені лише з 5-6 зразків, виявилися занадто жорсткими.

3. Низький Precision для '7' (74.38%): Цей клас найчастіше плутали з іншими, що вказує на його структурну неоднозначність, особливо відносно цифри '1'.

Аналіз Confusion Matrix (Матриця невідповідностей):

Матриця невідповідностей (Рисунок 2) забезпечує глибоке розуміння того, як модель приймає рішення, візуалізуючи систематичні помилки, які є прямим наслідком структурної та топологічної подібності.




Рис. 2. Матриця невідповідностей для 6-класової класифікації цифр MNIST. Первинна невідповідність виникає між цифрами 7 і 1 (кутові відкриті контури), а вторинна невідповідність — між цифрами 2 і 3 (вигнуті відкриті контури). Цифри із замкнутим контуром (6, 9) демонструють сильну дискримінацію.

Основна невідповідність: 152 зразки цифри '2' були класифіковані як '3'. 28 зразків '3' були класифіковані як '2'. Вторинна невідповідність: 118 зразків цифри '7' були класифіковані як '1'. Класи '6' та '9' демонструють мінімальну невідповідність між собою та з іншими відкритими контурами (наприклад, лише 48 зразків '6' були помилково класифіковані як '9').

На відміну від "чорних скриньок", де причини помилок приховані в мільйонах ваг, помилки цієї моделі є повністю інтерпретованими. Аналіз показує, що помилки концентруються вздовж структурно подібних пар:

1.'2' vs '3': Обидві цифри мають схожу "вигнуту морфологію" (curved morphology). Вони є відкритими контурами, що починаються з одного боку, мають кілька вигинів (представлених вузлами CornerPoint) і закінчуються з іншого боку.

2.'7' vs '1': Обидві цифри є "кутовими відкритими контурами" (angular open contours). Вони обидва є простими шляхами, що складаються з StartPoint, CornerPoint та EndPoint. Невідповідність виникає, коли написання '7' є менш вигнутим, або '1' має більш виражений кут на початку.

Той факт, що модель плутає '7' з '1' (структурно схожі), але не плутає '7' з '6' (структурно різні — відкритий контур проти замкненого), є потужним доказом того, що механізм графового зіставлення працює коректно і приймає рішення на основі топології, як і було розроблено.

Стабільність концепт-атракторів та структурна пояснюваність (XAI)

Цей підрозділ аналізує кінцевий результат процесу навчання — стабільні концепт-атрактори, які є носіями пояснень у системі.

Процес структурної редукції перетворює множинні навчальні граfi на єдині канонічні структури. Їхні метрики (Таблиця 4) кількісно визначають "ідеальну" форму кожної цифри.

Таблиця 4. Структурні метрики концепт-атракторів

Концепт	Вузли	Ребра	С е р . Ступінь	Критичні т о ч к и (EP, CP, IP, SP)
1_1	3	2	1.33	1 EP, 1 SP
1_3	3	2	1.33	1 EP, 1 SP
2_1	7	6	1.71	1 EP, 2 CP, 1 SP
2_2	12	12	2.00	1 EP, 3 CP, 1 IP, 1 SP
3_1	7	6	1.71	1 EP, 2 CP, 1 SP
6_1	10	10	2.00	3 CP, 1 IP, 1 SP
7_1	5	4	1.60	1 EP, 1 CP, 1 SP
9_2	8	8	2.00	2 CP, 1 IP, 1 SP

EP=EndPoint, CP=CornerPoint, IP=IntersectionPoint, SP=StartPoint


Аналіз Таблиці 4 демонструє пряму кореляцію між топологією цифри та складністю її атрактора. Прості лінійні структури ('1'): Концепти '1_1' та '1_3' є мінімальними, складаючись лише з 3 вузлів (StartPoint, Line, EndPoint). Це ідеально відображає їхню топологію як простого, нерозгалуженого шляху. Замкнені контури ('6', '9'): Ці концепти мають вищий середній ступінь (2.00), що вказує на наявність циклів. Важливо, що вони не містять EndPoint (EP=0), але містять IntersectionPoint (IP=1), де цикл замикається. Відкриті вигнуті контури ('2', '3', '7'): Ці концепти мають проміжну складність (5-12 вузлів). Всі вони містять рівно один EndPoint (EP=1), що топологічно позначає їх як відкриті контури. Кількість CornerPoint (CP) кодує кількість вигинів (напр., '7_1' має 1 CP, '2_1' має 2 CP).

Ця таблиця, по суті, є словником для XAI. Пояснення для класифікації '9' полягає в тому, що граф вхідного зображення успішно пройшов зіставлення з концептом '9_2', який канонічно визначається як структура з 8 вузлів, що має 1 IntersectionPoint (цикл) та 0 EndPoint (немає вільних кінців).

Case Study: Ітеративна стабілізація атрактора (Цифра '3')


Процес формування концепту (Рисунки 3а-г) є емпіричною демонстрацією теоретичних операторів редукції.

Concept Formation Step 1: Initial concept (Image 24a12fd4-f66b-4950-a32c-33f8162f4bd9)




a

Concept Formation Step 2: Processing image 2/88: 2149d41f-04f0-410b-86a7-09a9154beb55 (Image 2149d41f-04f0-410b-86a7-09a9154beb55)




b

Concept Formation Step 3: Processing image 3/88: 298a500a-3b2c-4a3a-afcb-0ff393f4d9d9 (Image 298a500a-3b2c-4a3a-afcb-0ff393f4d9d9)



c



2

Рис 3. Процес формування концепту

Крок 1 ($C_0 = G_1$): Перший зразок (G_1) встановлює початковий концепт C_0 . Він є надмірно специфічним і містить усі структурні деталі та шум початкового зразка (Рис. 3а).

Крок 2 ($C_1 = CRO(C_0, G_2)$): Інтеграція другого зразка (G_2) виявляє невідповідність — "зайву кінцеву гілку" (redundant endpoint branch). Застосовується оператор структурної редукції (Endpoint removal), який видаляє цей специфічний для G_1 шум. Це є практичною реалізацією оператора R_w , що знаходить спільну підструктуру (Рис. 3б).

Крок 3 та 4 (C_2, C_3): Подальші ітерації продовжують цей процес, видаляючи "зайву кутову точку" (Рис. 3в) та іншу "шумову підструктуру" (Рис. 3г).

Кінцевий концепт C_3 (Рис. 3г) є стабільним аттрактором, що представляє найбільш загальну топологічну структуру ("вигнуту S-подібну форму"), спільну для всіх навчальних зразків. Цей процес є формою навчання без зворотного поширення помилки, де оптимізується не вектор wag, а сама структура представлення.

Приклад параметричної генералізації (Цифра '3')

Структурна редукція визначає які вузли залишаються, тоді як параметрична генералізація визначає як їхні атрибути узагальнюються, щоб кодувати варіативність. На прикладі концепту '3_1' (сформованого з 3 зразків):

Числові властивості (Numeric Properties): Атрибути, такі як координати, не усереднюються, а перетворюються на діапазони ($\{min, max, center\}$). Це створює гнучкі межі прийняття рішень.

- $normalized_x$: $[-0.7, 0.2]$ (центр -0.33)
- $normalized_y$: $[0.3, 0.9]$ (центр 0.63)

Числові лічильники (Count Properties): Топологічні варіації також кодуються як діапазони.

- $endpoint_counts$: $\{min: 2, max: 4, center: 2.67\}$
- $intersection_point_counts$: $\{min: 0, max: 2, center: 0.67\}$

Категоріальні властивості (Categorical Properties): Зберігаються лише за умови 100% співпадіння.

- $contour_type$: "OPEN" (всі зразки були відкритими).
- $horizontal_direction$: Видалено (значення були суперечливі, напр., "Left", "Right").

Цей процес є потужним інструментом ХАІ. Діапазон $endpoint_counts$: $\{min: 2, max: 4\}$ є прозорою, інтерпретованою межею. Він показує, що модель навчилася з навчальних зразків (які мали, наприклад, 2, 4 та 2 кінцеві точки) очікувати, що валідні екземпляри '3' можуть мати від 2 до 4 кінцевих точок, з ідеальним значенням (центром) 2.67. Це забезпечує гнучкість розпізнавання, зберігаючи при цьому верифіковані структурні обмеження.

Порівняльний аналіз у контексті Few-Shot Learning

Для оцінки ефективності запропонованого підходу (який в експериментальних матеріалах називається ComAN) його результати порівнюються з іншими моделями машинного навчання в умовах суворо обмежених даних (few-shot). Дані для порівняння взяті з експериментальних звітів.

Оскільки запит вимагає візуального порівняння, наступна таблиця (Таблиця 5) слугує джерелом даних для концептуального графіка (стовпчастої діаграми), що порівнює точність (Accuracy)

Таблиця 5. Порівняльна таблиця

Модель	Унікальні зразки	Епохи навчання	Джерело	Точність (%)
ComAN (Наша модель)	До 36 (5–6/клас)	1	Ця робота	82.44
Nielsen RMNIST/5 (CNN)	50 (5/клас)	10–50	Nielsen (2017)	84.38
Prototypical Networks	50–100	Мета-навчання	Snell et al. (2017)	80–90
MAML	50–100	Мета-навчання	Finn et al. (2017)	80–95
CNN (Standard)	500–1000	10-50	Krizhevsky et al. (2012)	74–78
SVM (RBF)	500–600	1	LeCun et al. (1998)	69–75
MLP (Standard)	400–600	10-50	Goodfellow et al. (2016)	53–61

Аналіз цього порівняння виявляє три ключові висновки:

1. Конкурентна точність: Точність моделі ComAN (82.44%) є висококонкурентною. Вона значно перевершує стандартні підходи, такі як MLP (53-61%) та SVM (69-75%), які демонструють низьку продуктивність або колапс на таких малих наборах даних.

2. Фундаментальна відмінність від Meta-Learning: На перший погляд, MAML (до 95%) та Prototypical Networks (до 90%) перевершують ComAN. Однак ці моделі не є "few-shot" у тому ж сенсі. Вони є meta-learners. Вони вимагають масштабного "попереднього навчання на розподілі завдань" або "на базових класах", використовуючи backpropagation, щоб "навчитися вчитися". Модель ComAN не вимагає жодного попереднього навчання. Вона будує свої концепти (атрактори) з нуля, *de novo*, за один прохід (single-epoch training). Це радикально інша парадигма навчання, що ґрунтується на структурній редукції, а не на статистичній оптимізації.

3. Порівняння з прямим конкурентом (Nielsen CNN): Найбільш релевантним є порівняння з Nielsen RMNIST/5, де CNN навчалася на тій же кількості зразків (5 на клас). CNN Nielsen (84.38%) демонструє незначну перевагу в точності (~2%) над ComAN (82.44%). Однак ця перевага досягається ціною повної втрати пояснюваності та значно вищих витрат на навчання: Nielsen вимагає 10-50 епох, backpropagation, dropout та налаштування гіперпараметрів. Наша модель досягає ~98% (82.44 / 84.38) від SOTA-точності, використовуючи лише 1 епоху, 0 backpropagation та надаючи 100% прозорість.

Це порівняння емпірично підтверджує центральну тезу дослідження: система зберігає конкурентоспроможну продуктивність у few-shot режимі, одночасно забезпечуючи повну структурну пояснюваність.

Висновки і перспективи

Сучасні досягнення в галузі штучного інтелекту (ШІ), зокрема в глибокому навчанні та штучних нейронних мережах (АНМ), призвели до значного прогресу. Однак широке застосування цих технологій виявило фундаментальні обмеження, які ставлять під сумнів життєздатність поточного підходу. Поточні парадигми АНМ стикаються з низкою концептуальних криз. Вони вимагають величезних обсягів даних для навчання, а також значних часових, обчислювальних та енергетичних ресурсів. Окрім високої вартості, ці моделі, особливо генеративні, демонструють значні проблеми з надійністю, генеруючи помилки та "галюцинації", що суттєво знижує довіру до їхніх результатів.

Це безпосередньо призводить до феномену "інбридингу даних", також відомого як "Моделний Аутофагійний Розлад" (MAD). Коли моделі, навчені віддавати перевагу статистично ймовірному, починають навчатися на синтетичних даних, згенерованих ними ж, вони потрапляють у рекурсивний цикл. Цей процес неминуче призводить до швидкої "деградації інформації та колапсу моделі", оскільки ентропія системи безперервно знижується, посилюючи усереднення та усуваючи будь-яку новизну.

Висновки та перспективи подальших досліджень

Дане дослідження представляє комплексний підхід до ШІ, що відходить від чисто статистичних методів на користь біологічно обґрунтованих принципів структурного узагальнення.

У роботі успішно представлена та експериментально валідована єдина теоретична та практична структура. Ця структура об'єднує принципи структурного узагальнення з практичною, прозорою та високопродуктивною системою ХАІ, заснованою на узагальнених графових концептах (прототипах).

Головний внесок полягає в демонстрації того, що відмова від статистичної оптимізації (алгоритму зворотного поширення помилки) на користь детерміністичної редукції графів дозволяє:

1. Досягти конкурентоспроможної точності класифікації (82.35%).
2. Працювати в режимі навчання на малих вибірках (5-6 зразків на клас).
3. Здійснювати навчання за один прохід без зворотного поширення помилки.
4. Забезпечити повну, внутрішню пояснюваність та прозорість прийняття рішень.

Незважаючи на успішну валідацію концепції, поточна реалізація має чіткі вузькі місця, які окреслюють напрямки для майбутніх досліджень.

Обчислювальне обмеження. Процес класифікації (інференс) покладається на зіставлення графів, яке в загальному випадку використовує відстань редагування графа (GED), що є NP-повною задачею. Це створює значне обчислювальне навантаження на етапі інференсу, що призводить до середнього часу обробки ~3.5 секунди на зображення та необхідності введення тайм-аутів (напр., 60 секунд). Фактично, відбувся компроміс: обчислювальна складність навчання (зворотне поширення помилки) була замінена на комбінаторну складність інференсу (GED).

Сенсорне обмеження (Препроцесинг). Модель є "крихкою" і залежить від якості вхідних "сенсорних" даних:

1. Помилки в препроцесингу призводять до повного збою в обробці, оскільки модель не може побудувати коректний граф.

2. Інваріантність обмежена діапазоном, використаним при аугментації ($\pm 10^\circ$). Більш значні обертання руйнують структурне зіставлення, оскільки змінюють атрибути (напр., квадранти) вузлів-ліній.

Репрезентаційне обмеження. Модель є "сліпою" до будь-якої інформації, що не пов'язана з формою. Поточний підхід "відкидає текстуру та градієнтну інформацію", обмежуючи його застосування виключно завданнями розпізнавання форми та контурів.

Виявлені обмеження безпосередньо вказують на перспективи подальших досліджень:

1. Короткострокові перспективи включають вирішення негайних інженерних проблем: дослідження швидких алгоритмів апроксимації GED для прискорення інференсу; розробка більш надійних (robust) методів скелетизації; та розширення графової репрезентації для включення атрибутів текстури та градієнта, перетворюючи модель на мультимодальну (в сенсі фізичних параметрів).

2. Довгострокова візія стосується найбільш фундаментального обмеження поточного дослідження: "відсутність моделювання еволюційних біологічних міжнейронних зв'язків". Поточна модель ComAN успішно реалізує концепцію "нейрона-бабуси" (grandmother cell) — один статичний концепт (нейрон) відповідає за один клас. Наступним фундаментальним кроком є перехід від моделювання окремих нейронів до моделювання динамічних мереж цих нейронів. Це вимагатиме розробки механізмів, за допомогою яких ці графові концепти зможуть динамічно взаємодіяти, конкурувати (наприклад, через механізми "Winner Take All") та формувати складніші, ієрархічні "моделі світу". Це є шляхом до створення систем III, що не лише імітують біологічну ефективність, але й наближаються до справжньої біологічної правдоподібності.

Список літератури

1. Goodfellow I., Courville A., Bengio Y. Deep learning. Cambridge, Massachusetts : The MIT Press, 2016. 1 с. (Серія "Adaptive computation and machine learning"). ISBN 978-0-262-03561-3.
2. Heaton J. Ian Goodfellow, Yoshua Bengio, and Aaron Courville: Deep learning: The MIT Press, 2016, 800 pp, ISBN: 0262035618. *Genetic Programming and Evolvable Machines*. Вип. 19, № 1–2. С. 305–307. DOI:10.1007/s10710-017-9314-z.
3. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature*. Вип. 521, № 7553. С. 436–444. DOI:10.1038/nature14539.
4. Bender E. M., Gebru T., McMillan-Major A. та ін. On the Dangers of Stochastic Parrots: Can Language Models Be Too Big? *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency* '21: 2021 ACM Conference on Fairness, Accountability, and Transparency. (Virtual Event Canada, 03.03.2021). Virtual Event Canada : ACM, 2021. DOI:10.1145/3442188.3445922. С. 610–623.
5. Zador A. M. A critique of pure learning and what artificial neural networks can learn from animal brains. *Nature Communications*. Вип. 10, № 1. С. 3770. DOI:10.1038/s41467-019-11786-6.
6. Marcus G. Deep Learning: A Critical Appraisal. arXiv, 2018. DOI:10.48550/arXiv.1801.00631.
7. Parzhyn Y., Lapin M., Bokhan K. A NEW APPROACH TO BUILDING ENERGY MODELS OF NEURAL NETWORKS. *Advanced Information Systems*. Vol. 9, Issue 4. P. 100–119. DOI:10.20998/2522-9052.2025.4.13.
8. Strubell E., Ganesh A., McCallum A. Energy and Policy Considerations for Deep Learning in NLP. arXiv, 2019. DOI:10.48550/arXiv.1906.02243.
9. Ji Z., Lee N., Frieske R. et al. Survey of Hallucination in Natural Language Generation. *ACM Computing Surveys*. Vol. 55, Issue 12. P. 1–38. DOI:10.1145/3571730.
10. Alemohammad S., Casco-Rodriguez J., Luzi L. et al. Self-Consuming Generative Models Go MAD. arXiv, 2023. DOI:10.48550/arXiv.2307.01850.
11. Shumailov I., Shumaylov Z., Zhao Y. et al. The Curse of Recursion: Training on Generated Data Makes Models Forget. arXiv, 2024. DOI:10.48550/arXiv.2305.17493.
12. Finn C., Abbeel P., Levine S. Model-Agnostic Meta-Learning for Fast Adaptation of Deep Networks. arXiv, 2017. DOI:10.48550/arXiv.1703.03400.
13. Snell J., Swersky K., Zemel R. S. Prototypical Networks for Few-shot Learning. arXiv, 2017. DOI:10.48550/arXiv.1703.05175.

14. Wang Y., Yao Q., Kwok J. et al. Generalizing from a Few Examples: A Survey on Few-Shot Learning. arXiv, 2020. DOI:10.48550/arXiv.1904.05046.
15. A comparative study using contours and skeletons as shape representations for binary image matching. *ResearchGate*. 05.08.2025. DOI:10.1016/j.patrec.2015.04.007.
16. Parzhin Y., Galkyn S., Sobol M. Method For Binary Contour Images Vectorization Of Handwritten Characters For Recognition By Detector Neural Networks. *2022 IEEE 3rd KhPI Week on Advanced Technology (KhPIWeek)2022 IEEE 3rd KhPI Week on Advanced Technology (KhPIWeek)*. (Kharkiv, Ukraine, 03.10.2022). Kharkiv, Ukraine : IEEE, 2022. DOI:10.1109/KhPIWeek57572.2022.9916331. P. 1–6.
17. Shen W., Jiang Y., Gao W. et al. Shape recognition by bag of skeleton-associated contour parts. *Pattern Recognition Letters*. ("Efficient Shape Representation, Matching, Ranking, and its Applications" Series)Vol. 83, 01.11.2016. P. 321–329. DOI:10.1016/j.patrec.2016.02.002.
18. Adadi A., Berrada M. Peeking Inside the Black-Box: A Survey on Explainable Artificial Intelligence (XAI). *IEEE Access*. Vol. 6, 2018. P. 52138–52160. DOI:10.1109/ACCESS.2018.2870052.
19. Guidotti R., Monreale A., Ruggieri S. et al. A Survey Of Methods For Explaining Black Box Models. arXiv, 2018. DOI:10.48550/arXiv.1802.01933.
20. Gao X., Xiao B., Tao D. та ін. A survey of graph edit distance. *Pattern Analysis and Applications*. Вип. 13, № 1. С. 113–129. DOI:10.1007/s10044-008-0141-y.
21. Sanfeliu A., Fu K.-S. A distance measure between attributed relational graphs for pattern recognition. *IEEE Transactions on Systems, Man, and Cybernetics*. Vol. SMC-13, Issue 3. P. 353–362. DOI:10.1109/TSMC.1983.6313167.
22. Rifkin R., Klautau A. In Defense of One-Vs-All Classification.
23. Parzhin Y. Hypotheses of neural code and the information model of the neuron-detector. arXiv, 2014. DOI:10.48550/arXiv.1411.6768.
24. Parzhin Y. The detector principle of constructing artificial neural networks as an alternative to the connectionist paradigm. arXiv, 2017. DOI:10.48550/arXiv.1707.03623.
25. Parzhyn Y. Architecture of Information. arXiv, 2025. DOI:10.48550/arXiv.2503.21794.
26. Chen W.-Y., Liu Y.-C., Kira Z. et al. A Closer Look at Few-shot Classification. arXiv, 2020. DOI:10.48550/arXiv.1904.04232.
27. Lundberg S., Lee S.-I. A Unified Approach to Interpreting Model Predictions. arXiv, 2017. DOI:10.48550/ARXIV.1705.07874.
28. Ribeiro M. T., Singh S., Guestrin C. «Why Should I Trust You?»: Explaining the Predictions of Any Classifier. arXiv, 2016. DOI:10.48550/arXiv.1602.04938.
29. Rudin C. Stop Explaining Black Box Machine Learning Models for High Stakes Decisions and Use Interpretable Models Instead. arXiv, 2019. DOI:10.48550/arXiv.1811.10154.
30. Slack D., Hilgard S., Jia E. et al. Fooling LIME and SHAP: Adversarial Attacks on Post hoc Explanation Methods. arXiv, 2020. DOI:10.48550/arXiv.1911.02508.
31. Blumenthal D. B., Gamper J. On the exact computation of the graph edit distance. *Pattern Recognition Letters*. Вип. 134, 06.2020. С. 46–57. DOI:10.1016/j.patrec.2018.05.002.
32. Bougleux S., Brun L., Carletti V. та ін. Graph edit distance as a quadratic assignment problem. *Pattern Recognition Letters*. Вип. 87, 02.2017. С. 38–46. DOI:10.1016/j.patrec.2016.10.001.
33. Hendrycks D., Gimpel K. A Baseline for Detecting Misclassified and Out-of-Distribution Examples in Neural Networks. arXiv, 2018. DOI:10.48550/arXiv.1610.02136.
34. Yang J., Zhou K., Li Y. et al. Generalized Out-of-Distribution Detection: A Survey. arXiv, 2024. DOI:10.48550/arXiv.2110.11334.

Received (Надійшла) 18.11.2025

Accepted for publication (Прийнята до друку) xx.xx.2025

Відомості про авторів / About the Authors

FEW-SHOT LEARNING OF A GRAPH-BASED NEURAL NETWORK MODEL WITHOUT BACKPROPAGATION

Subject. We propose a structural-graph approach to classifying contour images in a few-shot regime without using backpropagation. **The core idea** is to make structure the carrier of explanations: an image is encoded as an attributed graph (critical points and lines represented as nodes with geometric attributes), and generalization is achieved via the formation of concept attractors (class-level concept graphs). **Purpose.** To design and experimentally validate an architecture in which class concepts are formed from a handful of examples (5–6 per class) through structural and parametric reductions, providing transparent decisions and eliminating backpropagation. **Objectives.** (1) Define a vocabulary of node/edge types and an attribute set for contour graphs; (2) specify normalization and invariances; (3) develop structural and parametric reduction operators as monotonic structural simplifications; (4)

describe a procedure for aggregating examples into stable concepts; (5) perform classification via graph edit distance (GED) with practical approximations; (6) compare with representative few-shot approaches. **Methods.** Contour vectorization is followed by constructing a bipartite graph (Point/Line as nodes) with normalized geometric attributes such as coordinates, length, angle, and direction; reductions include the elimination of unstable substructures or noise and the alignment of paths between critical points. Concepts are formed by iterative composition of samples, and classification is performed by selecting the best graph-to-concept match (using approximated GED). **Results.** On an MNIST subset with 5–6 base examples per class (single epoch), we obtain a consistent accuracy of around 82% with full traceability of decisions: misclassifications can be explained by explicit structural similarities. An indicative comparison with SVM, MLP, CNN, as well as metric and meta-learning baselines, is provided. **Conclusions.** The structural-graph scheme with concept attractors enables few-shot learning without backpropagation and offers built-in explanations through the explicit graph structure. Limitations concern the computational cost of GED and the quality of skeletonization; promising directions include classification-algorithm optimization, work with static scenes, and associative recognition.

Keywords: explainable artificial intelligence, few-shot machine learning, backpropagation, graph reduction.