

Київ 2024

**ДЕРЖАВНИЙ УНІВЕРСИТЕТ
ІНФОРМАЦІЙНО-КОМУНІКАЦІЙНИХ ТЕХНОЛОГІЙ
Навчально-науковий інститут інформаційних технологій**

Кафедра Інформаційних систем та технологій
Ступінь вищої освіти Магістр
Спеціальність 126 Інформаційні системи та технології
Освітньо-професійна програма Інформаційні системи та технології

ЗАТВЕРДЖУЮ

Завідувач кафедру
Інформаційних систем та технологій
Каміла СТОРЧАК
Ім'я, ПРІЗВИЩЕ

«__» _____ 2024 р.

**ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ**

Шостовіцькому Дмитру Геннадійовичу

(прізвище, ім'я, по батькові здобувача)

1. Тема кваліфікаційної роботи: «Удосконалення нейронних мереж для оптимізації ігрових стратегій»

керівник кваліфікаційної роботи Срібна Ірина Миколаївна професор кафедри, доктор технічних наук, доцент.

(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

затверджені наказом Державного університету інформаційно-комунікаційних технологій

від «15» жовтня 2024 р. № 320

2. Строк подання кваліфікаційної роботи «27» грудня 2024 р.

3. Вихідні дані до кваліфікаційної роботи: Нейронні мережі; Ігрові стратегії; Модель DSNN; Модель GSN; Інтелектуальні системи; Графові згорткові системи;

4. Зміст розрахунково-пояснювальної записки (перелік питань, які потрібно розробити)

1. Вступ: обґрунтування актуальності дослідження гібридної нейронної мережі для стратегій у відеоіграх.

2. Огляд існуючих підходів до графових згорткових нейронних мереж (GCNN).

3. Проблеми, пов'язані з автономними системами прийняття рішень.

4. Опис запропонованої гібридної моделі та її алгоритму.
5. Експериментальні результати: порівняння точності та ефективності.
6. Висновки: переваги гібридного підходу та рекомендації для подальших досліджень.
5. Перелік ілюстративного матеріалу: *презентація*
 1. Згорткова нейронна мережа.
 2. Правила гри в космічні шахи.
 3. Огляд запропонованої методики, використання GCN та об'єднання її з DCNN.
 4. Архітектура запропонованої гібридної мережі.
 5. Архітектура частини DCNN.
 6. Структура графа.
 7. Порівняння втрат DCNN і DCNN_GCNN.
 8. Результати кореляційного ефекту.
 9. Середнє і стандартне відхилення моделей різних характеристик.
 10. Прогнози дій та ходів експертів.
 11. Висновки, апробації.
6. Дата видачі завдання «15» жовтня 2024 р.

КАЛЕНДАРНИЙ ПЛАН

№ з/п	Назва етапів кваліфікаційної роботи	Строк виконання етапів роботи	Примітка
1	Підбір науково-технічної літератури	15.10 - 24.10 2024	Виконано
2	Огляд існуючих підходів до графових згорткових нейронних мереж (GCNN).	25.10 - 7.11 2024	Виконано
3	Опис запропонованої гібридної моделі та її алгоритму.	25.10 - 7.11 2024	Виконано
4	Експериментальні дослідження	8.11 - 21.11 2024	Виконано
5	Оформлення роботи вступ, висновки, реферат	22.11 - 5.11 2024	Виконано
6	Розробка демонстраційних матеріалів	6.12 - 12.12 2024	Виконано
7	Попередній захист роботи	25.12 2024	Виконано

Здобувач(ка) вищої освіти

_____ (підпис)

Дмитро ШОСТОВИЦЬКИЙ

(Ім'я, ПРІЗВИЩЕ)

Керівник

кваліфікаційної роботи

_____ (підпис)

Ірина СРІБНА

(Ім'я, ПРІЗВИЩЕ)

РЕФЕРАТ

Текстова частина кваліфікаційної роботи на здобуття освітнього ступеня магістра: 62 стор., 9 рис., 4 табл., 48 джерел.

Мета роботи – розробка гібридної графової згорткової нейронної мережі для вирішення задач у стратегіях відеоігор.

Об’єкт дослідження – графові згорткові нейронні мережі та їх використання в інтелектуальних системах.

Предмет дослідження – методи покращення точності та ефективності гібридних нейронних мереж у ігрових стратегіях.

Короткий зміст роботи: робота включає аналіз існуючих підходів, розробку нової моделі, тестування на ігрових даних та аналіз результатів.

КЛЮЧОВІ СЛОВА: ГІБРИДНА НЕЙРОННА МЕРЕЖА, ГРАФОВІ ЗГОРТКОВІ МЕРЕЖІ, СТРАТЕГІЯ ВІДЕОІГОР, ІНТЕЛЕКТУАЛЬНІ СИСТЕМИ.

ABSTRACT

The text part of the qualification work for obtaining the master's degree: 62 pages, 9 figures, 4 tables, 48 sources.

The purpose of the work is to develop a hybrid graph convolutional neural network for solving problems in video game strategies.

The object of research is graph convolutional neural networks and their use in intelligent systems.

The subject of research is methods of improving the accuracy and efficiency of hybrid neural networks in game strategies.

Summary of the work: the work includes analysis of existing approaches, development of a new model, testing on game data and analysis of results.

KEY WORDS: HYBRID NEURAL NETWORK, GRAPHIC CONGULATION NETWORKS, VIDEO GAME STRATEGY, INTELLIGENT SYSTEMS.

ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ.....	9
ВСТУП.....	10
1 АНАЛІЗ СУЧАСНИХ ПІДХОДІВ ДО ОПТИМІЗАЦІЇ ІГРОВИХ СТРАТЕГІЙ ЗА ДОПОМОГОЮ НЕЙРОННИХ МЕРЕЖ.....	12
1.1 Огляд існуючих методів та моделей GCNN.....	14
1.2 Проблеми автономних систем у відеоіграх.....	25
2 МЕТОДОЛОГІЯ РОЗРОБКИ ТА ВПРОВАДЖЕННЯ ГІБРИДНОЇ НЕЙРОННОЇ МЕРЕЖІ.....	30
2.1 DCNN у виділенні ознак.....	34
2.2 Побудова структури даних графіка.....	41
2.3 Модель розгалуження на основі навчання графів.....	43
2.4 Гібридна модель з функцією Feature Fusion.....	46
3 ЕКСПЕРИМЕНТАЛЬНІ ДОСЛІДЖЕННЯ ГІБРИДНОЇ МОДЕЛІ.....	48
3.1 Набір даних експерименту.....	49
3.2 Тонкощі реалізації.....	51
3.3 Результати експерименту.....	51
3.4 Теоретичне застосування в інших стратегічних іграх.....	58
ВИСНОВКИ.....	61
ПЕРЕЛІК ПОСИЛАНЬ.....	64
ДЕМОНСТРАЦІЙНІ МАТЕРІАЛИ.....	68

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ

GCNN (graph convolutional neural network) – графова згортка нейронної мережі.

DCNN (deep convolutional neural network) – глибока згортова нейронна мережа.

GCN (graph convolutional network) – графова згортова мережа.

GCN (graph neural network) – графова нейронна мережа.

FSM (finite-state machine) – кінцева машина.

AI (artificial intelligence) – штучний інтелект.

FPGA (field-programmable gate arrays) – програмовані вентиляльні матриці.

CFG (common fate graph) – загальний граф долі.

LGCL (learnable graph convolution layer) – навчальний шар згортки графа.

GNN (graph neural network) – графова нейронна мережа.

CEGCN (called the CNN-enhanced GCN) – так званий CNN-enhanced GCN.

AR (refinement module) – модуль уточнення.

AMCNN-DGCN (end-to-end multiscale convolutional neural network–dynamic graph convolutional network) – наскрізна багатомасштабна згорточна нейронна мережа–згорточна мережа з динамічним графом.

DCRNNs (diffused convolutional recurrent neural networks) – дифузні згорточні рекурентні нейронні мережі.

R-GCN (relational graph convolutional networks) – реляційні графові згорткові мережі.

SGF (Smart Game format) – формат Smart Game.

FGR (full graph representation) – повне графове представлення.

CFG (common fate graph) – загальний граф долі.

ВСТУП

Актуальність теми. Стрімкий розвиток ігрової індустрії вимагає постійного впровадження інноваційних рішень для створення більш досконалих стратегічних ігор, здатних задовольнити зростаючі очікування користувачів. У цьому контексті сучасні алгоритми штучного інтелекту, особливо нейронні мережі, відіграють вирішальну роль у аналізі великих обсягів ігрових даних, оптимізації прийняття рішень та побудові складних ігрових стратегій. Однак, незважаючи на досягнення в цій галузі, дослідники стикаються з низкою викликів, зокрема з недостатньою адаптивністю існуючих моделей до складних сценаріїв, багатовимірного характеру ігор і неоднорідності даних. Ці виклики вимагають розробки нових методів навчання нейронних мереж, які здатні інтегрувати різні підходи, наприклад, поєднувати переваги графових згорткових нейронних мереж (GCNN), що ефективно працюють із реляційними даними, та глибоких згорткових нейронних мереж (DCNN), орієнтованих на аналіз просторових особливостей. Такий гібридний підхід відкриває нові можливості для підвищення якості ігрових стратегій, створення більш реалістичних і адаптивних ігрових середовищ та вирішення інших задач, пов'язаних з обробкою складних даних у різних галузях.

Мета роботи. Розробка гібридної нейронної мережі, яка інтегрує можливості графових згорткових нейронних мереж (GCNN) і глибоких згорткових нейронних мереж (DCNN) для оптимізації ігрових стратегій.

Об'єкт дослідження. Штучні нейронні мережі, що застосовуються для моделювання ігрових процесів.

Предмет дослідження. Методи оптимізації структури нейронних мереж та алгоритмів їх навчання для підвищення ефективності стратегічних рішень.

Наукова новизна. Запропонована в роботі гібридна модель інтегрує передові підходи графових згорткових нейронних мереж (GCNN) та глибоких згорткових нейронних мереж (DCNN), що дозволяє значно підвищити точність і адаптивність

прийняття рішень у складних стратегічних іграх. Ця модель дає змогу враховувати як просторові, так і реляційні особливості, що є критично важливими для ефективного аналізу ігрових ситуацій та побудови стратегій. Вперше було розроблено та протестовано алгоритм навчання, який ефективно об'єднує ці дві нейронні архітектури за допомогою функції об'єднання ознак (Feature Fusion). Такий підхід дозволяє злиття різнорідних ознак з двох різних моделей, що забезпечує комплексний аналіз даних, виявляючи важливі залежності між елементами гри, а також здатність адаптувати стратегії до різних ігрових умов. Завдяки цьому гібридний підхід має потенціал значно покращити продуктивність та ефективність нейронних мереж у застосуванні до стратегічних ігор, де традиційні методи можуть бути менш ефективними через складність та різноманітність сценаріїв.

Практичне значення. Результати цієї роботи можуть знайти широке застосування в розробці інноваційних ігрових платформ, де автоматизація прийняття рішень є ключовим аспектом для забезпечення високої якості та інтерактивності ігрового процесу. Гібридна модель, яка поєднує можливості графових згорткових нейронних мереж (GCNN) і глибоких згорткових нейронних мереж (DCNN), дозволяє значно підвищити складність і реалізм ігрового процесу, роблячи його більш динамічним і адаптивним до змінюваних умов гри. Це забезпечить більш цікаве та захоплююче ігрове середовище для користувачів, що зможе привабити нових гравців та зберегти зацікавленість постійних.

Апробація. Основні положення та результати магістерської роботи доповідались та обговорювались на науково-технічних конференціях:

II Міжнародна науково-практична конференція «сучасні аспекти діджиталізації та інформатизації в програмній та комп'ютерній інженерії

1 АНАЛІЗ СУЧАСНИХ ПІДХОДІВ ДО ОПТИМІЗАЦІЇ ІГРОВИХ СТРАТЕГІЙ ЗА ДОПОМОГОЮ НЕЙРОННИХ МЕРЕЖ

Нейронні мережі — це основа сучасних технологій штучного інтелекту, які моделюють принципи роботи людського мозку. Вони використовують багат шарові структури, що складаються з штучних нейронів, для аналізу, обробки й прогнозування даних. Ці нейрони взаємодіють через вагові коефіцієнти, які налаштовуються під час навчання, дозволяючи мережі адаптуватися до вхідних даних та оптимізувати свої результати.

Ідея штучних нейронних мереж була запропонована ще у середині ХХ століття. У 1943 році Воррен Маккалок і Волтер Піттс створили першу математичну модель нейрона, яка заклала теоретичний фундамент для подальших досліджень. Наступні десятиліття ознаменувалися розробкою персептрона — простої нейронної мережі, здатної вирішувати базові завдання класифікації. Однак обмеження цих систем, зокрема неможливість роботи з нелінійними даними, стримували їхній розвиток до 1980-х років.

Справжній прорив стався у 2000-х роках завдяки значному зростанню обчислювальних потужностей і появі великих обсягів даних. Поєднання високопродуктивного апаратного забезпечення, таких як графічні процесори (GPU), та вдосконалених алгоритмів оптимізації відкрило шлях до створення складних архітектур нейронних мереж, зокрема глибокого навчання (deep learning).

На сьогодні існує багато типів нейронних мереж, кожен із яких орієнтований на розв'язання специфічних задач. До найпоширеніших належать мережі, розроблені для аналізу візуальної інформації. Вони ефективно працюють із зображеннями, відео та іншими типами даних, де важливі просторові залежності.

CNN використовують згорткові шари, які виділяють ключові особливості, такі як краї, текстури або форми, що робить їх незамінними у таких завданнях, як розпізнавання облич, медична діагностика та аналіз супутникових зображень.

RNN підходять для роботи з послідовностями даних, таких як текст, аудіо або часові ряди. Вони мають зворотні зв'язки, які дозволяють зберігати інформацію про попередні стани, забезпечуючи контекстний аналіз. Модифікації RNN, такі як LSTM (Long Short-Term Memory) і GRU (Gated Recurrent Unit), подолали проблему зникнення градієнта, що суттєво підвищило їхню ефективність.

GNN спеціалізуються на обробці даних у вигляді графів. Вони застосовуються для задач, де важливі зв'язки між елементами, наприклад, у соціальних мережах, хімічному моделюванні та прогнозуванні поведінки складних систем. Завдяки здатності моделювати зв'язки, GNN мають великий потенціал у задачах, які потребують аналізу структурованих даних.

Трансформери — це архітектура, яка революціонізувала обробку природної мови (NLP) та інші сфери. Вони використовують механізм уваги (attention), що дозволяє моделі зосереджуватися на важливих частинах вхідних даних. Такі моделі, як GPT і BERT, демонструють неймовірну ефективність у генерації тексту, перекладі, резюмуванні та інших завданнях.

GAN складаються з двох моделей — генератора та дискримінатора, які змагаються між собою. Генератор створює нові дані, намагаючись обдурити дискримінатор, а дискримінатор, у свою чергу, навчається розпізнавати штучно створені зразки. Це дозволяє GAN створювати реалістичні зображення, відео та навіть синтезувати голоси.

Незважаючи на значний прогрес, нейронні мережі мають низку обмежень. Наприклад, їхнє навчання вимагає великих обсягів даних та значних обчислювальних ресурсів. Крім того, існують виклики, пов'язані з інтерпретацією результатів, адже нейронні мережі часто працюють як "чорні ящики". Це створює

труднощі у галузях, де важлива прозорість, наприклад, у медицині чи юридичній сфері.

Окрему увагу заслуговують етичні аспекти. Використання нейронних мереж для створення глибоких фейків або маніпуляції інформацією підкреслює необхідність регулювання цієї технології. Також важливо розвивати енергоефективні моделі, оскільки сучасні системи штучного інтелекту споживають значні ресурси, що може мати вплив на екологію.

Інтеграція нейронних мереж із великими даними (Big Data) та Інтернетом речей (IoT) відкриває нові можливості. Наприклад, у розумних містах (smart cities) нейронні мережі можуть аналізувати трафік у реальному часі, оптимізуючи транспортні потоки. У медицині їх використовують для персоналізованого лікування на основі аналізу генетичних даних і медичних записів.

У межах цієї роботи пропонується розгляд гібридної моделі, яка інтегрує графові згорткові нейронні мережі та глибокі згорткові нейронні мережі. Такий підхід дозволяє поєднати переваги обох архітектур: роботу з нелінійними структурами даних і точний аналіз візуальної інформації. Це відкриває перспективи для використання у багатьох галузях, зокрема у медицині, фінансах та автоматизації бізнес-процесів.

1.1 Огляд існуючих методів та моделей GCNN

У сучасному світі стрімкого розвитку технологій, нейронні мережі знаходять широке застосування в різних сферах, включаючи ігрову індустрію. Вони відіграють ключову роль у створенні інтелектуальних систем, які здатні автоматизувати прийняття рішень, оптимізувати стратегії та адаптуватися до динамічних умов гри. Однак існуючі моделі автономних нейронних мереж стикаються з проблемами ефективності та точності під час роботи зі складними ігровими даними, де необхідно враховувати численні залежності та взаємодії між елементами гри. З метою

вирішення цих обмежень була запропонована гібридна графова згорткова нейронна мережа (GCNN), яка поєднує переваги графових моделей для обробки складних структурованих даних і згорткових нейронних мереж для вилучення важливих ознак з ігрових зображень або даних. Дана робота зосереджується на розробці і тестуванні цієї моделі, оцінці її ефективності в застосуванні до стратегічних ігор, таких як Го, і на порівнянні з іншими підходами, що використовуються в поточних дослідженнях. Ми аналізуємо, як гібридна модель може покращити результати порівняно з традиційними методами, які часто не враховують важливі просторові і кореляційні зв'язки між елементами гри.

Глибокі згорткові нейронні мережі (DCNN) користуються великим успіхом у багатьох сферах застосування, таких як комп'ютерний зір, автоматизована медична діагностика, автономні системи тощо. Інше застосування DCNN – для ігрових стратегій, де глибока нейронна мережева архітектура може бути використана для безпосереднього представлення та навчання стратегій від досвідчених гравців з різних сторін. Багато ігрових станів можуть бути виражені не тільки у вигляді матричної структури даних, придатної для навчання DCNN, але і у вигляді графічної структури даних. Більшість доступних методів DCNN ігнорують територіальні характеристики позицій обох сторін на основі правил гри. Тому в даній роботі ми пропонуємо гібридний підхід до графової нейронної мережі для вилучення особливостей моделі ігрових стратегій і злиття її в DCNN. Як модель навчання графів, згорткові мережі графів (GCN) надають схему, за допомогою якої можна виділити ознаки в структурі графа, що може краще виявити особливості у відносинах між стратегіями гри. Ми перевіряємо роботу та проектуємо гібридну мережу для інтеграції GCN та DCNN у гру Го та показуємо, що на наборі даних KGS Го продуктивність гібридної моделі перевершує традиційну модель DCNN. Гібридна модель демонструє хороші показники у витягуванні ігрової стратегії Го.

У теорії ігор стратегія – це розроблений гравцями план дій, який залежить не тільки від їх власних дій, але і від того, які варіанти є у інших гравців в оточенні.

Стратегія включає в себе не тільки вибір конкретних ходів, але й врахування можливих варіантів дій суперника, що дозволяє забезпечити більш ефективну взаємодію в рамках гри. Такий план може служити основою для прийняття рішень, визначення найкращих кроків та формування взаємодії між гравцями в ігровому середовищі, що відображає складність і динамічність стратегічних ігор. Останніми роками, завдяки дослідженням Google DeepMind у сфері стратегічних ігор, таких як го, шахи та сьогі [1,2,3], стратегія в контексті штучного інтелекту стала знову актуальною темою, оскільки досягнення в розробці новітніх алгоритмів дозволяють значно поліпшити здатність машин приймати ефективні стратегії в складних умовах. На сьогоднішній день запропоновані різні алгоритми прийняття рішень для стратегічних ігор, які значною мірою змінюють підходи до автоматизації ігрових процесів. Виходячи з принципу роботи, алгоритми можна розділити на дві основні групи: традиційні алгоритми штучного інтелекту (ШІ), які базуються на заздалегідь визначених правилах і евристичних, і алгоритми штучного інтелекту з машинним навчанням, що дозволяють системам самостійно вдосконалювати свої стратегії на основі отриманих даних.

На перших порах більшість підходів до розробки стратегічних ігор ґрунтувалися на формулюванні людиною конкретних правил і логіки для прийняття рішень та висновків, що дозволяло забезпечити передбачуваність і простоту в управлінні ігровими процесами. До таких підходів відносяться кінцева машина (FSM) [4], яка обмежує можливості гри до чітко визначених станів, пошук по дереву [5], що забезпечує аналіз варіантів на основі структури ігрових ходів, і утилітарний штучний інтелект [6], що орієнтується на максимізацію вигоди для гравця. Однак ці методи не підходять для більшості стратегічних ігор, оскільки конкретне використання алгоритмів залежить від специфіки сценарію та потреб, що виникають під час гри. Вони мають обмеження, пов'язані з важкістю адаптації до змінних умов та складності кожної окремої гри. Щоб пом'якшити ці проблеми, існуючі підходи були модифіковані та адаптовані для більш складних ігор на прийняття рішень.

Наприклад, алгоритм пошуку дерева Монте-Карло (MCTS) був розроблений для вирішення проблеми надмірного простору пошуку в грі Го [7], дозволяючи обчислювати ймовірнісні варіанти розвитку подій і забезпечувати оптимальне прийняття рішень. Хоча ці традиційні алгоритми штучного інтелекту вимагають менших обчислювальних витрат і є простими в розробці та налаштуванні, вони часто не справляються з великою кількістю змінних, особливо коли ігрова сцена стає більш складною, а кількість гравців збільшується. Це призводить до того, що правила і алгоритми стають дедалі складнішими для розробки, що підштовхує до використання нових підходів і методів у галузі штучного інтелекту та машинного навчання.

У порівнянні з традиційними алгоритмами штучного інтелекту, алгоритми штучного інтелекту з машинним навчанням можуть навчатися незалежно від наявних даних про ігри гравців і мають можливості для прийняття рішень. Глибоке навчання [8] та навчання з підкріпленням [9] – це алгоритми штучного інтелекту з машинним навчанням, які зазвичай використовуються у сфері ігор. Обидва методи вимагають великої кількості наборів даних для навчання. Різниця полягає в тому, що глибоке навчання спрямоване на вивчення досвіду існуючих експертів та імітацію їхніх стратегій, тоді як навчання з підкріпленням спрямоване на посилення продуктивності через самодослідження та повторну практику з самим собою. Хоча алгоритми штучного інтелекту з машинним навчанням можуть вирішувати проблеми для складних сценаріїв, одна модель не може задовольнити оцінку глобальної гри. У грі Го традиційна евристична функція оцінки ускладнює точну оцінку складності ситуації; Таким чином, це може вплинути на модель навчання з підкріпленням.

У методах глибокого навчання глибокі згорткові нейронні мережі (DCNN) користуються великим успіхом у багатьох додатках, таких як комп'ютерний зір [10], автоматизована медична діагностика [11], автономні системи [12] тощо. Інше застосування DCNN – для ігрових стратегій, де глибока нейронна мережева архітектура може бути використана для безпосереднього представлення та навчання

стратегій від досвідчених гравців з різних сторін. У найпростіших стратегічних іграх Wang et al. [13] використовували CNN для моделювання процесу прийняття рішень у грі Pac-Man та пояснення внутрішньої логіки кожного згорткового шару. Суцкевер і Наїр [14] представили модель CNN в Go, гру з високою складністю прийняття рішень, і прогноз дій експертів досяг 36,9 %. Щоб підвищити ефективність прийняття рішень, Кларк і Сторкі [15] запропонували модель DCNN з декількома прихованими шарами, яка поєднувала функції, побудовані вручну на основі правил Го, для досягнення кращих результатів прогнозування. Крім того, для прискорення моделей DCNN була використана ефективна апаратна архітектура. Li et al. [16] запропонували апаратну архітектуру, яка може вміщати різні програмовані масиви затворів (FPGA) для прискорення моделі DCNN і балансу між швидкістю обробки та апаратними ресурсами.

У зв'язку з різноманітністю правил стратегічних ігор, складністю простору розподілу та різною кількістю гравців, виникає необхідність у вилученні ігрових градієнтних особливостей для належної підтримки всього геймплею стратегічних ігор. Прогнозування можливих варіантів розвитку гри та прийняття оптимальних рішень вимагають здатності правильно оцінювати складні динамічні ситуації, де кожне нове рішення може змінити хід гри. Як показано на рисунку 1.1, шахи космічної четвірки є яскравим прикладом настільної стратегії, що значно відрізняється від традиційних ігор, таких як шахи чи го. Ця гра, виконана в тривимірному просторі, додає додаткові складнощі при прогнозуванні виграшних станів, оскільки дозволяє здійснювати комбінації фігур не лише на двовимірній поверхні, а й в об'ємному просторі. Для досягнення виграшної умови в шахах космічної четвірки необхідно розмістити чотири фігури одного кольору, які повинні бути розташовані послідовно. Ці чотири фігури можуть утворювати лінію не тільки в горизонтальному, вертикальному чи похилому напрямках площини, але й у косому розміщенні в тривимірному просторі (див. рис. 1.1). Завдяки такій різноманітності варіантів розташування фігур та можливості їх руху в трьох вимірах, стратегія гри

стає набагато складнішою. Відповідно, для побудови ефективних алгоритмів і моделей штучного інтелекту, здатних працювати з такою складною структурою гри, необхідно враховувати не тільки звичні правила двовимірних ігор, але й додаткові фактори, які виникають у тривимірному просторі. Це підвищує вимоги до алгоритмів навчання, які мають ефективно працювати з величезною кількістю можливих комбінацій та ситуацій.

Задача прогнозування таких виграшних станів є складною для традиційних підходів, таких як глибокі згорткові нейронні мережі (DCNN), оскільки вони спочатку були розроблені для обробки евклідових даних, що означає, що для такої складної стратегії, як шахи космічної четвірки, вони не працюють так ефективно. Хоча деякі підходи, що використовують DCNN, можуть досягати помітних результатів у традиційних стратегічних іграх, вони часто не враховують важливі взаємозв'язки між гравцями, зокрема зв'язки між їхніми фігурами, які мають значення для розподілу та прийняття рішень. Наприклад, у грі Го умова перемоги залежить від розміру території, яку займають камені гравця, що вимагає оцінки взаємозв'язків між областями, зайнятими кожним каменем. Ця кореляція між полями, які займаються каменями, має суттєвий вплив на загальну стратегію гри, оскільки вона визначає подальші кроки та прийняття рішень.

Проте традиційні підходи DCNN часто зосереджуються лише на вилученні інформації на рівні зображень і не враховують просторові кореляції між сусідніми полями чи зонами на дошці. Ці моделі переважно обробляють інформацію у вигляді плоских матриць або зображень, що може обмежувати їх здатність враховувати взаємозв'язки між окремими елементами гри на більш глибокому рівні. Вони не завжди можуть ефективно обробляти складні стратегії, де елементи гри мають неоднорідні та багатовимірні залежності. Ці залежності, які можуть бути критичними для прогнозування ігрового процесу, часто стосуються не тільки

безпосереднього впливу одного елемента на інший, а й стратегічних взаємодій на відстані, що змінюються залежно від поточної ситуації на дошці.

Неврахування таких складних залежностей може суттєво обмежити точність прогнозів і стратегії моделі, що робить традиційні DCNN недостатніми для деяких стратегічних ігор. Наприклад, у таких іграх, як Го чи шахи, існують специфічні кореляції, які можуть бути важливими для прийняття рішення про подальші кроки. Це свідчить про необхідність розвитку нових підходів, які здатні врахувати ці особливості. Інтеграція графових нейронних мереж (GCN) надає нові можливості для моделювання таких складних структурних зв'язків, оскільки GCN дозволяють краще захоплювати залежності між елементами гри, використовуючи графові структури, які більш природно відображають зв'язки між каменями, фігурами чи іншими елементами на дошці. Така інтеграція дозволяє створювати гнучкіші та потужніші моделі для прогнозування наступних ходів і оптимізації стратегій у складних ігрових середовищах.



Рис. 1.1 Правила гри в чотири шахи космосу

Багато ігрових станів можуть бути виражені не тільки у вигляді матричної структури даних, придатної для навчання DCNN, але і у вигляді графічної структури даних. Представлення графіка може представляти сутності в стратегічних іграх (наприклад, табори гравців, місцевість на карті, внутрішньоігрові ресурси) як вузли

на графіку, а відносини між сутностями (наприклад, відносини між таборами, відстані між ресурсами на карті) як ребра графіка. У порівнянні з матричними даними, дані графіка можуть не тільки представляти неевклідові правила в іграх на прийняття рішень; Він також може враховувати відносини суміжності між гравцями гри. Методи графічного зображення були застосовані в іграх камінь-ножиці-папір [17], іграх на домінування [18] та стратегічних іграх [19]. У грі в го Граф і Платцнер ввели загальний графік долі (CFG) для представлення дошки Го і витягли з нього функції для прогнозування ходів за допомогою методу пошуку дерева Монте-Карло [20]. Ці методи ефективно представляють неевклідові ігри та підвищують актуальність правил гри в стратегічних іграх.

Останнім часом графові нейронні мережі (GCN) привертають все більше уваги через їх видатну здатність обробляти дані домену графа. GCN імітує принцип CNN щодо згортки над структурованими даними і здатний обробляти неевклідові дані, які CNN не може обробити [21]. GCN став ключовим підходом до аналізу графів для широкого кола завдань зі складними взаємозв'язками, тобто аналізу медичних зображень [22], рекомендацій щодо місцезнаходження [23], соціальних мереж [24] та класифікації дистанційного зондування [25]. У порівнянні з CNN, оскільки кількість сусідів вузла даних графіка різна, немає можливості безпосередньо визначити ковзне вікно однакового розміру, тому GCN також використовується для дослідження кореляції між сутностями на зображенні шляхом агрегування характеристик сусідів навколо вузла. З огляду на силу GCN у цих областях, у цій статті ми запропонували використовувати GCN для виявлення залежностей між таборами в стратегічних іграх та дослідження потенційного впливу інформації про розподіл таборів на стратегію гри.

Для ефективного вирішення обмежень автономної глибокої згорткової нейронної мережі (DCNN) у навчанні ігрової стратегії, ми пропонуємо гібридний підхід, який поєднує графову нейронну мережу (GCN) з DCNN для більш

ефективного вилучення та інтеграції особливостей моделі ігрових стратегій. Традиційні моделі DCNN орієнтовані на обробку зображень і вилучення плоских ознак, що добре працює для простих стратегічних завдань. Однак при роботі зі складними іграми, де існують багатовимірні та просторові кореляції між елементами гри, такі підходи часто не дають бажаних результатів.

Завдяки поєднанню GCN з DCNN, гібридна модель здатна краще враховувати взаємозв'язки між елементами на дошці, створюючи графову структуру, яка дозволяє моделювати залежності між сусідніми каменями чи фігурами в ігровому процесі. Це дозволяє не лише покращити розпізнавання важливих стратегічних елементів, але й врахувати динамічні зміни, які можуть виникати внаслідок руху фігур або зміни ситуації на полі. Таке поєднання дає можливість більш точно прогнозувати наступні ходи, оптимізувати стратегії та забезпечувати гнучкість моделі у складних ігрових середовищах, як, наприклад, у грі Го.

Цей гібридний підхід значно розширює можливості традиційної DCNN, покращуючи її здатність до обробки складних просторових і реляційних залежностей, що мають місце в стратегії ігор, таких як Го, та відкриває нові перспективи для застосування у більш широкому колі ігор, де необхідно враховувати складні взаємозв'язки між елементами гри.

У роботі ми тестуємо цей підхід на класичній грі Го, щоб продемонструвати, як гібридизація GCN з DCNN покращує процес навчання і стратегічне передбачення. Як показано на рисунку 1.2, перший етап процесу включає в себе кодування ігрових даних в структуру масиву, що дозволяє зберігати інформацію про поточний стан гри. Цей етап є важливим, оскільки правильне кодування забезпечує належну основу для подальшої обробки та аналізу даних. Завдяки такому підходу ми можемо отримати чітке представлення ігрової дошки, включаючи позиції каменів, а також дані про вільні та зайняті простори.

Далі ми витягуємо плоскі особливості дошки, що відображають основні компоненти гри, використовуючи стандартні методи DCNN. Це дозволяє визначити початкові ознаки, такі як розташування каменів на дошці, їх взаємодію та найбільш значущі елементи гри. Плоскі ознаки, отримані на цьому етапі, є необхідними для подальшої інтеграції у більш складну структуру через графову нейронну мережу.

Після цього, наступним кроком є інтеграція цих початкових ознак через графову мережу, що дає змогу виявити глибші, більш комплексні залежності між елементами гри. Використовуючи GCN, ми створюємо граф, де вузли представляють окремі камені чи групи каменів, а ребра визначають їх взаємозв'язки. Це дозволяє моделювати не тільки локальні взаємодії, а й більш складні глобальні залежності, які впливають на стратегію гри, наприклад, важливість певних груп каменів для захисту або атаки.

Завдяки поєднанню цих двох методів – DCNN для витягнення плоских ознак і GCN для аналізу графових структур – ми можемо створити потужну модель, яка не тільки виявляє поверхневі особливості гри, а й здатна прогнозувати ефективні стратегії, враховуючи складні взаємозв'язки між різними елементами гри. Цей підхід дозволяє значно покращити точність стратегічних рішень, що робить його перспективним для використання в інших складних стратегічних іграх.

Таким чином, ми створюємо модель, яка поєднує сильні сторони обох типів мереж: можливість ефективно працювати з просторовими даними за допомогою DCNN і здатність GCN обробляти складні зв'язки та структури даних, що виникають у грі. Цей підхід дозволяє значно покращити точність прогнозування ходів і стратегії в грі Го.




Рис. 1.2 Огляд запропонованої методики

Потім ми представили метод, який називається методом загального графа доли (CFG) [26], що є спеціальним представленням графа, заснованим на правилах гри Го. Цей метод дозволяє ефективно відображати розподіл свободи для каменів одного кольору, поєднуючи камені одного кольору з прямими лініями в одній вершині графа. Завдяки цьому підходу можна створити більш точне представлення ситуації на дошці, що дає змогу краще аналізувати та прогнозувати ігрові ходи. Метод CFG дозволяє створювати гнучкішу модель для представлення просторових відносин між каменями Го, зберігаючи при цьому важливі характеристики позицій на дошці.

Цей підхід значно покращує ефективність прогнозування ходів, оскільки дозволяє враховувати як плоскі характеристики каменів, так і їхню взаємодію на рівні просторових зв'язків. На відміну від традиційних методів, заснованих на глибоких згорткових нейронних мережах (DCNN), запропонована нами модель здатна краще передбачати ходи, використовуючи співвідношення між каменями та їхніми позиціями на дошці. Це дає можливість моделювати не тільки локальні

взаємодії, але й більш складні глобальні залежності, що критично важливо для стратегічних ігор.

Основні внески цієї роботи полягають у наступному:

1. Ми пропонуємо новий гібридний фреймворк глибокого навчання нейронних мереж, який інтегрує DCNN і GCN для вилучення планарних, просторових і реляційних особливостей з ігор.
2. Використання нами структури даних графа для представлення стану гри підкреслює важливість відносин між каменями та їх просторовою позицією в стратегічному контексті гри.
3. Ми розробили інтегрований метод злиття ознак даних графів і особливостей зображень, що дозволяє вирішити проблему несумісності даних ознак між DCNN і GCN, створюючи більш ефективну і адаптивну модель.
4. Ми застосовуємо нашу гібридну модель до класичної стратегічної гри «Го», досягаючи кращої продуктивності, ніж традиційні методи, і демонструємо її переваги у складних ігрових сценаріях.

Ці результати можуть бути застосовані не тільки до гри Го, а й до інших стратегічних ігор, де необхідно враховувати складні залежності між елементами гри для прогнозування рухів і оптимізації стратегій.

1.2 Проблеми автономних систем у відеоіграх

Машинне навчання вважається завданням, керованим даними, і довело свою ефективність у багатьох сферах. Однак в останні роки, з вивченням даних графіків, дослідники виявили багато особливостей і змісту в даних графіків, які традиційні методи машинного навчання не можуть дослідити. Тому навчання на основі графів привернуло велику увагу і було застосовано до ряду завдань, таких як класифікація

графів, агрегація, регресія, прогнозування зв'язків тощо. Наприклад, в часовій і спектральній області Defferrard et al. [27] запропонували представлення CNN в контексті теорії спектральних графів. Вони розробили швидколокаційний фільтр згортки на графі для вивчення локальних і фіксованих особливостей на графіку. Більш того, ґрунтуючись на вихідній мережі, Kipf і Welling [28] запропонували варіант, заснований на локальному наближенні спектрального графа першого порядку для поліпшення архітектури згортки вибору, що значно покращує GCN по відношенню до задачі класифікації вузлів. Критично важливим фактором успіху CNN є навчання моделі глибокої мережі. Однак, багат шаровий GCN призводить до зникнення екстракції, призводить до надмірного згладжування фіксованих точок і конверджує власні значення вершин до узгоджених значень, що призводить до необхідності вдосконалення поточної архітектури GCN. Крім того, рецептивне поле неглибокого GCN обмежене. Щоб вирішити ці обмеження, використовуючи концепцію CNN, Li et al. [29] застосували залишкові та щільні зв'язки та розширені згортки до архітектури GCN та успішно побудували 56-шарову GCN зі значно покращеною продуктивністю в завданнях семантичної сегментації. Це дослідження надає велику допомогу розширенню GCN у багатьох галузях.

Крім того, моделі навчання графів важливі в космічній і просторовій областях. Gao et al. [30] припустили, що шар згортки графа, що навчається (LGCL), може автоматично вибирати фіксовану кількість сусідніх вузлів для кожної функції на основі ранжування значень, щоб забезпечити операції згортки. Цей метод дозволив досягти хороших результатів у підграфічній класифікації структури білка, яка зосереджена на просторовій структурі. Крім того, Моселла-Монторо та Руїс-Ідальго запропонували фреймворк SkinningNet, який використовує згортку графів з декількома агрегаторами для вилучення ознак у наскрізний спосіб, що дозволяє вивчати їх, щоб допомогти узагальнити невидимі топології. В іграх модель GCN також краще прогнозує результати гри, ніж традиційні моделі глибокого навчання. Li et al. представили стани гри TUBSTAP у вигляді графічних даних і використовували

GCN як мережу значень для прогнозування результатів гри за допомогою контрольованого навчання, покращуючи точність прогнозування результатів у порівнянні з CNN. У зв'язку з популярністю мультиагентних ігор, Liu et al. запропонували G2AneT, ігровий механізм, заснований на графічній мережі уваги для ігор зі складними відносинами, який показує важливість складних відносин між ігровими агентами і досягає кращої продуктивності в мультиагентних іграх. Крім того, Lee et al. розробили фреймворк на основі графової нейронної мережі (GNN) для задач децентралізованої стратегії в мультиагентних оборонних іграх, щоб імітувати стратегію експерта, з результатами, які перевершують інші алгоритми і можуть бути узагальнені до великомасштабних ігор. З точки зору напівнагляду, Бісберг і Феррара запропонували напівконтрольовану модель прогнозування GCN, GCN-WP, яка включала більше 30 функцій, пов'язаних з грою, і досягла хороших показників у прогнозуванні перемоги. Ці пов'язані роботи демонструють можливість використання графових згорткових мереж в іграх.

З розвитком технології навчання графів дослідники можуть аналізувати переваги та недоліки навчання графів у різних галузях. Як наслідок, гібридний модельний підхід об'єднання моделей глибокого навчання та моделей навчання графів став більш популярним. Наприклад, у класифікації гіперспектральних зображень GCN може використовувати кореляцію між сусіднім земним покривом для згортання неправильних областей, але він не може зафіксувати особливості на рівні пікселів. Тому Liu et al. пропонують гібридну мережу під назвою CNN-enhanced GCN (CEGCN), яка генерує комплементарні спектри на піксельному та суперпіксельному рівнях відповідно, і яка добре показала себе на трьох наборах даних. Мало того, Wang et al. запропонували метод, заснований на двозв'язаній структурі CNN–GCN для з'єднання даних HS та LiDAR, оброблених CNN, для побудови структури графа та вилучення інформації про його структуру шляхом спільного використання деяких шарів структури графа через GCN. Цей метод значно підвищує продуктивність у порівнянні з традиційною моделлю класифікації зображень дистанційного

зондування. Через характер моделі CNN просторову інформацію даних складно отримати. Meng et al. розробили багатоступеневу мережу агрегації, яка з'єднала CNN з модулем уточнення уваги (AR) і моделлю GCN для поліпшення просторової передачі даних ультразвукового медичного зображення і значного підвищення точності завдань сегментації медичних зображень.

Ґрунтуючись на цій структурі, Duan et al. запропонували модель GACNN, що складається з CNN, GCN та механізму уваги для вилучення глобальних та просторових особливостей зображень очного дна та покращення мережевого узагальнення в задачі класифікації за допомогою напівконтрольованого методу, що значно покращило показники класифікації моделі на зображеннях ураження очного дна. У зв'язку зі складним налаштуванням параметрів термоядерних моделей, Wang et al. запропонували наскрізну багатомасштабну згорткову нейронну мережу – динамічну графову згорткову мережу (AMCNN-DGCN), яка може фіксувати високодискримінаційні ознаки, і її модель може бути використана для виявлення мозкових хвиль втоми від водіння з точністю 95,65 %. GCN також може бути інтегрований з іншими моделями глибокого навчання. Лі та Юй [29] представили дифузовані згорткові рекурентні нейронні мережі (DCRNNs), які можуть фіксувати просторові залежності за допомогою графічно двонаправлених випадкових блукань та часових залежностей за допомогою архітектури кодувальник-декодер із запланованою дискретизацією для прогнозування трафіку. Ця модель розширила залежне від часу розширення моделі навчання графів. Гібридні моделі, засновані на навчанні графів, були застосовані в багатьох галузях, таких як біологія, фармація, мережевий взаємозв'язок тощо.

Тому, ґрунтуючись на дослідженні гібридної моделі, ми пропонуємо основу для злиття DCNN та GCN, використовуючи переваги DCNN у виділенні плоских ознак та GCN у обробці просторових даних і кореляції сутностей у іграх. Це дозволяє комбінувати сильні сторони обох підходів: DCNN забезпечує ефективне

вилучення інформації з зображень або плоских даних, тоді як GCN покращує розуміння взаємозв'язків між елементами на дошці, враховуючи їх просторові залежності та кореляції. У цій статті ми розглянемо гру Го як приклад для побудови графічної моделі ігор та перевірки ефекту покращення GCN на традиційні методи глибокого навчання в контексті ігрової стратегії. Гра Го є ідеальним кандидатом для перевірки, оскільки вона включає складні взаємодії між каменями, які повинні бути враховані під час планування стратегії, що дозволяє продемонструвати переваги гібридного підходу в реальних умовах.

2 МЕТОДОЛОГІЯ РОЗРОБКИ ТА ВПРОВАДЖЕННЯ ГІБРИДНОЇ НЕЙРОННОЇ МЕРЕЖІ

У цьому розділі представлено нову гібридну архітектуру нейронної мережі, яка поєднує в собі дві потужні технології: глибоку згорткову нейронну мережу (DCNN) та графову згорткову нейронну мережу (GCN). Така інтеграція дозволяє ефективно обробляти як плоскі ознаки, що відповідають візуальним характеристикам гри, так і структуровані дані графа, що відображають стратегічні зв'язки між різними елементами гри, такими як позиції каменів, їхні взаємодії та потенційні ходи. Цей підхід забезпечує більш комплексне та детальне моделювання ігрових ситуацій, що критично важливо для досягнення високої точності в прогнозуванні ходів.

Гібридна модель була застосована для прогнозування ходів у грі Go, продемонструвавши перевагу в порівнянні з традиційним використанням лише DCNN, оскільки здатна ефективно обробляти як зображення дошки, так і взаємозв'язки між каменями на графовому рівні. В результаті, ця модель дозволяє здійснювати більш точне та адаптивне планування ходів, враховуючи як локальні, так і глобальні аспекти гри.

У традиційних підходах, де використовуються лише DCNN, нейронна мережа здатна ефективно обробляти лише візуальні дані, такі як форми та конфігурації на дошці. Однак ці методи не завжди можуть адекватно враховувати стратегічні зв'язки між елементами гри, що є критичним для ефективного прогнозування в складних ігрових сценаріях. Тому інтеграція GCN у нашу гібридну модель дозволяє враховувати просторові та реляційні залежності між елементами, що робить модель більш потужною та адаптованою до різноманітних стратегічних ситуацій.

На рисунку 2.1 представлено архітектуру запропонованої гібридної мережі. Вона складається з двох основних компонентів: DCNN для витягання плоских ознак,

таких як розміщення каменів на дошці, і GCN для аналізу зв'язків між каменями та їх стратегічними впливами. Ця структура забезпечує потужну базу для автоматизованого прогнозування ходів, що є важливим кроком у розробці інтелектуальних систем для стратегічних ігор.




Рис. 2.1 Архітектура запропонованого методу

Загальна структура мережі включає три основні компоненти, кожен з яких відіграє важливу роль у забезпеченні ефективної обробки ігрових даних та прогнозуванні ходів у грі Go:

1. Виділення плоских ознак через DCNN: Першим етапом є використання методу одноканального кодування для представлення каменів на дошці гри в вигляді вектора. Цей вектор має розмір, що відповідає розмірам дошки (наприклад, для дошки 19x19 вектор має розмір 19×19), де кожен елемент містить інформацію про наявність каменя в конкретній позиції. Потім цей вектор передається в мережу DCNN для вилучення плоских ознак, що характеризують основні елементи гри, такі як групи каменів, можливі загрози, а також можливості для захоплення каменів. Цей етап допомагає моделі працювати з візуальними

патернами гри, що включають взаємодії між каменями в певних областях дошки.

2. Вилучення ознак графа через GCN: Оскільки гра Go має вбудовану графову структуру, де камінь можна вважати вузлом, а зв'язки між каменями — ребрами, для вилучення графових ознак ми застосовуємо графову нейронну мережу (GCN). Для цього будуються графи за допомогою структури CFG (Graph-based Co-Features), що дозволяє представити гру у вигляді графа. Потім ми використовуємо P-GCN (Реляційні згорткові мережі графа) для вилучення важливих ознак, таких як позиція каменів на дошці та характер їхніх зв'язків. Це дозволяє моделі враховувати стратегічні відносини між каменями, з'єднання між ними та їхню взаємозалежність. Завдяки цьому етапу мережа здатна глибше розуміти ситуацію на дошці, оцінюючи можливості захоплення, створення груп та інші стратегічні аспекти.
3. Злиття функцій: Після вилучення ознак через дві окремі моделі — DCNN для плоских ознак і GCN для графових — наступним кроком є злиття цих ознак для створення загального представлення гри. Злиття функцій дозволяє поєднати переваги обох підходів: глибоку обробку візуальних даних через DCNN і стратегічну обробку графових відносин через GCN. Це значно підвищує точність прогнозування, оскільки модель враховує як локальні візуальні патерни, так і глобальні стратегічні залежності між каменями. Злиті ознаки передаються на повністю зв'язаний шар, де здійснюється класифікація і прогнозується найбільш ймовірний хід у грі. Це дозволяє моделі автоматично адаптуватися до нових ігрових ситуацій та здійснювати більш точні прогнози на основі комплексних даних.

Запропонована гібридна мережа об'єднує дві потужні технології: глибоку згорткову нейронну мережу (DCNN), яка спеціалізується на обробці зображень та плоских ознак, і графові нейронні мережі (GCN), які дозволяють ефективно

працювати зі структурованими даними та виявляти взаємозв'язки між елементами гри. Цей підхід дає можливість використовувати переваги обох типів мереж для досягнення більш точної та потужної обробки складних ігрових ситуацій.

DCNN зосереджується на виділенні локальних ознак, таких як розташування каменів на дошці, групи, потенційні загрози та можливості захоплення. Це дозволяє мережі розпізнавати патерни, які визначають основні етапи гри, і сприяє прогнозуванню найбільш ймовірних ходів на основі таких патернів.

З іншого боку, GCN використовує графову структуру, що дозволяє враховувати глобальні взаємозв'язки між елементами гри. Це важливо для стратегічних ігор, таких як Go, де, окрім локальних патернів, необхідно враховувати також зв'язки між різними частинами дошки, можливості блокування супротивника, створення стратегічних груп та інші комплексні взаємодії.

Комбінація обох підходів дозволяє значно підвищити ефективність прогностичних можливостей моделі. Вона може не лише оцінювати локальні патерни, а й враховувати довгострокові стратегії, що складаються з взаємодії між елементами гри на всій дошці. Цей підхід робить гібридну мережу значно потужнішою та більш адаптованою до складних ігрових стратегій, де потрібно працювати як із детальними, так і з більш загальними аспектами гри.

В результаті, така інтеграція дозволяє досягати кращих результатів у прогнозуванні ходів і розумінні стратегічних аспектів гри, що дає значну перевагу при моделюванні складних ігрових ситуацій і рішень.

2.1 DCNN у виділенні ознак

Необроблені дані гри Го зазвичай зберігаються в форматі Smart Game (SGF), який є стандартним форматом для обміну інформацією про партії цієї гри. Формат SGF дає можливість зберігати не лише самі ходи, але й метадані гри, що містять додаткову інформацію про гру, таку як правила, умови чи додаткові анотації. Це дозволяє зручно та організовано зберігати всі аспекти гри для подальшого аналізу та обробки.

В SGF кожен хід гри представлений спеціальним записом, який включає символи, що позначають колір каменя (чорний або білий), а також координати на дошці. Наприклад, запис B[gc] вказує на розміщення чорного каменя в клітинці, що відповідає координатам "g" (7-й стовпець) і "c" (3-й рядок) на стандартній дошці 19x19. Такий запис дозволяє чітко визначити місце розташування кожного каменя на дошці гри.

Додатково, формат SGF також дозволяє зберігати інші важливі атрибути гри, такі як назва гри, дата початку, інші параметри правил гри чи результати, що робить його універсальним для збереження та аналізу даних партій Го. Можливість зберігати історію ходів і метадані в одному файлі сприяє гнучкості й ефективності використання SGF у контексті штучного інтелекту та машинного навчання, оскільки він дозволяє моделям зчитувати не лише самі ходи, але й додаткову інформацію, що може бути корисною для вдосконалення прогнозів чи стратегічних рішень.

Такі дані, хоча і є зрозумілими для людини, не можуть бути безпосередньо використані для навчання нейронних мереж, оскільки вони не містять числових представлень або структур, зручних для обробки комп'ютерними алгоритмами. Тому для адаптації цих даних до використання в мережевих моделях, ми застосовуємо метод одногарячого кодування (one-hot encoding). Цей метод дозволяє перевести

кожну позицію на дошці в унікальний вектор, де кожен елемент вектора представляє певну можливість на цій позиції (наприклад, порожнє поле, чорний камінь або білий камінь).

Процес кодування передбачає створення вектора для кожної клітинки дошки, де кожна позиція буде представлена вектором певної довжини, що включає індекси для довжини та ширини дошки. Це дозволяє нейронній мережі мати чітке уявлення про розташування каменів на дошці та їхні взаємозв'язки, що є необхідним для подальшого навчання. Як видно з Алгоритму 1, кожен хід гри Го буде перетворений на вектор, який буде подаватися на вхід до моделі, що дозволить нейронній мережі навчитися на основі цих даних передбачати наступні ходи або оцінювати поточний стан гри.

Алгоритм 1 Кодування даних Го у векторі

Вхідні дані: стан гри в поточній грі, який включає кортеж позиції ходу на дошці Го $[\text{tuple}(x_1, y_1) \dots, \text{tuple}(x_n, y_n)]$, і розмір плати.

Вихід: плата тензор з 11 плоскими характеристиками v .

1: Initialize board tensor with the size of $19 \times 19 \times 19$ zero vector vv .

2: **if** $\text{tuple}(x_{i+1}, y_{i+1})$ is black stone **do**

3: Add feature: $v[8]=1$

4: **else** $v[9]=1$

5: **for** $r = 1$ to range (1 to the length of the board)

6: **for** $c = 1$ to range (1 to the width of the board)

7: $p = \text{position tuple}(\text{row}=r+1, \text{col}=c+1)$

8: Find $\text{tuple}(x_i, y_i)$ whether has a stone group

9: **if** $\text{tuple}(x_i, y_i)$ do not in a stone group **do**

10: **if** $\text{tuple}(x_i, y_i)$ is not in ko situation (illegal move) **do**

11: $v[10][r][c]=1$

```

12:     else liberty_plane = min(4, stone's liberty in group) - 1
13:         if color of Go group == white do
14:             liberty_plane += 4
15:             v[liberty_plane][r][c]=1

```

Для підвищення ефективності роботи моделі, ми вирішили внести додаткові функції у вектор, що представляє ігрові позиції, щоб забезпечити більш глибоке розуміння ситуації на дошці. Одним з важливих аспектів гри Го є так звані "крайові камені", тобто камені, які знаходяться на межах гри і можуть мати особливі взаємозв'язки із іншими каменями, зокрема через обмежену кількість вольностей. Щоб врахувати цю важливу особливість, ми додаємо першу площину вектору, яка спеціально описує крайові камені на дошці.

Далі ми вводимо чотири площини для чорних каменів, які описують їх вольності, тобто кількість порожніх суміжних клітинок, які ці камені можуть контролювати. Це важлива характеристика, оскільки вольності визначають стабільність каменя та можливості його "живучості". Тому ми виділяємо окремі площини для чорних каменів з одна, дві, три або чотири вольностями. Ці площини дають моделі змогу розуміти, які камені знаходяться в більш вразливих позиціях (мають менше вольностей), а які - у більш вигідних.

Аналогічно, ми додаємо ще чотири площини для білих каменів, які описують їх вольності. Це дозволяє моделі розпізнавати аналогічні структури на стороні супротивника, що є важливим для правильного оцінювання ситуації та прийняття стратегічних рішень.

Крім того, важливу роль в процесі гри можуть грати ситуації, які є частинами специфічних правил Го, наприклад, "ко" — особлива ситуація, коли обидва гравці можуть захоплювати одні й ті ж камені, що може призвести до циклічних ситуацій.

Для відображення цієї ситуації ми додаємо ще одну площину, що дозволяє моделі розпізнавати такі моменти і приймати правильні рішення.

Цей вдосконалений енкодер з 11 площинами забезпечує більш точне та багатше представлення ситуації на дошці, що призводить до значного поліпшення характеристик моделі. Включення цих додаткових функцій допомагає нейронній мережі краще розуміти ігрові патерни та дозволяє підвищити точність її прогнозів, що має важливе значення для ефективного навчання й прийняття стратегічних рішень у грі Го.

У частині DCNN ми спроектували нейронну мережу, що складається з восьми згорткових шарів, усі з активаціями ReLU, що дозволяє мережі виявляти складні патерни в ігрових даних. Ці шари, як показано на рисунку 2.2, забезпечують поступове зменшення розміру простору даних, виділяючи найбільш важливі особливості гри. Важливою особливістю є те, що ми не додавали шари об'єднання (pooling) між згортковими шарами, оскільки в процесі гри на дошці поступово з'являється все більше каменів. Це означає, що кожне нове положення каменя може суттєво змінювати характеристику стану гри, тому всі деталі дошки, включаючи камені, що знаходяться на її краях, повинні враховуватися на всіх етапах навчання. Щоб уникнути ситуацій, коли вихід з високих шарів стає надзвичайно малим і не містить достатньо корисної інформації, ми впровадили нульову площадку (zero-padding) перед кожним згортковим шаром. Це дозволяє зберігати важливі просторові характеристики навіть на межах дошки, де інформація може бути обмежена або неповною. Окрім того, для забезпечення повного охоплення інформації з кожної клітинки дошки, ми встановили значення кроку (stride) на 2, що дозволяє більш глибоко захоплювати структурні особливості, що важливо для прогнозування правильних стратегічних рішень.

Таким чином, формула для розрахунку розміру графіка ознак, що формується після згортки, виглядає наступним чином:

$$\omega' = \frac{(x+2n-k)}{s}, \quad (2.1)$$

де x – розмір вхідної матриці;

k – розмір ядра згортки;

s – позначає довжину кроку, а кількість шарів з нульовим відступом становить p .




Рис. 2.2 Архітектура частини DCNN

На відміну від традиційних фреймворків, де часто використовуються повністю зв'язані шари для отримання остаточного представлення даних, в нашій моделі ми застосовуємо глобальний шар усереднення об'єднання (Global Average Pooling, GAP). Цей підхід має кілька важливих переваг, зокрема він дозволяє значно зменшити кількість параметрів, що робить модель більш стабільною і менш схильною до перенавчання. Крім того, глобальний шар усереднення ефективно зберігає важливі просторові характеристики, які були витягнуті за допомогою попередніх згорткових шарів.

Глобальний шар усереднення об'єднання працює, здійснюючи середнє значення для кожного каналу (характеристики) по всіх просторових координатах (рядках і стовпцях) після того, як проходять через попередні згорткові шари. Це дозволяє зберегти глобальні ознаки, які важливі для класифікації або подальших етапів обробки. Водночас він також дозволяє ефективно злиття різних типів ознак, що були витягнуті з графової структури та зображень.

Рівняння для глобального усереднення об'єднання можна записати наступним чином:

$$V_f = \frac{\sum_{h=1}^H \sum_{w=1}^W m_{h,w,f}}{H \times W}, \quad (2.2)$$

де m – карта ознак з вхідних даних Go після згорткових шарів;

h і w – довжина і ширина вектора даних, відповідно;

f – кількість каналів ознак.

Через використання глобального середнього шару об'єднання (Global Average Pooling, GAP), функціонування тензора вхідних даних Go, що має розміри $h \times w \times f$, полягає у зменшенні просторових вимірів (висоти h і ширини w) до одного вектору ознак з розміром f -dim. Це дозволяє значно зменшити кількість вагових параметрів, що особливо важливо для великих і складних моделей, де число параметрів може швидко зрости до небажаних величин, що веде до перенавчання та збільшення обчислювальних витрат.

Основна перевага цього підходу полягає в здатності зберігати суттєві просторові залежності, які є критичними для ігор з високою складністю, таких як Go. Під час перетворення даних у компактний вектор ознак цей процес дозволяє зберігати найважливіші аспекти, що стосуються взаємодії елементів гри, таких як позиції каменів на дошці, їхні зв'язки, можливі загрози або стратегічні можливості. Така трансформація даних дозволяє подолати обмеження традиційних методів, які можуть не вмещувати всі важливі залежності між елементами гри.

Особливо важливою є роль глобального середнього шару, який агрегує інформацію з усієї дошки, дозволяючи отримати зведену картину гри, де кожен вектор ознак містить лише найістотнішу інформацію. Це значно знижує обчислювальні витрати та сприяє більш швидкому та точному процесу навчання. Замість того, щоб зберігати великі обсяги даних про кожен окремий піксель або камінь на дошці, глобальний середній шар об'єднує ці дані, зберігаючи лише ті характеристики, які є критичними для прогнозування ходів і оцінки стратегії.

Цей метод особливо корисний для стратегічних ігор, де важливо зберігати взаємозв'язки та просторові залежності між елементами гри. У випадку Го, наприклад, навіть незначні зміни в розташуванні каменів можуть мати вирішальне значення для подальших ходів. Глобальне агрегування дозволяє моделі фокусуватись на ключових аспектах гри, таких як групи каменів, їх взаємні загрози і потенційні захоплення, що суттєво підвищує її точність у прогнозуванні.

Таким чином, результат цього процесу — вектор ознак розміру fff-dim — є значно менш об'ємним, але зберігає всю суттєву інформацію про гру, зокрема стратегічні варіанти, що робить модель більш ефективною, а обчислювальні витрати мінімальними. Це також дозволяє застосовувати подібні гібридні нейронні мережі для роботи з більш складними іграми, що мають різні просторові або структурні вимоги.

Скорочення кількості вагових параметрів за допомогою глобального середнього шару або подібних методів не тільки зменшує ризик перенавчання, але й покращує загальну здатність моделі до узагальнення. Перенавчання — це коли модель надмірно "підлаштовується" під тренувальні дані, втрачаючи здатність добре працювати на нових, невідомих даних. У випадку складних ігор, таких як Го, це може призвести до того, що модель "запам'ятає" лише конкретні стратегії або ходи з тренувальних даних, не здатна прогнозувати ефективно в інших ситуаціях або на нових дошках.

Зменшення кількості параметрів дозволяє уникнути надмірної складності в моделі, що робить її більш ефективною та швидкою при обробці нових даних. Зокрема, це важливо для великих наборів даних, де обчислювальна ефективність є критичною. Коли кількість вагових параметрів зменшується, модель стає менш схильною до шуму в даних, що також знижує ймовірність перенавчання.

Ще однією суттєвою перевагою є масштабованість такої моделі. Оскільки збереження лише ключових ознак гри дозволяє відмовитися від надмірної кількості параметрів, модель здатна працювати з різними іграми або навіть адаптуватися до нових варіацій правил вже існуючих ігор. Це дає змогу застосовувати таку архітектуру в багатьох контекстах, зокрема для адаптації до нових стратегічних ігор або навіть змін у правилах старих. Це створює універсальний інструмент, який може працювати в різних сценаріях без потреби суттєво змінювати структуру чи перенавчати модель заново.

Завдяки цим властивостям гібридні моделі, що поєднують різні нейронні мережі, стають не лише потужними для конкретних задач, але й здатними до швидкої адаптації та масштабування для нових ігор і умов.

2.2 Побудова структури даних графіка

Традиційні плоскі об'єкти не можуть представляти зв'язок між каменями, тому нам потрібно представити Го у вигляді графічної структури для вивчення цих ознак. Через незмінність дошки Го щодо обертання та дзеркального відображення, положення дошки може бути виражене у вигляді повного представлення графіка (FGR) зі структурою сітки 19×19 на графіку. Однак це представлення займає достатньо місця в пам'яті, а ефект виразу подібний до планарної мережевої структури, яка використовується для навчання DCNN. Щоб покращити цей підхід, ми представляємо дошку Го у загальному графіку долі (CFG), який представляє сусідні камені з однаковою свободою разом як вузол, і з'єднання цих кластерів каменів як одне ребро на основі правил «групи» Го. Це уявлення походить від того, що прямі лінії каменів одного кольору на дошці повинні або вижити разом, або втратити свою свободу і всі бути захоплені, тому ці камені мають спільну долю на дошці. Метод представлений наступним чином:

$$(v_1, v_2, \dots v_n) \rightarrow V, \quad (2.3)$$

$$(e_1 \in v_1, e_2 \in v_2, \dots e_n \in v_n) \rightarrow E \in V, \quad (2.4)$$

де v – каменем у кам'яній групі, що поділяє спільну свободу;

e – з'єднання одних і тих же каменів з іншою групою в своїй групі.

CFG не тільки зберігає характеристики окремого каменю, але і зменшує простір графа. Більше того, це представництво також чудово визначає правила території щодо перемоги в Го.

Дані Го не тільки були вбудовані в структуру CFG; ми також вручну додали деякі функції до CFG на основі правил Го. Існує шість особливостей вузлів і одна реберна особливість, які допомагають моделі краще вивчити структуру графа, як показано в таблиці 2.1.

Таблиця 2.1

Особливості роботи CFG

Тип	Функції	Кількість векторів	Деталі
Вузол	Чорний, білий, порожній	3	Колір каменів-займаних перехресть
Вузол	За свободу в кам'яній групі	4	Свобода в кам'яній групі поділена на загальну кількість каменів
Вузол	Юридичний хід	1	Чи законне переміщення каменю чи ні
Вузол	Повороти ходу	5	Кількість ходів у групі
Вузол	Вигідний хід	1	Чи призведе хід до захоплення каменя суперника

Вузол	Кількість знімків	8	Скільки каменів суперника було захоплено
Край	Взаємини груп	3	Чи є з'єднана група каменів суперником або порожнім пунктом, і якщо це суперник, то чи більша вона за нього

Ці ознаки поділяються на двійкові значення і на різні вектори. Наприклад, що стосується кольору каменю, то чорний, білий і порожній розбиті на три різні вектори і представлені у вигляді двійкових значень. Після вилучення ознак вузлів і ребер, цей підхід може зменшити протиріччя між GCN і плоскими об'єктами.

2.3 Модель розгалуження на основі навчання графів

Дані Го, представлені в CFG, не є евклідовими даними, що означає, що вони не мають інваріантності перекладу, а традиційні моделі глибокого навчання намагаються вивчити їхні особливості. Щоб виявити зв'язок між каменями Го, ми використовуємо нейронну мережу реляційного графа (R-GCN), яка є графовою нейронною мережею, для навчання даних Го, представлених CFG. Спільна доля – графік $g=(v, e)$. v і e представляють вузли (групи каменів) і ребра (з'єднання каменів в групу) відповідно. У попередніх дослідженнях Ralaivola et al. виокремили особливості ігрової стратегії з моделей CFG на основі шляхів перерахування та використовували векторні машини підтримки, щоб допомогти класифікувати ходи експертів. У цій статті ми побудували модель R-GCN з двома згортковими шарами графа для вилучення ознак графа. N представляє кількість груп каменів CFG, а матриця A представляє її матрицю суміжності, яка також є відношенням між групами. X - це $N \times D$ -розмірна матриця, що складається з ознак цих груп, де D - матриця ступенів матриці суміжності, $D_{ii} = \sum_j A_{ij}$. X і A - це входи в нашій моделі на

основі розділу GCN. Таким чином, як шар нейронної мережі, GCN поширюється між шарами наступними способами [28]:

$$f(H^L, A) = \sigma\left(D^{-\frac{1}{2}} \tilde{A} D^{-\frac{1}{2}} H^L W^L\right), \quad (2.5)$$

де $\tilde{A} = A + I$;

$D^{-\frac{1}{2}} \tilde{A} D^{-\frac{1}{2}}$ – ядро спектральної згортки є використання симетричних нормальних матриць Лапласа, які представляються у вигляді.

GCN оновлює прихований стан вузла, зважуючи його сусідні ознаки та власні особливості [28]. Прихований стан кожного вузла i , що проходить через шар згортки графа традиційного GCN, можна виразити наступною формулою:

$$h_i^{(l+1)} = \sigma\left(\sum_{j \in N_i} \frac{1}{c_i} W^{(l)} h_j^{(l)}\right), \quad (2.6)$$

де $W^{(l)}$ – спільною вагою всіх ребер у l шару;

h_j – це прихований стан сусіда вузла i ;

$\frac{1}{c_i}$ – константа регуляризації;

σ – функцією активації.

Однак співвідношення між різними вузлами каменів є зваженим, яке розраховується на основі порівняння кількості каменів G_i , що містяться між вузлами різного кольору.

Щоб агрегувати інформацію про ребра в загальному графі долі, R-GCN робить удосконалення на вихідній основі, так що ребра різних відношень використовують різну вагу, тільки ребра одного типу відношення r використовуйте однакову вагу

відображення $W_r^{(l)}$. Тому формула прихованого стану вузла представляється наступним чином:

$$h_i^{(l+1)} = \sigma \left(W_0^{(l)} h_i^{(l)} + \sum_{r \in R} \sum_{j \in N_l^r} \frac{1}{c_{i,r}} W_r^{(l)} h_j^{(l)} \right), \quad (2.7)$$

де $W_0^{(l)} h_i^{(l)}$ - оновлення інформації вузла i ;

N_l^r – множина сусідніх вузлів вузла i у співвідношенні $r \in R$.

За допомогою операції згортки моделі R-GCN передається інформація між сусідніми вузлами, а також фокусується зв'язувальний зв'язок між вузлами. Цей метод дозволяє ефективно витягти співвідношення між каменями і просторове співвідношення між територіями в дошці. Потім ми додаємо глобальний максимальний шар об'єднання до останнього шару, щоб підготуватися до агрегації плоских об'єктів. Алгоритм 2 показує запропонований метод прогнозування руху.

Алгоритм 2 Запропонований метод прогнозування рухів

Ввід: Плоский вектор даних гри Го D ; Розмір партії s ; Число епох модельній підготовці E ; Швидкість навчання η ; Кількість шарів нейронних мереж графа l .

Вивід: The accuracy of move prediction.

1: Точність прогнозування ходу.

1: Модель тренування DCNN за навчальними даними вектора 11 ознак площини D .

2. Точне налаштування моделі DCNN за допомогою валідації набору даних.

3. Згенеруйте f -dim карта характеристик літака через глобальний середній пул.
- 4: Побудуйте CFG, $G = [x, edgeindex, pos, edgeattr, y]$ шляхом ручного додавання функцій вузлів і периферійних функцій на основі ігрової архітектури Го.
- 5: **for** $e = 1$ to E **do**
- 6: Тренування на моделі R-GCN у l шари.
7. Розрахуйте втрати на основі функції втрати крос-ентропії та оновіть вагу W через SGD.
- 8: **end for**
- 9: Розрахуйте кінцевий вихід за допомогою роботи злиття та проведіть прогнозування ходу

2.4 Гібридна модель з функцією Feature Fusion

Гібридна мережа поєднує в собі переваги графових згорткових мереж (GCN) і глибоких згорткових нейронних мереж (DCNN). Модель DCNN витягла плоскі особливості даних Го, а GCN вивчила знехтувані особливості гри, моделюючи залежності між ігровими елементами та складною інформацією про територію. Щоб об'єднати ці дві функції, ми додаємо операцію злиття ознак для об'єднання функцій і передачі їх на кінцевий повністю пов'язаний рівень для прогнозування ходів. Процес злиття з двома дескрипторами ознак можна описати наступним чином:

$$F = C^w \cdot (I \oplus \mu G), \quad (2.8)$$

де F – особливість злиття;

C^w – параметр ваги в повністю пов'язаному шарі;

I і G – це ознаки, які витягуються в DCNN і R-GCN відповідно.

Символ $\oplus$ позначає оператор у злитті ознак для конкатенації. Символ μ представляє коефіцієнт злиття для збалансування ознак з площини та графіка, і ми встановили його на 0,7 після експерименту.

Нарешті, ми використовуємо шар softmax для прогнозування ймовірності ходів у кожній позиції дошки. Щоб обчислити функцію softmax для вектора $x=(x_1, x_2 \dots x_l)$ з повного рівня зв'язку експоненціальна функція застосовується до кожного компонента для обчислення e_i^x ; потім кожне з цих значень слід нормалізувати:

$$\text{softmax}(x_i) = \frac{e_i^x}{\sum_{j=1}^l e_j^x}, \quad (2.9)$$

де кожне з цих значень є сумою всіх значень, що підлягають нормуванню.

За визначенням, компоненти функції softmax є невід'ємними і в сумі дорівнюють 1, тобто софтмакс повертає ймовірності.

У зв'язку з тим, що гра в го має максимум 361 можливий хід, функція втрати крос-ентропії використовується для оптимізації параметрів для навчання гібридної моделі. Вона може виражатися в наступному:

$$L = \frac{1}{N} \sum_i L_i = - \frac{1}{N} \sum_i \sum_{c=1}^M y_{ic} \log p_{ic}, \quad (2.10)$$

де M – позначає кількість ходів на дошці;

символ p_{ic} – ймовірність ходів.

Якщо істинний клас вибірки i дорівнює c , y_{ic} приймає 1, в іншому випадку приймає 0.

3 ЕКСПЕРИМЕНТАЛЬНІ ДОСЛІДЖЕННЯ ГІБРИДНОЇ МОДЕЛІ

У цьому розділі ми детально описуємо гібридну модель, яка поєднує в собі дві потужні архітектури – глибоку згорткову нейронну мережу (DCNN) та графову згорткову мережу (GCN). Ця інтеграція дозволяє нашій моделі обробляти як плоскі зображення, так і структуровані дані у вигляді графів, що робить її ідеальною для прогнозування стратегічних ходів у грі Go. Для тестування моделі ми використали набір даних KGS Go, що містить записи висококваліфікованих ігор, що дозволяє оцінити ефективність моделі в умовах реальних стратегічних ситуацій.

Щоб перевірити доцільність і ефективність нашої гібридної моделі, ми порівняли її з моделлю DCNN, яка була використана в оригінальному дослідженні. Модель DCNN сама по собі може успішно виконувати задачу прогнозування ходів на основі візуальних ознак гри, однак її здатність враховувати глобальні залежності між різними частинами дошки обмежена. У порівнянні з нею, наша гібридна модель, об'єднуючи переваги як глибоких згорткових мереж для обробки зображень, так і графових нейронних мереж для аналізу просторових і стратегічних взаємозв'язків, показала значно кращі результати у прогнозуванні більш складних ходів.

Точність прогнозування рухів експерта була використана як головний критерій для оцінки роботи нашої моделі. Важливими аспектами є не тільки точність прогнозів, але й здатність моделі враховувати контекст гри та робити прогнози, що відповідають стратегічним рішенням висококваліфікованих гравців. Зокрема, ми оцінювали, як наша гібридна модель здатна прогнозувати ходи після кількох попередніх ходів, враховуючи стратегічні патерни, які можуть виникати на різних етапах гри.

Ми також провели серію експериментів, щоб визначити вплив різних параметрів та характеристик нашої гібридної моделі. Це включало дослідження різних архітектурних налаштувань DCNN та GCN, а також експериментування з числом шарів і розмірами фільтрів у згорткових мережах. Такі параметри мали

значний вплив на ефективність прогнозування, оскільки кожен з цих елементів може по-різному впливати на здатність моделі розпізнавати важливі патерни та залежності. Ще одним важливим етапом наших досліджень було оцінювання максимальних переваг використання функцій графіка для прогнозування ходів. Ми вивчали, як включення інформації про структуру графа, що представляє зв'язки між різними елементами гри (наприклад, каменями на дошці), впливає на точність прогнозів. Виявилося, що така інформація має значний вплив на поліпшення прогнозів, оскільки дозволяє моделі розуміти глобальні стратегії та взаємодії між різними частинами дошки.

Окрім самої точності прогнозів, ми також звернули увагу на довірчі інтервали прогнозованих значень. Оскільки гра в Go є складною стратегією з багатьма можливими варіантами, важливо мати здатність не лише передбачати найкращі ходи, а й оцінювати рівень невизначеності прогнозу. За допомогою аналізу довірчих інтервалів ми змогли оцінити рівень впевненості моделі в своїх прогнозах, що дозволяє краще розуміти, коли модель може бути менш точна або надавати більше варіантів для вибору стратегії.

3.1 Набір даних експерименту

У цьому експерименті ми використовували набір даних Go, який був зібраний з сервера KGS Go, доступного за вебсайтами <http://u-go.net/gamerecords/> (станом на 28 липня 2023 року). Цей набір містить записи ігор, що були зіграні високопоставленими гравцями в період з 2001 по 2019 рік. Загалом набір включає близько 179 689 експертних ігор (приблизно 4 мільйони місць ходів), зіграних на дошках розміру 19×19 , у яких хоча б один з гравців мав рейтинг 7 дан або вище, або в яких обидва гравці мали по 6 дан. Цей набір є вкрай корисним для навчання та тестування моделей, що працюють із стратегічними іграми, оскільки він містить

записи ігор висококваліфікованих гравців, які можуть служити чудовими прикладами для розпізнавання складних стратегій та прийняття рішень.

На основі попереднього дослідження ми здійснили поділ цього великого набору даних на три основні підмножини для тренування, валідації та тестування моделей. Згідно з розподілом, 90 % всіх даних були відведені для тренувального набору, 2 % для валідаційного набору і 8 % для тестового набору. Такий розподіл дозволяє забезпечити достатню кількість даних для навчання моделі, а також для моніторингу її ефективності під час налаштування та підбору гіперпараметрів.

Валідаційний набір даних використовується для регулювання гіперпараметрів, що дозволяє нам здійснити точне налаштування моделі, моніторячи її роботу на етапі навчання і знаходячи найкращі параметри, які забезпечують максимальну ефективність. Це критично важливо для забезпечення точності та узагальненості моделі, оскільки неправильне налаштування може призвести до перенавчання або недостатнього навчання.

Оскільки в грі Go ходи в межах однієї гри тісно пов'язані між собою і можуть залежати один від одного, важливо було, щоб ми не розглядали окремі ходи гри як незалежні одиниці. У нашому підході всі дані гри тасуються як єдине ціле, що дозволяє враховувати зв'язки між ходами і стратегічними рішеннями, прийнятими протягом всієї гри. Це також важливо для моделювання складних стратегій, оскільки кожен хід може мати важливе значення в контексті попередніх і наступних ходів.

Таким чином, набір даних був підготовлений таким чином, щоб зберегти важливі залежності між ходами, що дає змогу більш точно вивчити стратегії гри та взаємодії між гравцями, особливо в контексті глибоких навчальних моделей, які вимагають аналізу складних патернів і довгострокових залежностей у грі.

3.2 Тонкощі реалізації

Гібридні мережі були побудовані на фреймворку PyTorch та Python-3.9 з процесором Intel Core i7 та графічним процесором NVIDIA GTX 3050Ti. Щоб ще більше покращити продуктивність моделі прогнозування руху, ми використовували стохастичний градієнтний спуск (SGD) як оптимізатор. Оптимізатор SGD був встановлений з коефіцієнтом навчання 0,001, коефіцієнтом загасання 0,1 % і імпульсом 90 %. Гібридна модель складається з моделей DCNN і GCN, а також train з розміром партії 128 на 10 епох. У таблиці 3.1 наведено подробиці про кількість шарів, а також про розмір і кількість фільтрів у кожній моделі.

Таблиця 3.1

Конфігурація гібридного режиму

Модель	Шар	Кількість фільтрів	Розмір фільтра
DCNN	3 шари	256	7x7
	5 шарів	128	5x5
	2 шари	192	5x5
R-GCN	1 шар	256	

3.3 Результати експерименту

Під час цього аналізу ми провели кілька експериментів, щоб переконатися, що результати були стабільними та не стохастичними. Базова модель DCNN використовується як базова лінія, за якою можна порівняти модель злиття з моделлю GCN, а точність прогнозування ходу є критерієм оцінки, за яким ми оцінюємо надійність нової моделі. У зв'язку з тим, що набір даних був порушений, а сила (ранг) гравців у Го була нерегулярною по відношенню один до одного в записах Го, було складно, щоб ранг ігор у тренувальному наборі та тестовому наборі був

однаковим, тому ми провели середню обробку. Ранг представляє рівень Го гравців; чим вищий ранг, тим потужніша сила гравця в го. Середнє і стандартне відхилення всіх експериментів були розраховані для оцінки того, чи була точність в розумному діапазоні. Ми також обчислюємо стандартну похибку (stderr) точності експерименту за допомогою випадкової вибірки, що робить експеримент більш переконливим.

Щоб перевірити підвищення продуктивності гібридних мереж у порівнянні з традиційною DCNN, ми провели експерименти, в яких модель CNN-GCN і традиційна DCNN мали таку ж кількість шарів згортки та інших параметрів, як і модель DCNN гібридної моделі. Ми виміряли точність прогнозування ходу в навчальній вибірці та тестовій вибірці для 10 епох, а втрати кожної епохи показані на рисунку 3.1.




Рис. 3.1 Втрати кожної епохи

Середнє і стандартне відхилення експерименту по прогнозуванню ходу використовуються для оцінки строгості експерименту, як показано на рисунку 3.2.




Рис. 3.2 Середнє і стандартне відхилення від випадковості пробігає

У таблиці 3.2 показана різниця в точності між двома моделями за китайськими правилами.

Таблиця 3.2

Прогнозування руху в різних моделях

Модель	Тестовий набір даних			Набір даних про потяг		
	Точність	Ранг	Stderr	Точність	Ранг	Stderr
DCNN	46.8 %	6.87	± 1.2 %	47.2 %	6.35	± 1.7 %
DCNN-(R-GCN)	48.7 %	6.87	± 0.9 %	49.8 %	6.35	± 1.9 %

Завдяки навчанню, запропонована нами модель може досягти максимальної точності майже 50% у прогнозуванні ходів на наборі даних KGS GO. Варто зазначити, що при тій же перевірці тестового набору продуктивність гібридної моделі покращується в порівнянні з традиційною моделлю DCNN, а точність збільшується приблизно на 2 %. Наскільки нам відомо, раніше відома робота над набором даних KGS використовувала аналогічний алгоритм з використанням меншої

8-шарової моделі DCNN і досягла приблизно 45 % точності щодо прогнозування руху [15]. Незважаючи на те, що набір даних, застосований нашою моделлю, досяг своєї останньої версії в порівнянні з попередніми, прогнозовані результати все ще знаходяться в порівнянному діапазоні. У порівнянні з результатом прогнозування традиційної моделі DCNN, точність нашої гібридної моделі перевищує 4,43 %.

Для перевірки впливу кореляцій між каменями Го на стратегію руху ми провели кілька експериментів із застосуванням Graph-based Co-Features (CFG) для моделювання взаємодії між групами каменів. Цей підхід дозволяє краще відобразити стратегічні залежності між різними частинами дошки, що значно покращує розуміння того, як один камінь може впливати на інші в контексті гри.

Як показано в таблиці 3.3, використання CFG для побудови коефіцієнтів ваги між групами каменів дійсно демонструє значне покращення в точності прогнозування. Після тренування на нашій гібридній моделі, яка комбінує DCNN та GCN, стало очевидно, що CFG дозволяє виявити стратегічні патерни, які традиційні методи не можуть обробити з такою ефективністю. Зокрема, GCN здатна виявляти взаємозв'язки між групами каменів, що, в свою чергу, підвищує точність прогнозування на основі більш комплексного розуміння гри.

Цей ефект кореляції також демонструє, як GCN може працювати з графами, де кожен камінь на дошці сприймається як вузол, а зв'язки між каменями — як ребра, що дозволяє моделі враховувати більш глибокі стратегічні зв'язки. У підсумку, використання CFG для побудови кореляційних відносин між каменями виявилось важливим кроком до покращення ефективності прогнозів у нашій гібридній моделі, дозволяючи точніше передбачати наступні ходи навіть у складних ігрових ситуаціях.

Точність моделей з різними характеристиками

Модель	Функції	Точність	Stderr
DCNN	Ніхто	43.1%	$\pm\pm 3.0\%$
DCNN	11	46.8%	$\pm\pm 1.2\%$
DCNN–GCN	11 особливостей площини Функція No Edge	47.9%	$\pm\pm 1.5\%$
DCNN–(R-GCN)	11 особливостей площини Функція Have Edge	48.7%	$\pm\pm 1.9\%$

Крім того, побудова плоских особливостей у векторних даних також вплинула на вивчення гібридної моделі. Виходячи з принципу R-GCN, виділення ознак на загальному графіку долі впливає лише на розподіл ваги між різними співвідношеннями, а інші параметри нічим не відрізняються від моделі GCN. Це свідчить про те, що модель DCNN має слабкість в аналізі групових відносин в ігровій стратегії, але R-GCN може підвищити продуктивність звичайної моделі DCNN в цьому напрямку. У зв'язку з перемішуванням набору даних і випадковістю експерименту ми також розраховали середнє значення та стандартне відхилення кожної моделі після кількох експериментів, як показано на рисунку 3.3.




Рис. 3.3 Середнє і стандартне відхилення моделей з різними характеристиками

На додаток до точності ходів як критерію для оцінки моделі, ми також розділили гру на 10 етапів, кожен з яких містить 36 ходів експертів (адже максимальна кількість ходів на дошці становить лише 361), щоб перевірити продуктивність гібридної моделі в грі. На рисунку 3.4 ми можемо побачити, що оскільки на початку на дошці дуже мало каменів, моделі важко витягти корисну інформацію, а співвідношення між каменями в загальному графіку долі втратить свою функцію. До тих пір, поки не буде досягнута половина гри, з поступовим збільшенням числа каменів Го на дошці, вилучення GCN особливостей відносин на графіку починає впливати на навчання моделі і покращувати продуктивність гібридної моделі. Це свідчить про те, що співвідношення між каменями має значний вплив на оцінку стратегії гри. Таким чином, чим більше проходить гра, тим краще запропонована нами модель показує себе в прогнозуванні ходів.




Рис. 3.4 Прогнози ходів експертів на кожному етапі

Далі впевнений прогноз в межах числа n вгадування також є гідним критерієм, за яким можна оцінювати гібридну мережу. Якщо n є невеликим, це означає, що мережа може передбачити результат ходів експерта в межах невеликого довірчого інтервалу. Як показано на рисунку 3.5, прогнози дій експертів стають точнішими з більшою кількістю вгадувань і сходяться приблизно після 25 вгадувань.




Рис. 3.5 Топ-n прогнозів дій експертів

Це свідчить про те, що ймовірність прогнозування правильних ходів експертів входить до топ-25 для гібридної моделі. Однак у реальній грі суддя не дасть мережі ще 25 шансів вгадати на дошці Го; тому, порівняно з реальними експертами з 7 Dan, у запропонованій нами моделі все ще є помітний розрив. Як допоміжний інструмент для побудови ігрових стратегій, прогнозування гібридної моделі після кількох спроб може допомогти ігровим програмам ефективно скоротити простір пошуку.

3.4 Теоретичне застосування в інших стратегічних іграх

Виходячи з результатів експериментів, наведених раніше, де ми застосовували нашу гібридну модель до гри в го, можна стверджувати, що вона демонструє відмінну продуктивність і має значний потенціал для розв'язання стратегічних задач у інших іграх, що мають подібну складність та вимоги до прийняття рішень. Гра в го, як одна з класичних стратегічних ігор, є своєрідною вихідною точкою для перевірки наших гіпотез щодо ефективності цієї моделі. Враховуючи її популярність серед інших стратегічних ігор, можна сказати, що багато стратегічних ігор базуються на принципах, схожих до тих, що застосовуються в го, таких як просторові стратегії,

взаємодія між агентами, управління територією та інші елементи, які складають основи кожної такої гри.

Завдяки універсальності та потужності нашої гібридної моделі, її потенціал для вирішення складних стратегічних задач не обмежується лише грою Go, але може бути успішно адаптований до різних стратегічних ігор, що мають подібні характеристики та вимоги. Ось кілька прикладів, які демонструють, як наша модель може бути використана для вирішення проблем у контекстах, що є значно складнішими за Go:

Приклад 1: "Космічні чотири шахи" У цій грі, де фігури розташовані у тривимірному просторі, важливо не тільки визначити їх точне місце на дошці, але й аналізувати їх взаємодії. Враховуючи, що кожна фігура може переміщатися в кількох напрямках і взаємодіяти з іншими елементами гри в тривимірному просторі, наша гібридна модель здатна обробляти ці складні зв'язки. Використовуючи GCN для побудови графів, які відображають взаємозв'язки між фігурами, наша модель може прогнозувати рухи, враховуючи не тільки позиції фігур, а й їхні взаємодії в різних вимірах. Така модель дозволяє ефективно прогнозувати ходи в складних, багатовимірних ігрових умовах.

Приклад 2: "League of Legends" та "Dota 2" Ці популярні багатокористувацькі стратегії вимагають від гравців швидкої адаптації до змін на карті, взаємодії між героями та застосування командної тактики. Гібридна модель, поєднуючи CNN для обробки візуальної інформації з карти та GCN для моделювання взаємозв'язків між героями, може ефективно аналізувати та прогнозувати як індивідуальні стратегії героїв, так і загальні командні стратегії. Цей підхід дозволяє прогнозувати рухи героїв, враховуючи як їхні індивідуальні можливості, так і стратегічну тактику команди в цілому. Водночас, як і в Go, важливо швидко

адаптуватися до змін у грі, і наша модель допомагає в цьому завдяки здатності враховувати динамічні та складні взаємодії.

Приклад 3: "Starcraft" та "Age of Empires" У цих класичних стратегічних іграх величезна кількість одиниць та різноманітних елементів взаємодіє на великих картах. Наш гібридний підхід дає змогу ефективно обробляти дані карти за допомогою CNN, а також аналізувати взаємозв'язки між різними одиницями, використовуючи GCN. Це дозволяє моделювати та прогнозувати ефекти територіального впливу, а також аналізувати, як взаємодія груп одиниць на різних частинах карти впливає на загальну стратегію. Модель може не тільки передбачити, де і коли гравець може застосувати свої ресурси, але й допомогти оптимізувати стратегію з урахуванням глобальних ефектів на карті, таких як зміни місцевості або атакуючі угруповання ворога.

Ці приклади показують, що завдяки здатності нашої гібридної моделі враховувати як просторові, так і стратегічні взаємодії, вона може бути успішно застосована для вирішення складних завдань у багатьох стратегічних іграх. Це дозволяє не лише покращити прогнози для конкретних ігор, таких як Go, але й адаптувати модель для більш складних і багатогранних стратегій, що мають великі, динамічні і взаємопов'язані елементи.

ВИСНОВКИ

У цій роботі ми розробили інноваційну гібридну мережу, яка поєднує можливості графових нейронних мереж (GCN) і глибоких згорткових нейронних мереж (DCNN), і застосували її для вирішення завдання стратегії в класичній стратегічній грі — грі в го. Наше дослідження має на меті перевірити ефективність запропонованої моделі, а також показати, як вона може змінити підхід до розвитку стратегічних рішень у відеоіграх, зокрема у тих, що включають складні залежності між різними елементами гри.

Гібридна модель, яку ми розробили, використовує найкраще з обох світів. З одного боку, глибокі згорткові мережі (DCNN) застосовуються для вилучення плоских ознак, що дозволяє ефективно обробляти зображення та інші типи даних, де важлива фільтрація на рівні пікселів або інших низькорівневих характеристик. З іншого боку, графові нейронні мережі (GCN) вводяться для обробки даних структур графа, побудованих відповідно до специфіки правил гри, що дозволяє вивчати взаємозв'язки та залежності між сутностями в грі, такими як гравці, території, ресурси та стратегічні позиції.

Гра в го, яку ми використали як приклад для тестування нашої моделі, є складною стратегією з великою кількістю можливих варіантів розвитку подій. Це дає можливість продемонструвати силу нашого фреймворку, але водночас показує й обмеження, які можуть бути вирішені в подальших дослідженнях. Важливо зазначити, що хоч ми і застосували гру в го як тестовий випадок, пропонується гібридна модель виявляє значний потенціал і для інших стратегічних ігор, де взаємодія між гравцями та іншими сутностями стає визначальним фактором для прийняття рішень.

Переваги нашої гібридної моделі:

1. Покращення ідентифікації стратегічних ситуацій: Модель здатна виявляти ключові формації, які сигналізують про сильні та слабкі сторони кожної зі стратегій. Цей підхід дозволяє отримати більш комплексну картину гри, зосереджуючись не тільки на окремих ходах, але й на довгострокових стратегічних цілях, враховуючи не лише окремих гравців, а й командну взаємодію.
2. Оцінка гри на кількох рівнях: Гібридна модель здатна враховувати різні рівні гри, враховуючи як глобальні, так і локальні зв'язки між ігровими елементами. Це дозволяє враховувати важливі аспекти, які можуть бути неочевидними для традиційних моделей, такі як територіальний вплив і ресурси на окремих ділянках ігрового поля.
3. Адаптація до різних етапів гри: Оскільки стратегічні ігри часто мають кілька етапів (початковий, середній, фінальний), важливо мати здатність адаптувати стратегію до змінюваних умов гри. GCN дозволяє вивчати довгострокові залежності, які важливі на пізніших етапах гри, тоді як DCNN дає можливість адаптуватися до більш тактичних рішень на початкових етапах.

Ці переваги дозволяють нам досягти значного прогресу в розробці ігрових стратегій, адже традиційні методи глибокого навчання часто ігнорують складні взаємозв'язки між ігровими елементами та їхнє просторове розташування.

Обмеження та напрямки для подальших досліджень:

Хоча результати, отримані з використанням нашої гібридної моделі, є обнадійливими, деякі обмеження все ще потребують вирішення, що вимагає подальших удосконалень і вдосконалень моделі:

1. Злиття функцій: Механізм злиття функцій, який ми використали, є відносно простим і не враховує деяких специфічних характеристик стратегічних ігор, що можуть мати суттєвий вплив на ефективність моделі. Це відкриває можливості для розробки більш складних підходів до злиття, які могли б краще

інтегрувати специфічні елементи гри, зокрема правила гри, ресурсне управління та інші важливі аспекти.

2. Побудова графових структур: Відповідно до побудови структур графів для ігор, ми використовували складний метод, що включає ручне визначення вузлів і ребер. У майбутньому ми плануємо вивчити використання таких підходів, як `superpixel`, для автоматичної генерації графів і зниження обчислювальної складності. Це також дозволить полегшити процес масштабування моделі на інші ігри з більшою кількістю елементів.
3. Техніки для динамічних ігор: Оскільки багато стратегічних ігор мають динамічні графи даних, особливо в умовах зміни стану гри в реальному часі, існує необхідність у розвитку методів, які дозволяють обробляти часові ряди в контексті графових нейронних мереж. Це відкриває можливість для більш точного відображення зміни ситуацій в грі, а також надасть можливість адаптувати модель до постійно змінюваних умов гри.
4. Розширення застосувань до інших типів ігор: Під час подальших досліджень ми плануємо розглянути розширення гібридної моделі на інші стратегічні ігри, зокрема на ігри з більш складною динамікою та кількістю агентів. Це дозволить нам ще більше вдосконалити модель і перевірити її на більш широкому спектрі задач.

Таким чином, цей дослідницький підхід відкриває нові можливості для застосування гібридних моделей у стратегічних іграх, дозволяючи створювати більш складні й ефективні стратегії, а також удосконалювати адаптацію до різних варіантів ігрових ситуацій. У майбутньому наша мета — розширити модель, інтегруючи нові методи побудови графів і навчання, що дозволить ще більше покращити її ефективність у стратегічних іграх з високим рівнем складності та великими обсягами даних.

ПЕРЕЛІК ПОСИЛАНЬ

1. Silver, D.; Hubert, T.; Schrittwieser, J.; Antonoglou, I.; Lai, M.; Guez, A.; Lanctot, M.; Sifre, L.; Kumaran, D.; Graepel, T.; et al. A general reinforcement learning algorithm that masters chess, shogi, and Go through self-play. *Science* **2018**, *362*, 1140–1144. [[Google Scholar](#)] [[CrossRef](#)] [[PubMed](#)]
2. Furukawa, M.; Abe, M.; Watanabe, T. A Study on Utility Based Game AI Considering Long-Term Goal Achievement. *J. Soc. Art Sci.* **2021**, *20*, 139–148. [[Google Scholar](#)] [[CrossRef](#)]
3. Hazra, T.; Anjaria, K. Applications of game theory in deep learning: A survey. *Multimed. Tools Appl.* **2022**, *81*, 8963–8994. [[Google Scholar](#)] [[CrossRef](#)]
4. Mahajan, C. Reinforcement Learning Game Training: A Brief Intuitive. *MatSciRN Other Electron.* **2020**. [[Google Scholar](#)] [[CrossRef](#)]
5. Yasruddin, M.L.; Hakim Ismail, M.A.; Husin, Z.; Tan, W.K. Feasibility Study of Fish Disease Detection using Computer Vision and Deep Convolutional Neural Network (DCNN) Algorithm. In Proceedings of the 2022 IEEE 18th International Colloquium on Signal Processing & Applications (CSPA), Selangor, Malaysia, 12–12 May 2022; pp. 272–276. [[Google Scholar](#)]
6. Hou, J.; Gao, T. Explainable DCNN based chest X-ray image analysis and classification for COVID-19 pneumonia detection. *Sci. Rep.* **2021**, *11*, 16071. [[Google Scholar](#)] [[CrossRef](#)]
7. Yang, J.H.; Choi, W.Y.; Lee, S.; Chung, C.C. Autonomous Lane Keeping Control System Based on Road Lane Model Using Deep Convolutional Neural Networks. In Proceedings of the 2019 IEEE Intelligent Transportation Systems Conference (ITSC), Auckland, New Zealand, 27–30 October 2019; pp. 3393–3398. [[Google Scholar](#)]

8. Wang, B.; Ma, R.; Kuang, J.; Zhang, Y. How Decisions Are Made in Brains: Unpack “Black Box” of CNN With Ms. Pac-Man Video Game. *IEEE Access* **2020**, *8*, 142446–142458. [[Google Scholar](#)] [[CrossRef](#)]
9. Li, Z.; Zhu, C.; Gao, Y.; Wang, Z.; Wang, J. AlphaGo Policy Network: A DCNN Accelerator on FPGA. *IEEE Access* **2020**, *8*, 203039–203047. [[Google Scholar](#)] [[CrossRef](#)]
10. Ichsan, M.N.; Armita, N.; Minarno, A.E.; Sumadi, F.D.; Hariyady. Increased Accuracy on Image Classification of Game Rock Paper Scissors using CNN. *J. RESTI (Rekayasa Sist. Dan Teknol. Inf.)* **2022**, *6*, 606–611. [[Google Scholar](#)] [[CrossRef](#)]
11. Kamatekar, S.L.; Hiremath, S.M. Domination, Easymove Game Represented in Graph. *Int. J. Math. Arch.* **2018**, *9*, 179–185. [[Google Scholar](#)]
12. Yun, W.J.; Yi, S.; Kim, J. Multi-Agent Deep Reinforcement Learning using Attentive Graph Neural Architectures for Real-Time Strategy Games. In Proceedings of the 2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC), Melbourne, Australia, 17–20 October 2021; pp. 2967–2972. [[Google Scholar](#)]
13. Xia, F.; Sun, K.; Yu, S.; Aziz, A.; Wan, L.; Pan, S.; Liu, H. Graph Learning: A Survey. *IEEE Trans. Artif. Intell.* **2021**, *2*, 109–127. [[Google Scholar](#)] [[CrossRef](#)]
14. Zhai, Z.; Staring, M.; Zhou, X.; Xie, Q.; Xiao, X.; Bakker, M.E.; Kroft, L.J.; Lelieveldt, B.P.; Boon, G.J.; Klok, F.A.; et al. Linking Convolutional Neural Networks with Graph Convolutional Networks: Application in Pulmonary Artery-Vein Separation. In Proceedings of the Graph Learning in Medical Imaging: First International Workshop, GLMI 2019, Held in Conjunction with MICCAI 2019, Shenzhen, China, 17 October 2019. [[Google Scholar](#)]
15. Zhong, T.; Zhang, S.; Zhou, F.; Zhang, K.; Trajcevski, G.; Wu, J. Hybrid graph convolutional networks with multi-head attention for location

- recommendation. *World Wide Web* **2020**, 23, 3125–3151. [[Google Scholar](#)] [[CrossRef](#)]
16. Wilkens, R.S.; Ognibene, D. MB-Courage@EXIST: GCN Classification for Sexism Identification in Social Networks. In Proceedings of the IberLEF 2021, Málaga, Spain, 21–24 September 2021. [[Google Scholar](#)]
 17. Liang, J.; Deng, Y.; Zeng, D. A Deep Neural Network Combined CNN and GCN for Remote Sensing Scene Classification. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2020**, 13, 4325–4338. [[Google Scholar](#)] [[CrossRef](#)]
 18. Mosella-Montoro, A.; Ruiz-Hidalgo, J. SkinningNet: Two-Stream Graph Convolutional Neural Network for Skinning Prediction of Synthetic Characters. In Proceedings of the 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), New Orleans, LA, USA, 18–24 June 2022; pp. 18572–18581. [[Google Scholar](#)]
 19. Li, W.; He, H.; Hsueh, C.; Ikeda, K. Graph Convolutional Networks for Turn-Based Strategy Games. In Proceedings of the International Conference on Agents and Artificial Intelligence, Online Streaming, 3–5 February 2022. [[Google Scholar](#)]
 20. Liu, Y.; Wang, W.; Hu, Y.; Hao, J.; Chen, X.; Gao, Y. Multi-Agent Game Abstraction via Graph Attention Neural Network. In Proceedings of the AAAI Conference on Artificial Intelligence, Honolulu, HI, USA, 27 January–1 February 2019. [[Google Scholar](#)]
 21. Lee, E.S.; Zhou, L.; Ribeiro, A.; Kumar, V. Learning Decentralized Strategies for a Perimeter Defense Game with Graph Neural Networks. *arXiv* **2022**, arXiv:2211.01757. [[Google Scholar](#)]
 22. Bisberg, A.; Ferrara, E. GCN-WP—Semi-Supervised Graph Convolutional Networks for Win Prediction in Esports. In Proceedings of the 2022 IEEE Conference on Games (CoG), Beijing, China, 21–24 August 2022; pp. 449–456. [[Google Scholar](#)]

- 23.Liu, Q.; Xiao, L.; Yang, J.; Wei, Z. CNN-Enhanced Graph Convolutional Network with Pixel- and Superpixel-Level Feature Fusion for Hyperspectral Image Classification. *IEEE Trans. Geosci. Remote Sens.* **2020**, *59*, 8657–8671. [[Google Scholar](#)] [[CrossRef](#)]
- 24.Wang, L.; Wang, X. Dual-Coupled CNN-GCN-Based Classification for Hyperspectral and LiDAR Data. *Sensors* **2022**, *22*, 5735. [[Google Scholar](#)] [[CrossRef](#)] [[PubMed](#)]
- 25.Meng, Y.; Wei, M.; Gao, D.; Zhao, Y.; Yang, X.; Huang, X.; Zheng, Y. CNN-GCN Aggregation Enabled Boundary Regression for Biomedical Image Segmentation. In Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention, Lima, Peru, 4–8 October 2020. [[Google Scholar](#)]
- 26.Duan, S.; Huang, P.; Chen, M.; Wang, T.; Sun, X.; Chen, M.; Dong, X.; Jiang, Z.; Li, D. Semi-supervised classification of fundus images combined with CNN and GCN. *J. Appl. Clin. Med. Phys.* **2022**, *23*, e13746. [[Google Scholar](#)] [[CrossRef](#)]
- 27.Wang, H.; Xu, L.; Bezerianos, A.; Chen, C.; Zhang, Z. Linking Attention-Based Multiscale CNN With Dynamical GCN for Driving Fatigue Detection. *IEEE Trans. Instrum. Meas.* **2021**, *70*, 2504811. [[Google Scholar](#)] [[CrossRef](#)]
- 28.McDonnell, K.; Abram, F.; Howley, E. Application of a Novel Hybrid CNN-GNN for Peptide Ion Encoding. *J. Proteome Res.* **2022**, *22*, 323–333. [[Google Scholar](#)] [[CrossRef](#)]
- 29.Liang, Y.; Jiang, S.; Gao, M.; Jia, F.; Wu, Z.; Lyu, Z. GLSTM-DTA: Application of Prediction Improvement Model Based on GNN and LSTM. *J. Phys. Conf. Ser.* **2022**, *2219*, 012008. [[Google Scholar](#)] [[CrossRef](#)]
- 30.Li, B.; Zhu, Z. GNN-Based Hierarchical Deep Reinforcement Learning for NFV-Oriented Online Resource Orchestration in Elastic Optical DCIs. *J. Light. Technol.* **2022**, *40*, 935–946. [[Google Scholar](#)] [[CrossRef](#)]

ДЕМОНСТРАЦІЙНИЙ МАТЕРІАЛ