

**МАГІСТЕРСЬКА РОБОТА**

**МР. ШМ - 48.00.00.000 ПЗ**

**Група ШМ-24-3**

**Савчук Ігор**

**2025**

**Івано-Франківський національний технічний університет нафти і газу**

**Факультет інформаційних технологій**

**Кафедра інженерії програмного забезпечення**

**Савчук Ігор Іванович**

(прізвище, ім'я, по батькові)

УДК 004.9  
(індекс)

## **МАГІСТЕРСЬКА РОБОТА**

**Моделі та методи напівконтрольованого навчання для задач обробки**

**медичних зображень**

(назва роботи)

**Інженерія програмного забезпечення**

(назва освітньої програми)

**121 - Інженерія програмного забезпечення**

(шифр і назва спеціальності)

**Савчук І.І.**

(підпис, ініціали та прізвище здобувача освітнього ступеня)

**Науковий керівник**

**Крихівський Михайло Васильович, к.т.н., доцент**

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

**Допущено до захисту**

**Завідувач кафедри**

**доц.**

**Бандура В.В.**

(посада) (підпис) (дата) (ініціали та прізвище)

**Нормоконтроль**

**доц.**

**Вовк Р.Б.**

(посада) (підпис) (дата) (ініціали та прізвище)

Робота містить результати власних досліджень. Використання ідей, результатів і текстів інших авторів мають посилання на відповідне джерело

**Івано-Франківськ – 2025**

**Івано-Франківський національний технічний університет нафти і газу**

Факультет інформаційних технологій

Кафедра інженерії програмного забезпечення

Освітній рівень магістр

Спеціальність 121 – Інженерія програмного забезпечення

ЗАТВЕРДЖУЮ:

Зав. кафедрою

ІПЗ

доц.

В.В. Бандура

“ 04 ” вересня 2025 р.

# ЗАВДАННЯ

## НА МАГІСТЕРСЬКУ РОБОТУ СТУДЕНТУ

**Савчуку Ігорю Івановичу**

(прізвище, ім'я, по-батькові)

**1. Тема магістерської роботи “ Моделі та методи напівконтрольованого навчання для задач обробки медичних зображень ”**

керівник проекту (роботи) Крихівський М.В., к.т.н., доцент

затверджені наказом закладу вищої освіти від “ 05 ” листопада 2025 р. № 695/7

**2. Строк подання студентом проекту (роботи) 15 грудня 2025 р.**

**3. Вихідні дані до проекту (роботи) Концепції та формальні моделі побудови інформаційних та програмних технологій напівконтрольованого машинного навчання**

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

1. Аналіз методів напівконтрольованого машинного навчання для обробки медичних зображень

2. Дослідження методів та алгоритмів напівконтрольованого навчання для обробки зображень

3. Дослідження архітектур популярних існуючих моделей семантичної сегментації

4. Застосування методів та алгоритмів глибоко навчання для обробки медичних зображень

**5. Перелік графічного матеріалу (з точним зазначенням обов'язкових креслень)**

1. Класифікація методів машинного навчання (рис. 1.1)

2. Представлення таксономії напівконтрольованого навчання (рис. 1.2)

3. Вигляд згорткових нейронних мереж зсередини (рис. 1.3)

4. Приклад накладання фільтра на зображення (рис. 1.4)

5. Приклад семантичної та екземпляроної (або інстансної) сегментації (рис. 2.1)

## 6. Консультанти розділів проекту (роботи)

Розділ	Консультант	Підпис, дата
Перевірка на плагіат	доц., к.т.н. Вовк Р.Б.	

7. Дата видачі завдання 04 вересня 2025 р.

Керівник \_\_\_\_\_

(підпис)

Завдання прийняв до виконання \_\_\_\_\_

(підпис)

## КАЛЕНДАРНИЙ ПЛАН

№ п/п	Назви етапів магістерської роботи	Строк виконання етапів роботи	Примітка
1	Підбір і вивчення літератури по темі магістерської роботи	15.09.2025	виконано
2	Аналіз методів напівконтрольованого машинного навчання для обробки медичних зображень	01.10.2025	виконано
3	Дослідження методів та алгоритмів напівконтрольованого навчання для обробки зображень	17.10.2025	виконано
4	Дослідження архітектур популярних існуючих моделей семантичної сегментації	02.11.2025	виконано
5	Застосування методів та алгоритмів глибоко навчання для обробки медичних зображень	19.11.2025	виконано
6	Методологія напівконтрольованого навчання на основі збурень	02.12.2025	виконано
7	Затвердження пояснювальної записки роботи завідувачем кафедри	15.12.2025	виконано

Студент – магістр \_\_\_\_\_

(підпис)

Керівник роботи \_\_\_\_\_

(підпис)

## АНОТАЦІЯ

**Магістерська робота:** 76 с., 28 рис., 4 табл., 45 джерел.

**Тема:** Моделі та методи напівконтрольованого навчання для задач обробки медичних зображень

**Метою роботи** є розробка, аналіз та обґрунтування ефективних моделей напівконтрольованого навчання, орієнтованих на підвищення точності класифікації та семантичної сегментації медичних зображень.

**Об'єктом дослідження** є процеси напівконтрольованого навчання в системах автоматизованої обробки та аналізу медичних зображень.

**Предметом дослідження** є моделі, методи та алгоритми напівконтрольованого навчання, що забезпечують підвищення точності обробки медичних зображень.

### **Результати дослідження**

В роботі проведено дослідження можливостей і обмежень застосування напівконтрольованих методів у задачах класифікації та семантичної сегментації медичних зображень.

### **Висновок**

Визначено, що поєднання глибоких моделей з неміченими даними дає змогу суттєво підвищити якість прогнозування у випадках, коли кількість мічених даних є обмеженою. Досліджено механізми збурень у напівконтрольованому навчанні, включаючи інваріантність моделей до деформацій, шумів та трансформацій

**НАПІВКОНТРОЛЬОВАНЕ НАВЧАННЯ; ГЛИБОКЕ НАВЧАННЯ; МЕДИЧНІ ЗОБРАЖЕННЯ; СЕМАНТИЧНА СЕГМЕНТАЦІЯ; КЛАСИФІКАЦІЯ; НЕЗБАЛАНСОВАНІСТЬ КЛАСІВ; АДАПТИВНА ВТРАТА УЗГОДЖЕНОСТІ; РЕГУЛЯРИЗАЦІЯ; ЗГОРТКОВІ НЕЙРОННІ МЕРЕЖІ; АУГМЕНТАЦІЯ ДАНИХ.**

## ABSTRACT

**Master Thesis:** 76 pp., 28 fig., 4 tab., 45 sources.

**Topic:** Models and methods of semi-supervised learning for medical image processing tasks

**The method of the work** is the development, analysis and justification of effective models of semi-supervised learning, focused on increasing the accuracy of classification and semantic segmentation of medical images.

**The object of the research** is the processes of semi-supervised learning in automated medical image processing and analysis systems.

**The subject of the research** is models, methods and algorithms of semi-supervised learning, which ensure increasing the accuracy of medical image processing.

### **Research results**

The paper studies the possibilities and limitations of the application of semi-supervised methods in the tasks of classification and semantic segmentation of medical images.

### **Conclusion**

It is noted that the combination of deep models with unlabeled data makes it possible to significantly improve the quality of prediction in the case when the amount of labeled data is limited. The drilling mechanisms in semi-supervised learning are studied, including the invariance of models to deformations, noise and transformations.

**SEMI-SUPERVISED LEARNING; DEEP LEARNING; MEDICAL IMAGES; SEMANTIC SEGMENTATION; CLASSIFICATION; CLASS IMBALANCE; ADAPTIVE LOSS OF COHERENCE; REGULARIZATION; CONVULSIVE NEURAL NETWORKS; DATA AUGMENTATION.**

## ЗМІСТ

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ .....	9
ВСТУП.....	10
РОЗДІЛ 1. АНАЛІЗ ПРОБЛЕМАТИКИ НАПІВКОНТРОЛЬОВАНОГО МАШИННОГО НАВЧАННЯ В КОНТЕКСТІ ОБРОБКИ МЕДИЧНИХ ЗОБРАЖЕНЬ .....	14
1.1. Комп'ютерна діагностика на основі машинного навчання у випадку незбалансованості класів даних .....	14
1.1.1. Проблема напівконтрольованого навчання та незбалансованості класів .....	14
1.1.2. Методологія адаптивної змішаної функції втрати узгодженості ....	15
1.2. Роль та класифікація машинного навчання в сучасній науці .....	17
1.2.1. Навчання з вчителем (Supervised Learning).....	18
1.2.2. Навчання без вчителя (Unsupervised Learning) .....	19
1.3. Навчання з частковим наглядом або напівконтрольоване навчання як компромісна парадигма .....	19
Висновки до розділу .....	25
РОЗДІЛ 2. ДОСЛІДЖЕННЯ МЕТОДІВ ТА АЛГОРИТМІВ ГЛИБОКОГО ТА НАПІВКОНТРОЛЬОВАНОГО НАВЧАННЯ ДЛЯ ЗАДАЧ ОБРОБКИ ЗОБРАЖЕНЬ .....	26
2.1. Семантична сегментація зображень від традиційних методів до глибоких CNNs .....	26
2.2. Дослідження архітектур популярних існуючих моделей семантичної сегментації.....	28
2.2.1. Повністю згорткові мережі (FCN) .....	28
2.2.2. Мережа деконволюції.....	29
2.2.3. Модель DeepLab.....	30

2.2.4. Мережа SegNet.....	32
2.2.5. Нейронна мережа UNet.....	33
2.3. Методологія аугментації даних зображень у глибокому навчанні .....	34
2.3.1. Нормальна аугментація .....	35
2.3.2. Методи на основі нейронних мереж .....	36
2.4. Проблема незбалансованості класів у глибокому навчанні для задач класифікації та сегментації .....	38
2.4.1. Незбалансованість у напівконтрольованому навчанні .....	40
2.5. Методи на основі збурень для напівконтрольованого навчання.....	41
Висновки до розділу .....	48
РОЗДІЛ 3. ЗАСТОСУВАННЯ МЕТОДІВ ТА АЛГОРИТМІВ НАПІВКОНТРОЛЬОВАНОГО НАВЧАННЯ ДЛЯ ОБРОБКИ МЕДИЧНИХ ЗОБРАЖЕНЬ .....	49
3.1. Застосування глибокого навчання у класифікації медичних зображень .....	49
3.2. Напівконтрольоване навчання у семантичній сегментації медичних зображень .....	52
3.3. Методологія напівконтрольованого навчання на основі збурень .....	55
3.4. Критичний аналіз обмежень стандартних втрат узгодженості в напівконтрольованому навчанні .....	58
3.5. Використання функції адаптивної втрати узгодженості для незбалансованих класів в напівконтрольованому навчанні .....	61
Висновки до розділу .....	67
ВИСНОВКИ .....	69
ПЕРЕЛІК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ.....	72

## **ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ**

SSL - Semi-Supervised Learning

CL - Consistency Loss

SCL - Suppressed Consistency Loss

OSP - Original Sample Prediction

ASP - Augmented Sample Prediction

EMA - Exponential Moving Average

UDA - Unsupervised Data Augmentation

MT - Mean Teacher

VAT - Virtual Adversarial Training

SDM - Signed Distance Map

ASDNet - Attention-based Semi-supervised Segmentation Network

WSI - Whole Slide Imaging

CT - Computed Tomography

MRI - Magnetic Resonance Imaging

RNN - Recurrent Neural Network

## ВСТУП

### **Актуальність теми.**

Сучасна медична діагностика активно інтегрує інтелектуальні комп'ютерні системи, здатні автоматично аналізувати медичні зображення та допомагати лікарям у виявленні патологій. Глибоке навчання стало ключовим інструментом у цьому процесі, однак його ефективність суттєво залежить від кількості та якості доступних мічених даних. У реальних умовах медичні установи часто стикаються з обмеженими можливостями для розмітки зображень, оскільки цей процес потребує залучення кваліфікованих фахівців і значних часових ресурсів. Крім того, медичні зображення характеризуються високою варіативністю та нерівномірним розподілом патологічних випадків, що створює проблему незбалансованості класів. У таких умовах традиційні методи контрольованого навчання демонструють недостатню точність і схильність до ігнорування рідкісних, але клінічно важливих аномалій.

Напівконтрольоване навчання постає ефективною альтернативою, що дозволяє поєднувати обмежений обсяг мічених даних із великим масивом неміченої інформації. Воно забезпечує можливість побудови більш точних та стійких моделей без суттєвого збільшення вартості підготовки розмічених вибірок. Однак застосування напівконтрольованих методів у медичних задачах пов'язане з низкою викликів, серед яких провідне місце займає проблема узгодженості прогнозів, чутливість до збурень та вплив незбалансованості класів. З-поміж існуючих підходів особливу увагу привертає регуляризація узгодженості, але її ефективність різко падає при значній диспропорції класів.

Потреба у розробці моделей, здатних забезпечувати високу діагностичну точність саме для рідкісних патологій, робить дослідження напівконтрольованого навчання надзвичайно важливим. У цій роботі розглянуто поєднання глибоких згорткових архітектур із адаптивними

механізмами втрати узгодженості, що дозволяє покращити результати як класифікації, так і семантичної сегментації медичних зображень. Здійснено всебічний аналіз існуючих методів, досліджено їхні обмеження, запропоновано та обґрунтовано підхід, здатний підвищити ефективність обробки даних навіть у складних і високовимірних медичних доменах. Отримані результати спрямовані на створення більш стійких і чутливих систем комп'ютерної діагностики, що має важливе практичне значення для охорони здоров'я.

Актуальність роботи зумовлена глобальною тенденцією до впровадження інтелектуальних систем підтримки медичних рішень, де автоматичний аналіз зображень відіграє ключову роль. У той час як методи глибокого навчання вже показали значні успіхи у медичній діагностиці, їх широке застосування стримується недостатньою доступністю високоякісних анотованих датасетів. Процес їх формування є дорогим, тривалим та вимагає участі експертів вузького профілю, що об'єктивно обмежує можливості масштабування сучасних систем. Крім того, медичні зображення майже завжди містять значний дисбаланс між кількістю здорових та патологічних випадків, що спричиняє зниження ефективності традиційних підходів.

Напівконтрольоване навчання як проміжна парадигма відкриває нові можливості для використання великих обсягів немічених даних, доступних у клінічній практиці. Його здатність покращувати точність моделей без суттєвого збільшення обсягів розмітки робить цей напрям надзвичайно перспективним. Проте відсутність адаптивних механізмів, здатних враховувати незбалансованість класів, значно обмежує застосовність існуючих методів у медичній сфері. Це створює потребу у розробці більш гнучких і чутливих алгоритмів, які здатні підтримувати високу точність саме там, де це найбільш критично — у виявленні рідкісних патологій і малих структур.

Таким чином, дослідження моделей та методів напівконтрольованого навчання в умовах незбалансованості класів та обмеженої кількості мічених

даних є своєчасним та важливим науковим завданням, яке має значний практичний потенціал у контексті розвитку сучасних медичних інформаційних систем.

**Метою роботи** є розробка, аналіз та обґрунтування ефективних моделей напівконтрольованого навчання, орієнтованих на підвищення точності класифікації та семантичної сегментації медичних зображень.

**Об'єктом дослідження** є процеси напівконтрольованого навчання в системах автоматизованої обробки та аналізу медичних зображень.

**Предметом дослідження** є моделі, методи та алгоритми напівконтрольованого навчання, що забезпечують підвищення точності обробки медичних зображень.

#### **Завдання дослідження:**

1. Проаналізувати теоретичні основи напівконтрольованого навчання та його застосування у медичній діагностиці.
2. Дослідити існуючі архітектури глибоких нейронних мереж, призначених для задач сегментації та класифікації.
3. Розглянути та систематизувати методи аугментації та регуляризації, що застосовуються в напівконтрольованих моделях.
4. Розробити або адаптувати підхід до змішаної або адаптивної втрати узгодженості, орієнтованої на роботу з незбалансованими класами.
5. Провести дослідження ефективності напівконтрольованих методів для класифікації та сегментації медичних зображень.
6. Сформулювати рекомендації щодо використання отриманих результатів у практичних медичних системах.

#### **Методи дослідження**

У роботі застосовано такі методи дослідження: методи глибокого та напівконтрольованого навчання; згорткові нейронні мережі; методи регуляризації узгодженості та збурень; алгоритми аугментації даних; методи аналізу незбалансованості класів; статистичні методи оцінки точності;

емпіричне моделювання та експериментальна перевірка з використанням спеціалізованих датасетів медичних зображень.

### **Наукова новизна отриманих результатів**

Наукова новизна роботи полягає у формуванні та обґрунтуванні адаптивного підходу до напівконтрольованого навчання для задач медичної класифікації та сегментації. Запропоновано удосконалену функцію адаптивної втрати узгодженості, що дозволяє враховувати нерівномірний розподіл класів та підвищує чутливість моделей до рідкісних патологій. Доведено ефективність використання методів на основі збурень у поєднанні з адаптивними ваговими коефіцієнтами для зменшення впливу домінуючих класів.

### **Практичне застосування результатів**

Практичне значення отриманих результатів полягає у можливості використання розроблених методів для побудови більш точних і стійких систем комп'ютерної діагностики. Запропоновані моделі можуть бути інтегровані у програмні комплекси для автоматичного аналізу медичних зображень, включно з системами раннього виявлення патологій. Результати дослідження дозволяють зменшити потребу в анотації великих обсягів даних, що є ресурсомістким процесом у медичній практиці.

**Структура магістерської роботи.** Представлена робота складається зі вступу, трьох розділів та висновків. Загальний обсяг роботи становить 76 сторінок, і містить 28 рисунків, 4 таблиці, перелік використаних джерел із 45 позицій.

# РОЗДІЛ 1. АНАЛІЗ ПРОБЛЕМАТИКИ НАПІВКОНТРОЛЬОВАНОГО МАШИННОГО НАВЧАННЯ В КОНТЕКСТІ ОБРОБКИ МЕДИЧНИХ ЗОБРАЖЕНЬ

## 1.1. Комп'ютерна діагностика на основі машинного навчання у випадку незбалансованості класів даних

Протягом останніх років комп'ютерна діагностика (КД) на основі технологій машинного навчання (МН) набула статусу одного з ключових та найбільш перспективних інструментів у клінічній медицині. Забезпечуючи автоматизований аналіз різноманітних типів медичних зображень, МН суттєво підвищує ефективність діагностики захворювань. Основними завданнями КД є сегментація та класифікація медичних зображень.

На початкових стадіях патологічного процесу, пухлинні утворення або ураження можуть мати мінімальні розміри на сканах пацієнтів, що підвищує ризик їх пропуску лікарем-радіологом. Для вирішення цієї проблеми застосовується комп'ютерна сегментація, яка дозволяє автоматично виділяти виявлені патологічні структури. На противагу цьому, методи медичної класифікації забезпечують автоматичний аналіз зображень та формування діагнозу захворювання.

### *1.1.1. Проблема напівконтрольованого навчання та незбалансованості класів*

Останні дослідження продемонстрували значні успіхи методів навчання з наглядом у задачах класифікації [2-4] та сегментації [5] медичних зображень. Однак, реалізація цих методів вимагає великих обсягів повністю анотованих медичних зображень, тоді як на практиці часто наявна значна кількість немічених зображень, які потенційно можуть бути використані для підвищення точності моделей. З огляду на це, напівконтрольоване навчання або навчання з частковим наглядом (НЧН) є ідеальним підходом для

ефективного використання всього масиву медичних сканів, включаючи як мічені, так і немічені зразки.

Крім того, медичні набори даних часто характеризуються суттєво незбалансованими розподілами класів. Це проявляється, наприклад, у значній перевазі негативних випадків над позитивними випадками захворювання (класифікація). У сегментаційних наборах даних частка пікселів, що відповідають патології (наприклад, пухлині), зазвичай значно менша за частку фонових пікселів (нормальна тканина). Нехтування проблемою незбалансованості класів може призвести до систематичного ігнорування меншого класу (як правило, класу захворювання), що несе потенційно фатальні клінічні наслідки.

Хоча існують окремі роботи, присвячені НЧН для класифікації [7-8] та сегментації медичних зображень, жодна з них явно не фокусувалася на вирішенні критичної проблеми незбалансованості класів. Таким чином, наше дослідження спрямоване на заповнення цієї прогалини в літературі шляхом явного вивчення проблеми незбалансованості класів у контексті НЧН для класифікації та семантичної сегментації медичних зображень.

### *1.1.2. Методологія адаптивної змішаної функції втрати узгодженості*

Сучасні передові алгоритми НЧН [1, 9] переважно базуються на застосуванні збурень (perturbations). Більшість з них доповнюють немічений набір даних і використовують функцію втрат узгодженості (Consistency Loss, CL), щоб забезпечити подібність прогнозованих розподілів класів для оригінальних та доповнених немічених зразків.

У даній роботі ми зосереджуємося на модифікації функції втрат узгодженості в рамках одного з найбільш ефективних методів НЧН на основі збурень, а саме Unsupervised Data Augmentation (UDA) [1]. Важливо зазначити, що запропонований підхід є загально застосовним і може бути інтегрований з будь-яким методом НЧН на основі збурень, що використовує функцію втрат узгодженості.

Стандартна функція втрат узгодженості (CL), яка використовується в UDA, має два основні недоліки:

1. Вона погіршує продуктивність класифікації для класів з меншою кількістю зразків.

2. Цільовий розподіл завжди встановлюється як розподіл оригінального прикладу, а не як суміш розподілів оригінального та доповненого прикладів.

Для подолання цих обмежень ми пропонуємо застосовувати метод адаптивної змішаної функції втрати узгодженості (Adaptive Blended Consistency Loss (ABCL)). ABCL вирішує обидва недоліки, генеруючи цільовий розподіл класів, який є сумішшю оригінального та доповненого розподілів. Змішування зміщується в бік того зразка (оригінального чи доповненого), який забезпечує вищий прогноз ймовірності для меншого класу.

Ми застосовуємо метод ABCL як для класифікації, так і для семантичної сегментації медичних зображень. У випадку семантичної сегментації, що передбачає класифікацію кожного пікселя (2D) або вокселя (3D) зображення, ABCL застосовується на рівні пікселя/вокселя.

Ми провели експерименти, порівнюючи ABCL з конкуруючими методами на наступних наборах даних:

- Класифікація: Набір даних раку шкіри HAM10000 та набір даних ретинального фундусу REFUGE Challenge (глаукома).

- Семантична сегментація: Набір даних ультразвуку нервів та набір даних ультразвуку раку молочної залози.

Для набору HAM10000, ABCL досяг незваженого середнього відгуку (UAR) 0.67, що значно перевищує показник базової реалізації UDA (0.59). Крім того, ABCL суттєво перевершив сучасний метод Suppressed Consistency Loss (SCL).

Для набору REFUGE, ABCL також значно перевершив SCL, збільшивши UAR з 0.57 до 0.67.

ABCL перевершив базову лінію, виміряну за показником Dice Coefficient, на обох наборах даних (ультразвуку нервів та ультразвуку раку молочної залози). Ці результати підтверджують, що ABCL забезпечує послідовне підвищення продуктивності методів НЧН на основі узгодженості в задачах класифікації та сегментації, які характеризуються незбалансованими класами.

Основні внески даної роботи полягають у наступному:

- Визначення важливості обробки незбалансованості класів для класифікації та сегментації медичних зображень з частковим наглядом, що не було явно вирішено в попередніх дослідженнях.

- Застосування Adaptive Blended Consistency Loss (ABCL) як вдосконаленої заміни стандартної функції втрат узгодженості для алгоритмів НЧН на основі збурень (таких як UDA та Mean Teacher), спеціально розробленої для вирішення проблеми незбалансованості класів.

- Проведення експериментів на репрезентативних медичних наборах даних (двох для класифікації та двох для сегментації), які підтверджують переваги ABCL над стандартними функціями втрат та існуючими методами, спрямованими на вирішення незбалансованості класів.

## **1.2. Роль та класифікація машинного навчання в сучасній науці**

У сучасну цифрову еру машинне навчання (МН) набуло статусу критично важливого інструменту, що застосовується у численних наукових та прикладних доменах, включаючи медичні дослідження, біологію, робототехніку та виробництво. Методології МН використовуються для розв'язання складних задач, демонструючи при цьому рівень точності, порівнянний з людським. Сучасний розвиток обчислювальних ресурсів та зростання обсягів доступних даних сприяють постійному збільшенню потужності та ефективності МН-технік.

Машинне навчання є підмножиною штучного інтелекту (ШІ), що фокусується на розробці моделей, які навчаються відображати вхідні дані на вихідні або приймати рішення, ґрунтуючись на досвіді (даних), а не на явних алгоритмічних інструкціях.

МН традиційно поділяється на три основні парадигми: навчання з наглядом, навчання без нагляду та навчання з підкріпленням. Для цілей даного огляду акцент буде зроблено на перших двох категоріях.

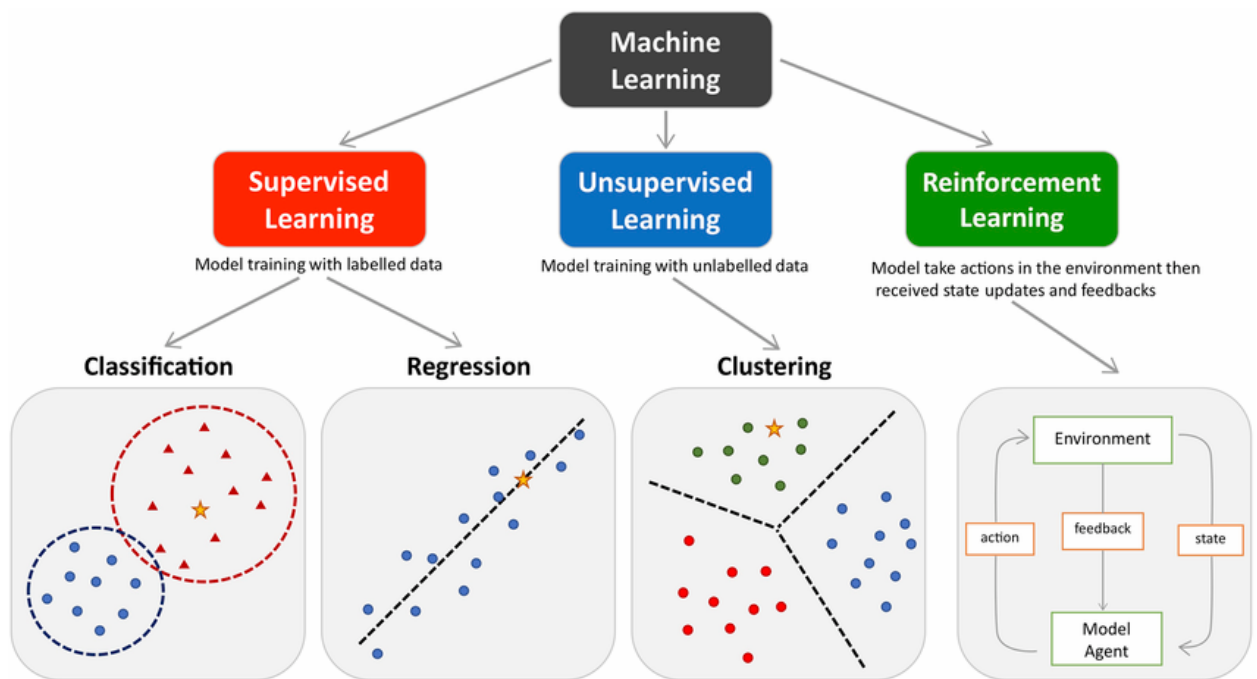


Рис. 1.1. Класифікація методів машинного навчання

### 1.2.1. Навчання з вчителем (*Supervised Learning*)

У навчанні з наглядом навчена модель отримує вхідні дані та генерує відповідний прогноз вихідних даних. Процес навчання моделі полягає у встановленні оптимального відображення між входом та виходом шляхом порівняння прогнозованого виходу з бажаним виходом (міткою).

Ключовою вимогою для цієї парадигми є наявність пари «вхідні дані – бажаний вихід (мітка)» для кожного зразка в навчальному наборі. Отже, забезпечення високої продуктивності наглядових моделей вимагає збору значних обсягів анотованих (мічених) даних.

Основні категорії наглядного навчання включають:

- Класифікація: Метою є призначення вхідних даних до однієї з дискретних категоріальних міток класів.
- Регресія: Метою є прогнозування неперервного числового значення.

### *1.2.2. Навчання без вчителя (Unsupervised Learning)*

На відміну від навчання з наглядом, навчання без нагляду передбачає роботу лише з вхідними даними, без надання явних вихідних міток. Ці методи спрямовані на виявлення прихованих закономірностей, структур або властивостей у даних.

Дві важливі техніки навчання без нагляду:

- Кластеризація (Clustering): Загальна мета полягає у виявленні внутрішніх шаблонів у наборі даних та групуванні схожих точок даних у кластери.
- Зменшення розмірності (Dimensionality Reduction): Це процес скорочення кількості ознак або змінних (розмірності) у наборі даних, зберігаючи при цьому його ключову інформаційну цінність.

## **1.3. Навчання з частковим наглядом або напівконтрольоване навчання як компромісна парадигма**

Короткий аналіз двох основних парадигм машинного навчання – навчання з наглядом та навчання без нагляду – виявляє їхні ключові недоліки:

- Навчання з наглядом вимагає значних фінансових та часових витрат на отримання великих обсягів анотованих (мічених) даних.
- Навчання без нагляду характеризується складністю вилучення семантично значущої інформації виключно з немічених даних.

З огляду на ці обмеження, навчання з частковим наглядом (НЧН) або Semi-Supervised Learning (SSL) виступає як перспективна компромісна

парадигма. НЧН використовує невелику кількість мічених зразків ( $x_L, y_L$ ) у поєднанні зі значним обсягом немічених даних ( $x_U$ ) для оптимізації процесу навчання моделі.

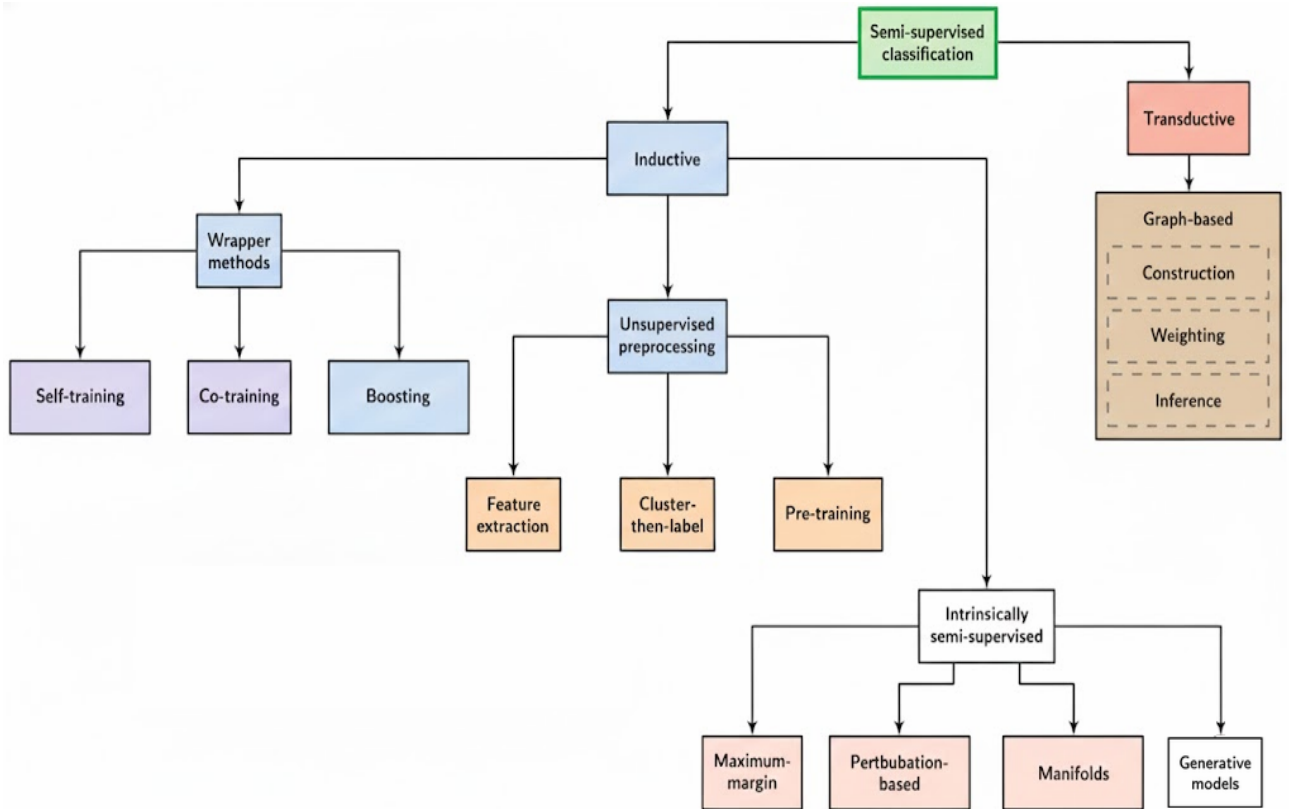


Рис. 1.2. Представлення таксономії напівконтрольованого навчання

Основна мета НЧН полягає у використанні закономірностей, виявлених у немічених даних, для доповнення та покращення передбачень моделі, що базуються на обмеженому міченому наборі.

Інтуїтивно, використання неміченого масиву даних дозволяє моделі формувати більш точні та стійкі кордони рішень між різними класами, оскільки ці кордони краще відображають приховану структуру розподілу даних [32].

Історично склалося, що дослідники розробили різні підходи до напівконтрольованого навчання, які загалом поділяються на трансдуктивне та індуктивне навчання.

## Класифікація навчання з частковим наглядом

Парадигма	Мета	Область застосування
Індуктивне НЧН	Побудова узагальненої моделі, здатної робити передбачення для <b>будь-яких</b> точок даних, включно з <b>небаченими</b> екземплярами.	Узагальнення моделі для майбутніх, невідомих даних.
Трансдуктивне НЧН	Присвоєння міток <b>лише</b> неміченим точкам даних ( $x_U$ ), які <b>відомі</b> моделі під час фази навчання.	Призначення міток наявному неміченому наборі без узагальнення на нові дані.

У широкому сенсі, індуктивне НЧН створює модель, здатну виводити мітки для нових екземплярів, тоді як трансдуктивне НЧН може лише мітити немічені дані, які були частиною навчального набору.

#### 1.4. Переваги та архітектурні особливості згорткових нейронних мереж

Комп'ютерний зір (Computer Vision) є однією з найважливіших прикладних областей машинного навчання, що охоплює різноманітні завдання, такі як детекція об'єктів, класифікація зображень [5] тощо. Сучасні дослідження демонструють проривні результати на публічних наборах даних, як-от ImageNet [6], CIFAR-10 або CIFAR-100 [7]. Досягнення цих успіхів стало можливим завдяки використанню специфічного класу нейронних мереж – згорткових нейронних мереж (Convolutional Neural Networks, CNNs) [9]. CNNs забезпечують моделі здатність краще розуміти внутрішнє представлення зображення та автоматично вивчати ознаки без необхідності їх ручного інженерінгу.

Архітектура CNNs побудована як послідовність згорткових блоків, за якими слідує класифікаційний модуль [41]. Кожен згортковий блок традиційно складається з трьох ключових шарів:

- Шар банку фільтрів (Filter Bank Layer)

- Шар нелінійності (Non-linearity Layer)
- Шар пулінгу (Pooling Layer)

Основною характеристикою CNNs є карта ознак (feature map), яка слугує входом і виходом для шарів у кожному блоці. Карти ознак на початкових шарах можуть відображати елементарні ознаки зображення (наприклад, контури, кути), тоді як на глибших шарах вони кодують більш абстрактні та складні представлення (наприклад, очі, вуха на зображенні кішки).

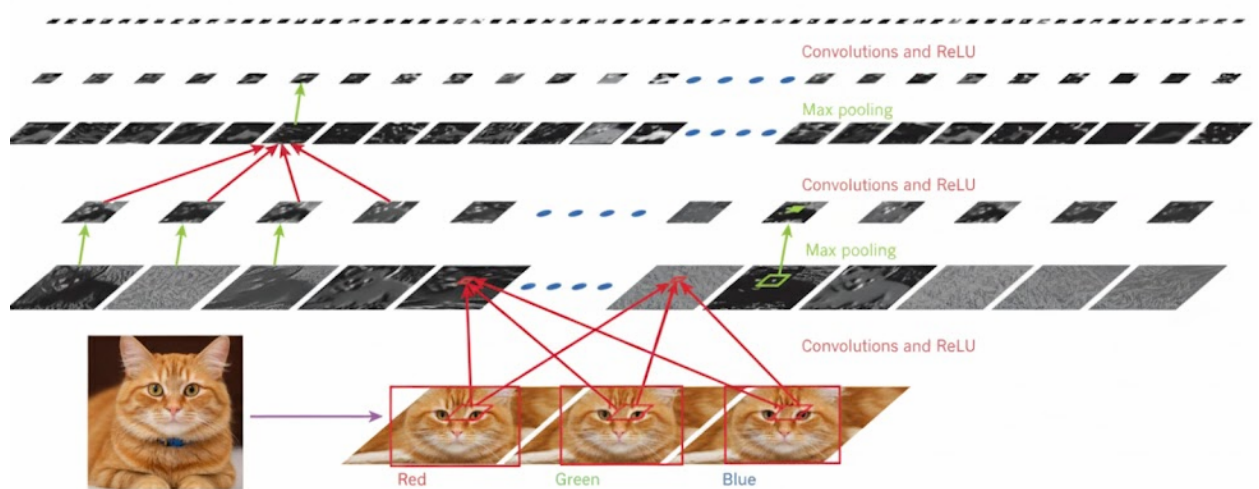


Рис. 1.3. Вигляд згорткових нейронних мереж зсередини

Шар банку фільтрів складається з набору фільтрів (або ядер), які є матрицями ваг. Розмірність фільтра становить  $(W,H)$  для чорно-білого зображення та  $(W,H,D)$  для кольорового зображення (де  $D$  — глибина, наприклад, 3 для RGB).

Кожен фільтр виконує операцію згортки (convolution): він сканує зображення, здійснюючи поелементне множення з відсканованою ділянкою (вікном) і підсумовуючи отримані значення. Фільтр діє як детектор ознак, і його ваги можуть бути початково налаштовані на виявлення специфічних ознак, таких як вертикальні чи горизонтальні краї.

Важливі налаштування згорткового шару включають:

1. Доповнення (Padding).

Процес додавання нульових пікселів навколо меж зображення. Це запобігає втраті інформації по краях зображення та гарантує, що фільтр може охопити всі області вхідного зображення.

## 2. Крок (Stride).

Визначає кількість пікселів, на яку фільтр зміщується від поточної позиції при скануванні. Більший крок призводить до меншої вихідної карти ознак. Інтуїтивно, фільтр являє собою вікно, яке ковзає горизонтально від верхнього лівого кута зображення до нижнього правого, і повертає вихідну карту ознак (як показано на рисунку 1.4). Крім того, фільтр часто називають детектором ознак, а його ваги іноді попередньо визначаються для відображення того, які саме ознаки він має виявляти, наприклад, вертикальні чи горизонтальні краї.

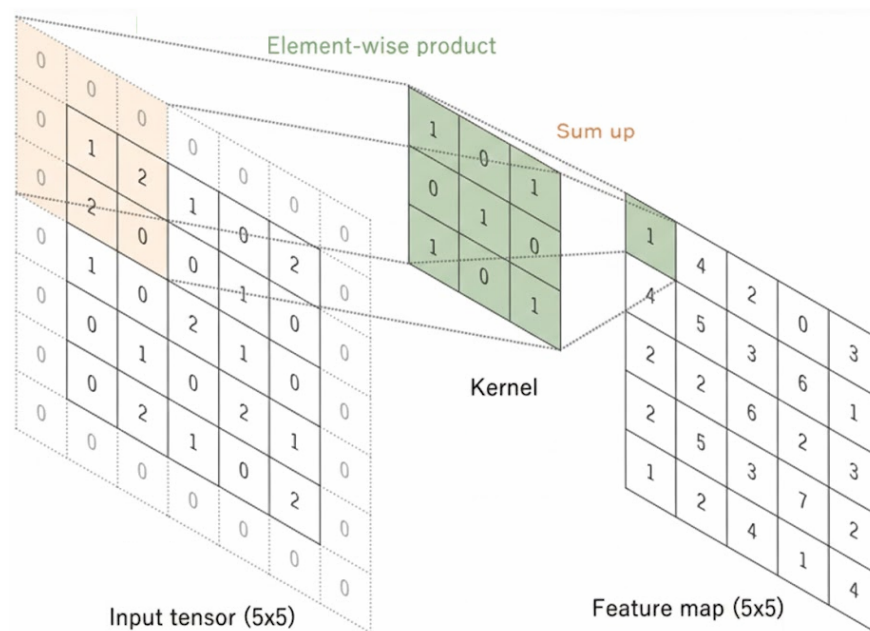


Рис. 1.4. Приклад накладання фільтра на зображення

Вихід шару банку фільтрів подається на шар нелінійності, який містить функцію активації. Найбільш поширеною є функція Rectified Linear Unit (ReLU), що визначається як  $f(x) = \max(0, x)$ .

Мета нелінійної функції активації — запобігти зведенню моделі до простої лінійної моделі, дозволяючи мережі вивчати складні нелінійні взаємозв'язки в даних, необхідні для вирішення комплексних завдань.

Шар пулінгу (субдискретизації) також використовує механізм сканування. Він застосовує певну функцію (наприклад, max pooling, average pooling або sum pooling) до кожної області карти ознак, розмір якої визначається параметром фільтра пулінгу (наприклад,  $2 \times 2$ ). Наприклад, max pooling повертає найбільше значення в межах цієї області.

Функція пулінгу дозволяє зменшити розмірність карт ознак, одночасно зберігаючи найбільш важливу інформацію (інваріантність до невеликих зсувів) і зменшуючи кількість параметрів моделі.

На високому рівні архітектура CNNs має дві ключові переваги:

1. Спільне використання параметрів.

Один і той же фільтр (набір ваг) використовується для сканування всього зображення. Якщо певний детектор ознак (фільтр) є корисним в одній частині зображення, він, ймовірно, буде корисним і в іншій, що значно зменшує загальну кількість параметрів, які необхідно навчати.

2. Розрідженість зв'язків.

Кожне вихідне значення в шарі залежить лише від невеликої підмножини вхідних значень (локальної області), що підвищує обчислювальну ефективність.

Карти ознак, отримані з усіх згорткових блоків, в кінці вирівнюються (flattened) у вектор і подаються на вхід класифікаційного модуля, відомого як повністю зв'язаний шар (Fully Connected Layer). У повністю зв'язаному шарі кожен нейрон цього шару отримує вхідні дані від кожного нейрона попереднього шару. Це означає, що всі входи пов'язані з усіма виходами (відсутність розрідженості зв'язків), на відміну від згорткових шарів. Головна роль повністю зв'язаного шару полягає в тому, щоб взяти високорівневі ознаки, витягнуті попередніми згортковими та пулінговими шарами, і перетворити їх у фінальні прогнози (класифікаційні оцінки). Цей шар

функціонує як традиційна нейронна мережа і генерує оцінки (scores) для кожного класу.

Навчання CNNs відбувається за допомогою алгоритму зворотного поширення помилки (back-propagation), як і в стандартних нейронних мережах, причому ваги фільтрів також підлягають оптимізації.

### **Висновки до розділу**

У першому розділі було здійснено послідовне дослідження основних теоретичних аспектів напівконтрольованого машинного навчання в контексті обробки медичних зображень, що дозволило сформулювати цілісне уявлення про специфіку цієї парадигми. Було показано, що обмежена кількість мічених медичних даних та значна незбалансованість класів є ключовими бар'єрами для розробки точних діагностичних моделей. Аналіз існуючих підходів засвідчив, що поєднання мічених і немічених даних може суттєво підвищити ефективність моделювання, проте вимагає спеціальних механізмів регуляризації. У роботі було розглянуто явище незбалансованості класів як одну з головних причин зниження чутливості моделей до рідкісних патологій. Також було висвітлено роль функцій втрати узгодженості, які забезпечують використання інформації з немічених даних, підвищуючи узагальнювальну здатність моделей. Окрему увагу приділено дослідженню адаптивних методів, здатних коригувати вплив дисбалансу в процесі навчання. Розгляд парадигм контрольованого, неконтрольованого та напівконтрольованого навчання дозволив обґрунтувати переваги саме комбінованого підходу для медичних застосувань. Аналіз виявив, що медичні зображення мають високу варіативність, що ускладнює їх обробку без залучення додаткової інформації з немічених даних.

## РОЗДІЛ 2. ДОСЛІДЖЕННЯ МЕТОДІВ ТА АЛГОРИТМІВ ГЛИБОКОГО ТА НАПІВКОНТРОЛЬОВАНОГО НАВЧАННЯ ДЛЯ ЗАДАЧ ОБРОБКИ ЗОБРАЖЕНЬ

### 2.1. Семантична сегментація зображень від традиційних методів до глибоких CNNs

Сегментація зображень поділяється на дві основні категорії: семантична сегментація та сегментація екземплярів (Instance Segmentation).

Семантична Сегментація це методи семантичної сегментації присвоюють кожному пікселю зображення мітку класу, до якого він належить (наприклад, "пухлина" або "фон"). Таким чином, модель виводить маску класу для кожного пікселя.

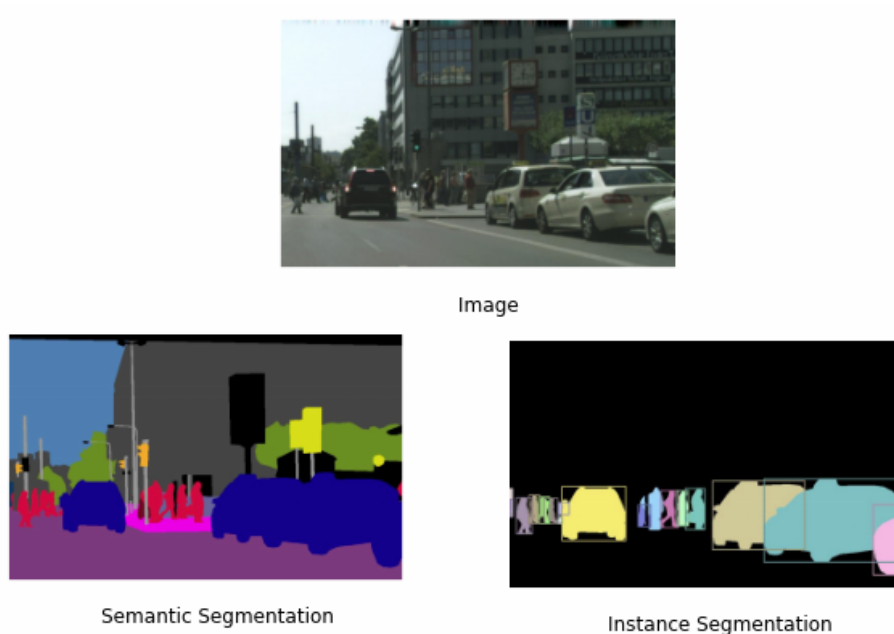


Рис. 2.1. Приклад семантичної та екземплярної (або інстансної) сегментації

Сегментація екземплярів ця задача є розширенням семантичної сегментації, де, окрім присвоєння класу, пікселі додатково розділяються відповідно до приналежності до різних екземплярів одного й того ж класу. Наприклад, якщо на зображенні є дві пухлини, семантична сегментація

позначить їх як клас "пухлина", тоді як сегментація екземплярів розділить їх на "пухлина 1" та "пухлина 2".

На ранніх етапах розвитку комп'ютерного зору, методи сегментації зображень ґрунтувалися на традиційних алгоритмах, таких як порогова обробка (thresholding), зростання регіонів (region growing) та кластеризація k-засобами (k-means clustering).

Однак, завдяки значному успіху моделей глибокого навчання, зокрема згорткових нейронних мереж (CNNs), точність сегментації зображень різко зросла. Сучасні підходи, такі як DeepLab [15] та U-Net [16], які базуються на CNNs, встановили нові стандарти продуктивності. Обмежуючи обсяг даного огляду, ми зосередимося виключно на методах семантичної сегментації, які використовують моделі глибокого навчання.

Як зазначалося, CNNs є домінуючим підходом у комп'ютерному зорі, особливо в задачах класифікації зображень, де вони автоматично вивчають ознаки та генерують глобальне передбачення класу для всього зображення.

Дослідники адаптували архітектуру глибоких CNNs для вирішення задачі семантичної сегментації, модифікуючи їх для виведення локального передбачення — прогнозу класу для кожного пікселя зображення, що формує маску передбачення.

Ранні підходи (на основі фрагментів) [17] застосовували CNN для класифікації центрального пікселя у невеликому фрагменті вхідного зображення. Сканування зображення фрагмент за фрагментом дозволяло отримати передбачення для кожного пікселя. Однак цей підхід був обчислювально неефективним через багаторазове застосування того самого ядра CNN до перекривних областей.

Для підвищення ефективності була запропонована інтуїтивна ідея [18] використання повністю згорткових нейронних мереж (Fully Convolutional Networks, FCNs), які обробляють усе зображення за один прохід через мережу. Це вимагало модифікації архітектури CNN для збереження розміру виходу рівним розміру входу, використовуючи шари зменшення розмірності

(для ефективності та захоплення контексту) та шари збільшення розмірності (для відновлення просторової роздільної здатності). FCNs не лише підвищили обчислювальну ефективність, але й дозволили захоплювати глобальну просторову інформацію. Завдяки цим перевагам, FCNs лежать в основі всіх сучасних методів семантичної сегментації.

## 2.2. Дослідження архітектур популярних існуючих моделей семантичної сегментації

### 2.2.1. Повністю згорткові мережі (FCN)

Лонг та ін. [48] запропонували FCN, модифікувавши існуючі класифікаційні CNN (наприклад, VGG16, GoogleNet). Автори замінили повністю зв'язані шари на повністю згорткові та інтегрували шари збільшення розмірності (upsampling). Це дозволило моделі обробляти зображення довільного розміру та генерувати маску передбачення того ж розміру, що й вхідне зображення.




Рис. 2.2. Повністю згорткові мережі для семантичної сегментації

Шари збільшення розмірності включають навчальні фільтри деконволюції (які виконують збільшення розмірності за допомогою, наприклад, білінійної інтерполяції).

З'єднання пропусків (Skip Connections) використовувалися для уточнення семантики та просторової точності виходу шляхом комбінування грубої, високорівневої інформації з карт ознак глибоких шарів з низькорівневою інформацією з більш ранніх шарів.

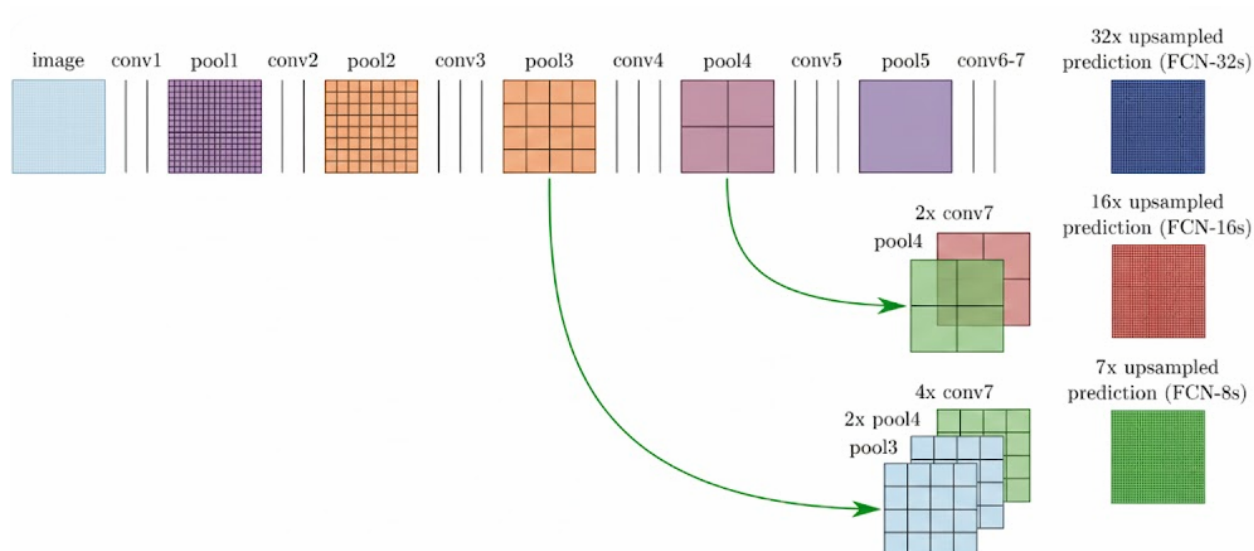


Рис. 2.3. Приклад з'єднання пропусків, що дозволяють моделі використовувати високорівневу інформацію з середніх шарів

Як результат, модель досягла 67.2% середнього IoU (Intersection over Union) на наборі даних PASCAL VOC 2012.

### 2.2.2. Мережа деконволюції

Мережа DeConvNet [20] була розроблена на основі архітектури кодувальника-декодувальника. Вона складається зі:

- Кодувальника (Convolutional Network), що кодує вхідне зображення у вектор ознак. Важливо, що в цій архітектурі кодувальник (VGG16) не був повністю згортковим, оскільки включав два повністю зв'язані шари (які потім доповнювалися).
- Декодувальника (Deconvolution Network) - перетворює вектор кодування ознак у щільну карту передбачення класів на рівні пікселів.

Декодувальник містить послідовність навчальних шарів деконволюції, розпулу (unpooling) та одиниць ReLU. Мотивація полягала в подоланні відсутності справжньої деконволюції в попередніх моделях (FCNs).




Рис. 2.4. Загальна архітектура мережі деконволюції, базована на 16-шаровій CNN моделі VGG

Мережа досягла 72.5% IoU на PASCAL VOC 2012, перевершивши конкуруючі моделі.

### 2.2.3. Модель DeepLab

Моделі DeepLab (DeepLabv1, DeepLabv2, DeepLabv3, DeepLabv3+) є одними з найвпливовіших.

DeepLabv1 - основа це архітектура FCN (з VGG16 як основою).

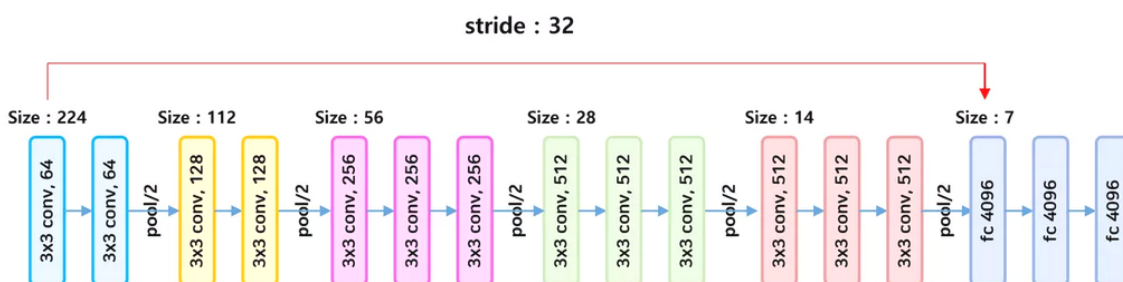


Рис. 2.5. Архітектура моделі DeepLabv1

Ключові особливості:

- Розширені згортки (Atrous Convolutions) збільшують рецептивне поле ядра (контекст), використовуючи проміжки при його застосуванні до входу,

без збільшення обчислювальних витрат. Це дозволяє захоплювати контекст на більшій відстані та зменшує зниження сигналу.

- Повністю зв'язане CRF (Fully Connected CRF) використовується на етапі виходу для уточнення карти оцінок сегментації, покращуючи локалізацію об'єктів. Карта ознак спочатку збільшується до оригінальної роздільної здатності білінійною інтерполяцією, а потім уточнюється CRF.

Досягнуто 71.6% IoU на PASCAL VOC-2012.

DeepLabv2 - це покращення і використання CNN ResNet як основи FCN. Запропоновано Адаптивний Пірамідальний Пулінговий Просторові Згортки (Atrous Spatial Pyramid Pooling, ASPP) для стійкої сегментації об'єктів у різних масштабах. ASPP фільтрує вхідні карти ознак за допомогою кількох паралельних розширених згорткових шарів з різними швидкостями розширення.

Результати. Встановлено новий рекорд 79.7% IoU на PASCAL VOC2012.

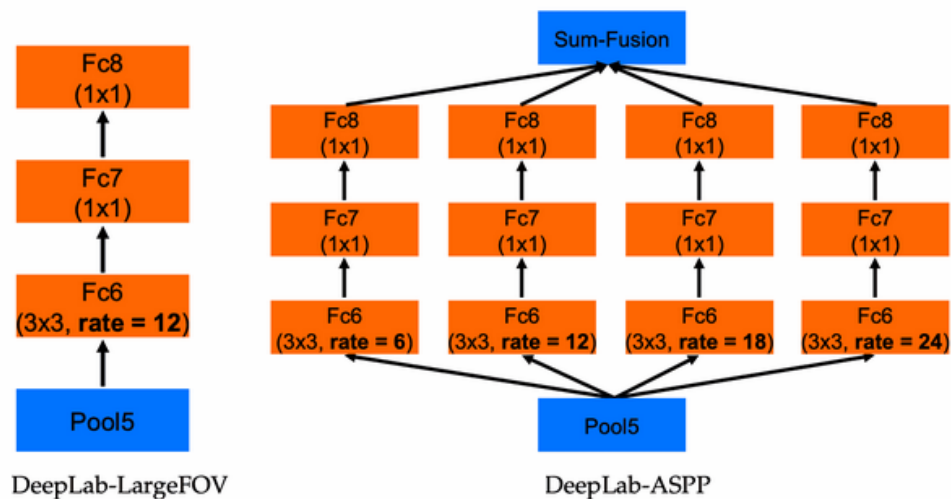


Рис. 2.6. Структура DeepLabv2

DeepLabv3 – це перегляд використання розширеної згортки та видалення повністю зв'язаного CRF.

Ключові ідеї:

- Глибші каскадні розширені згортки, тобто більше блоків з розширеною згорткою в каскаді для захоплення інформації на великій відстані.
- Модифікований ASPP доповнений навчальною пакетною нормалізацією (Batch Normalization), ознаками на рівні зображення (Image-level features) та згортками  $1 \times 1$ .

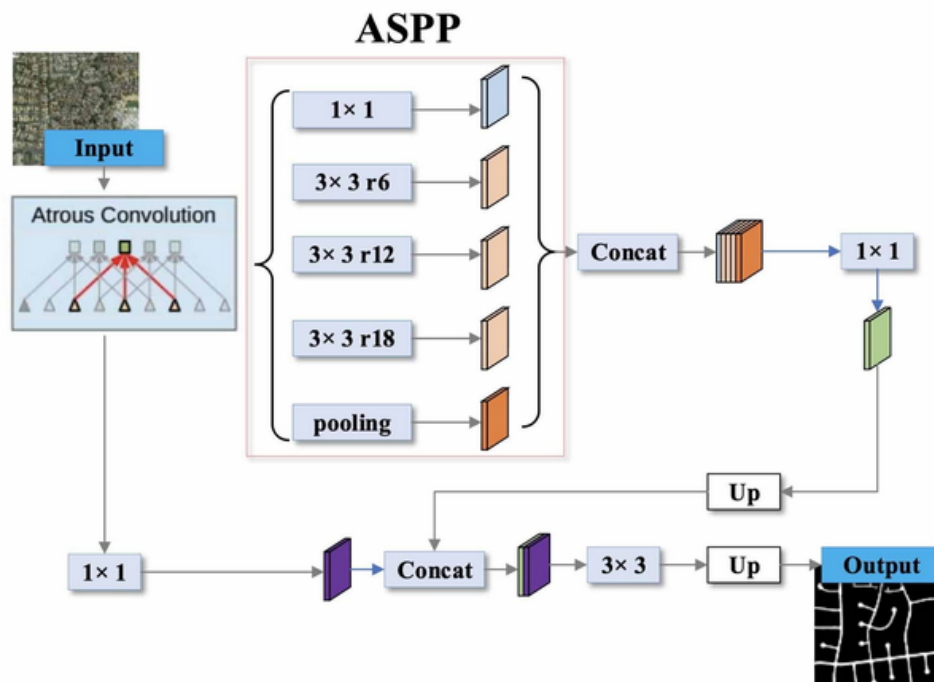


Рис. 2.7. DeepLab-V3 як основний модуль пірамідального пулінгового просторового розширення (ASPP)

#### 2.2.4. Мережа SegNet

SegNet є ще однією повністю згортковою глибокою мережею кодувальника-декодувальника. Кодувальник базується на VGG16, але без двох повністю зв'язаних шарів, що зробило SegNet повністю згортковою.

Мережа декодувальника використовує індекси пулінгу, отримані на етапі max-пулінгу відповідного кодувальника, для виконання розпулу. Це ключова відмінність: етап збільшення розмірності не вимагає навчання (не використовуються навчальні фільтри деконволюції). Після розпулу

розріджені карти згорткуються з навчальними фільтрами для створення щільних карт ознак.

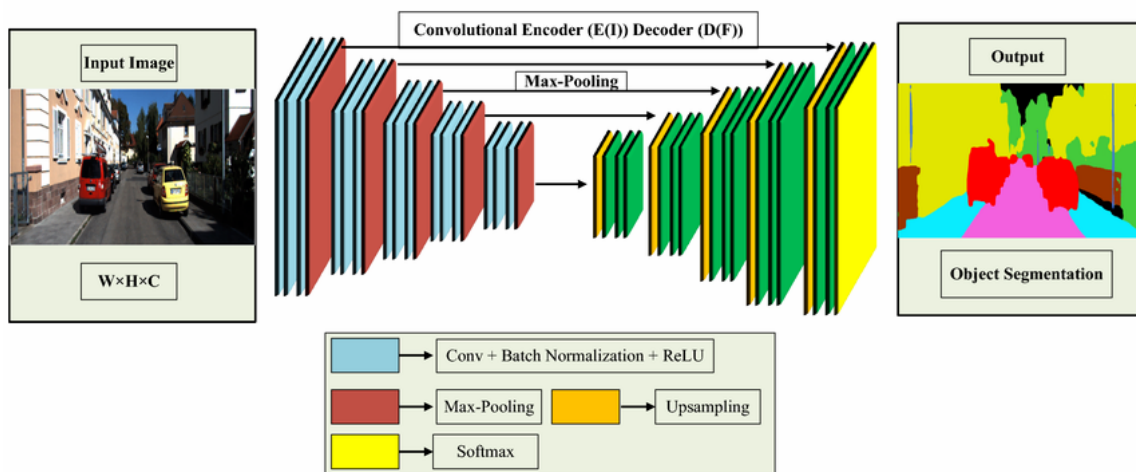


Рис. 2.8. Архітектура SegNet мережі

### 2.2.5. Нейронна мережа UNet

На відміну від моделей для загальної сегментації, UNet була спочатку розроблена для сегментації медичних зображень. Це U-подібна FCN, що складається з:

1. Шляху стиснення (Contracting Path) - захоплює контекст шляхом зменшення роздільної здатності (аналогічно типовій CNN).

2. Симетричного шляху розширення (Expansive Path) - відповідає за локалізацію об'єктів шляхом збільшення роздільної здатності (аналогічно мережі деконволюції).

3. З'єднання пропусків (Skip Connections). На кожному шарі збільшення розмірності об'єднані карти ознак (збільшені) комбінуються з відповідно обрізаними картами ознак зі шляху стиснення. Це дозволяє передавати високоточну просторову інформацію безпосередньо від кодувальника до декодувальника, формуючи характерну U-подібну архітектуру.

Після останнього блоку розширення, до отриманих карт ознак застосовується фінальна згортка  $1 \times 1$  (convolution  $1 \times 1$ ). Кількість вихідних каналів цієї згортки дорівнює кількості класів сегментації, дозволяючи

отримати фінальну карту оцінок (scores) для кожного пікселя, за якою потім застосовується функція Softmax для отримання ймовірностей.




Рис. 2.9. Архітектура нейронної мережі UNet

Ця мережа є класичним прикладом моделі кодувальника-декодувальника (Encoder-Decoder), яка ефективно поєднує контекстну інформацію (що отримується з глибоких шарів) із точною локалізацією (що відновлюється з поверхневих шарів).

### 2.3. Методологія аугментації даних зображень у глибокому навчанні

В умовах успішного навчання глибоких моделей згорткових нейронних мереж (CNNs), які зазвичай вимагають значних обсягів даних, аугментація даних зображень (data augmentation) відіграє критично важливу роль. Аугментація — це техніка генерації додаткових зображень на основі інформації, що міститься в існуючих зразках, без зміни їхнього семантичного змісту. Цей процес підвищує різноманітність навчального набору даних.

Застосування аугментації дозволяє моделі частіше стикатися з симульованими небаченими даними, сприяючи вирішенню проблеми перенавчання (overfitting) та підвищенню узагальнювальної здатності моделі.

Методи аугментації даних зображень можна класифікувати на три основні групи:

1. Нормальна аугментація (евристичні трансформації);
2. Методи на основі нейронних мереж (генеративні моделі);
3. Пошук аугментації (автоматизовані політики).

### 2.3.1. Нормальна аугментація

При нормальній аугментації додаткові зображення створюються за допомогою простих математичних функцій та геометричних перетворень, які трансформують такі аспекти, як текстура, форма та колір.

Таблиця 2.1.

Методи нормальної аугментації

Метод	Опис трансформації	Наслідки та призначення
Обертання	Зображення обертається за годинниковою або проти годинникової стрілки на випадковий кут.	Об'єкт зберігає форму, але змінює орієнтацію, підвищуючи інваріантність моделі до кутового положення.
Віддзеркалення	Зображення відображається горизонтально або вертикально, створюючи симетричний зразок відносно відповідної осі.	Підвищує інваріантність моделі до симетричних змін.
Зсув	Всі значення пікселів зображення переміщуються (трансльуються) вгору, вниз, вліво або вправо.	Імітує зміну положення об'єкта в кадрі. Надмірний зсув може призвести до втрати важливої інформації.
Обрізання	Випадкова область зображення фіксованого розміру вирізається.	Генерує зображення меншого розміру, імітуючи різні кадризації об'єкта.
Вирізання	(Натхненню технікою регуляризації dropout). Випадкова область фіксованого розміру видаляється і замінюється випадковими значеннями пікселів.	Симулює ситуації, коли об'єкт частково оклюдований (перекритий), що підвищує стійкість моделі. Схоже на випадкове стирання.
Трансформація кольору	Маніпулювання чотирма основними аспектами: відтінок, насиченість,	Для кольорових зображень (наприклад, у колірному просторі

Метод	Опис трансформації	Наслідки та призначення
	яскравість та контраст. Популярні методи включають вирівнювання гістограми та регулювання яскравості, контрасту, балансу білого, різкості та розмиття.	RGB або HSI) змінює характеристики пікселів, що підвищує інваріантність моделі до варіацій освітлення та колірного балансу.
Впровадження шуму	Додавання до зображення певної кількості шумових значень пікселів (зазвичай гауссового шуму).	Сприяє навчанню моделі більш стійких ознак, які є менш чутливими до шуму сенсора або артефактів.

Приклад нормальної аугментації подано на рис. 2.10.




Рис. 2.10. Приклади методів нормальної аугментації на медичному зображенні ураження шкіри

### 2.3.2. Методи на основі нейронних мереж

У цьому підході нові зразки зображень генеруються за допомогою навченої нейронної мережі, при цьому зберігаючи семантичну відповідність оригінальній мітці.

Генеративно-змагальні мережі (GANs) складаються з двох взаємодіючих моделей, які навчаються в антагоністичний спосіб:

- Генеративна модель (Generator) навчається створювати синтетичні зразки даних.

- Дискримінаційна модель (Discriminator) навчається відрізнити справжні дані від фейкових, згенерованих.

Процес полягає в наступному. Генератор навчається протистояти навченому дискримінатору, прагнучи створити зразки, які дискримінатор класифікує як справжні, тим самим ефективно генеруючи нові, високоякісні дані для аугментації.




Рис. 2.11. Зразки, згенеровані генератором. Синя рамка позначає останню версію кожного зразка

Перенесення нейронного стилю – техніка, що дозволяє створювати нові зображення, які зберігають зміст оригінального зображення, але застосовують стиль іншого зображення.

Дві CNN обробляють два вхідні зображення (одне з змістом, інше зі стилем). Мережа розділяє, а потім об'єднує ці компоненти, створюючи аугментоване зображення з тим самим змістом, але зміненим стилем, що є корисним для підвищення стійкості до варіацій стилю.

Через складність визначення оптимальної комбінації та параметрів численних евристичних методів аугментації, були розроблені алгоритми пошуку аугментації, які автоматично знаходять найбільш ефективну політику аугментації даних.

Авто аугментація складається з алгоритму пошуку та простору пошуку. Алгоритм пошуку використовує навчання з підкріпленням (Reinforcement Learning) для знаходження оптимальної політики аугментації в просторі пошуку. Політика складається з багатьох підполітик. Кожна підполітика включає дві нормальні трансформації зображень, які параметризовані ймовірністю застосування трансформації та її величиною.

Але процес є обчислювально витратним, оскільки пошук політик виконується на проксі-завданнях з різними моделями та розмірами наборів даних.

Випадкова аугментація (RandAugmentation) розроблена для подолання високої обчислювальної вартості AutoAugmentation. Замість окремої фази пошуку, RandAugmentation безпосередньо оцінює вплив аугментації на цільову модель та набір даних. Простір пошуку значно менший і включає набір доступних операцій, їхню фіксовану величину та лише два гіперпараметри ( $N$  — кількість послідовних операцій і  $M$  — загальна величина, що налаштовуються) для налаштування. Це забезпечує значно вищу ефективність.

#### **2.4. Проблема незбалансованості класів у глибокому навчанні для задач класифікації та сегментації**

Навчальні набори даних часто характеризуються незбалансованим розподілом класів. Це особливо актуально у прикладних областях, як-от:

1. Фінансові системи. Класифікація шахрайських транзакцій, де шахрайські випадки (меншість) значно поступаються нешахрайським (більшість).

2. Охорона здоров'я. Виявлення раку, де здорові зразки (більшість) переважають зразки з патологією (меншість).

Незбалансованість призводить до того, що модель машинного навчання демонструє упередженість до прогнозування класів більшості, що критично знижує точність передбачення для класів меншості. Для вирішення цієї проблеми розроблено три основні групи методів:

#### 1. Підхід на рівні даних

Цей підхід полягає у повторній вибірці (resampling) навчального набору для створення більш збалансованого розподілу перед подачею даних у модель.

- Недостатня вибірка (Under-sampling) - випадкове зменшення кількості зразків класів більшості.

Недолік: може призвести до значної втрати інформації, що містилася у вилучених даних.

Удосконалення: застосування інтелектуальних методів для ефективного вибору, які саме зразки більшості слід вилучити.

- Надмірна вибірка (Over-sampling) - випадкове збільшення кількості зразків класів меншості.

Недолік: збільшує час навчання та може спричинити перенавчання (overfitting) моделі.

Удосконалення: використання інтелектуальних методів [68, 69, 70] для генерації нових штучних зразків меншості на основі існуючих.

#### 2. Підхід на рівні алгоритму

Цей метод модифікує алгоритм моделі для надання більшої ваги класам меншості, замість зміни розподілу даних. Цей підхід поділяється на три підкатегорії [24]:

2.1. Модифікація функції втрат - розробка нових функцій втрат, які зменшують вплив класів більшості на загальні втрати. Приклади включають: середню помилку хибного відхилення (Mean False Deviation Error), фокальну втрату (Focal Loss), зважену перехресну ентропію (Weighted Cross-Entropy).

2.2. Навчання чутливе до вартості (Cost-Sensitive Learning) - модель навчається на основі матриці вартості класифікації, де різним класам призначаються різні вартості.

2.2. Зміщення порогу - регулювання порогу рішення моделі для зменшення упередженості щодо "легких" зразків (класи більшості), тим самим збільшуючи кількість правильних передбачень для "складних" зразків (класи меншості).

Гібридні методи комбінують підходи на рівні даних та алгоритмічні методи. Типово, вони спочатку виконують повторну вибірку, а потім застосовують алгоритмічні техніки, наприклад, чутливе до вартості навчання.

#### *2.4.1. Незбалансованість у напівконтрольованому навчанні*

Усі вищезгадані методи розроблені для навчання з наглядом, де розподіл мічених даних відомий. Застосування цих підходів у середовищі НЧН ускладнене через невідомий розподіл немічених даних.

Метод Suppressed Consistency Loss (SCL) - це алгоритмічний метод, запропонований для НЧН на основі збурень. У середовищі з незбалансованими класами, узгоджена регуляризація може змусити межу рішення переміститися в області з низькою щільністю меншого класу, що призводить до його неправильної класифікації. SCL пригнічує (зменшує) внесок втрати узгодженості для класів меншості. Це зміщує межу рішення подалі від областей низької щільності, покращуючи передбачувальну здатність для меншого класу.

У той час як у класифікації проблема незбалансованості розглядається на рівні цілого зображення, у семантичній сегментації вона виникає на рівні пікселя. Зокрема, у бінарній сегментації медичних зображень (наприклад, пухлина проти фону) кількість фонових пікселів (більшість) значно переважає кількість пікселів переднього плану (патологія, меншість).

Методи вирішення цієї проблеми також поділяються на підходи на рівні даних та алгоритмічні підходи.

Застосування методів недостатньої/надмірної вибірки, розроблених для класифікації, є проблематичним для сегментації:

- видалення пікселів/вокселів класу більшості призведе до втрати великого обсягу інформації із зображення.

- існуючі методи використовують алгоритми вибору фрагментів для балансування кількості фрагментів, які містять класи більшості та меншості.

Алгоритмічні методи є більш поширеними для сегментації та включають модифікації функцій втрат. Dice Loss базується на метриці коефіцієнта Дайса та спрямована на максимізацію подібності між передбаченою та істинною масками сегментації. Tversky Loss модифікує метрику коефіцієнта Дайса, надаючи більшої ваги хибним негативам (пропущеним пікселям патології), ніж хибним позитивам. Pre-computed Weight Map використовується в UNet для надання більшої ваги пікселям, розташованим ближче до меж об'єктів.

На цей час відсутні дослідження, сфокусовані на вирішенні проблеми незбалансованості класів у контексті напівконтрольованої семантичної сегментації.

## **2.5. Методи на основі збурень для напівконтрольованого навчання**

Ми зосереджуємося на внутрішньо напівконтрольованих методах, які є підкласом індуктивного напівконтрольованого навчання (SSL). Ці підходи використовують немічені дані, спираючись на два фундаментальні припущення щодо структури простору даних: припущення про низьку щільність та припущення про гладкість.

Припущення про низьку щільність стверджує, що оптимальна межа рішення повинна розташовуватися в областях з низькою щільністю вхідного простору даних. Припущення про гладкість стверджує, що якщо дві точки даних знаходяться близько одна до одної у вхідному просторі, вони повинні мати однакову передбачену мітку [21].

На основі припущення про гладкість, методи на основі збурень підвищують стійкість моделі шляхом застосування стохастичного шуму до немічених даних. Це накладає вимогу, що оригінальний вхід та той самий вхід, збурений шумом, повинні призводити до однакового передбаченого результату.

Нижче наведено огляд ключових технік, які використовують цей підхід та продемонстрували найвищу продуктивність, переважно у завданнях класифікації.

П-МОДЕЛЬ натхненна ансамблевим навчанням. Її основна ідея полягає у заохоченні узгодженості (consistency) між двома виходами моделі,  $z$  та  $z\sim$ , які генеруються з одного й того ж входу в межах одного навчального пакету (batch). Генерація двох різних виходів досягається шляхом застосування різних умов dropout та різних операцій аугментації даних (стохастичний шум) до одного входу.

Моделю оптимізується за допомогою двох функцій втрат:

- втрата перехресної ентропії застосовується до передбачення  $z$  лише для мічених входів.
- середньоквадратична похибка (Mean Squared Error) між  $z$  та  $z\sim$  застосовується для всіх входів.

На наборі даних CIFAR-10 з 4000 мітками, П-МОДЕЛЬ досягла рівня помилок 12.36%.

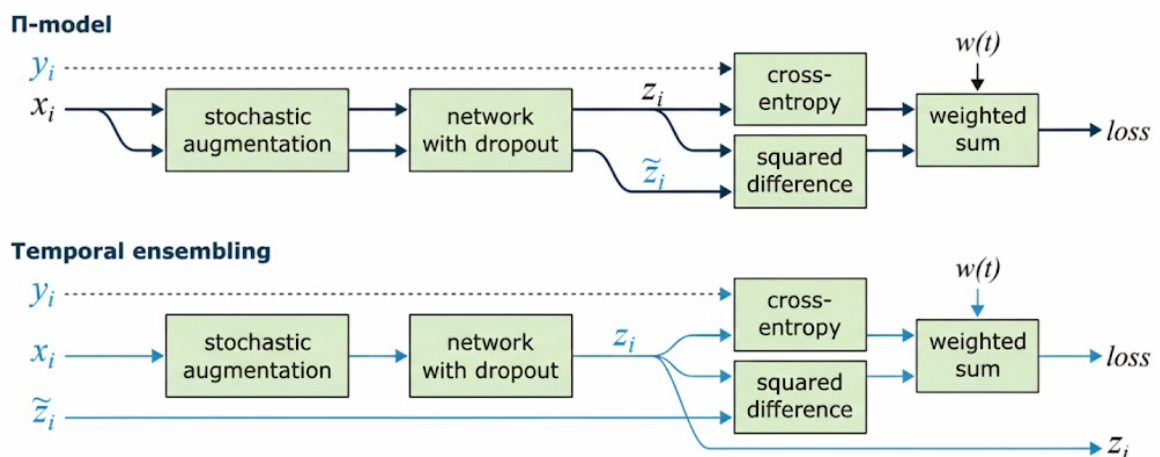


Рис. 2.12. Схема навчання методів на основі П-МОДЕЛІ

Техніка Temporal Ensembling є розширенням П-МОДЕЛІ. Ключова відмінність полягає в тому, що модель генерує лише один поточний вихід  $z_t$ , тоді як цільове передбачення  $z_{t+1}$  базується на акумульованому ансамблі виходів моделі з попередніх навчальних епох.

Після кожної епохи, вихід моделі  $z_t$  оновлюється в ансамблі виходів  $Z_t$  за допомогою експоненційного ковзного середнього (Exponential Moving Average, EMA):

$$Z_t \leftarrow \alpha Z_t + (1 - \alpha) z_t$$

де  $\alpha$  — коефіцієнт згладжування, близький до 1. Цільовий вихід  $z_{t+1}$  обчислюється шляхом ділення  $Z_t$  на коефіцієнт  $(1 - \alpha)^t$ , де  $t$  — номер поточної епохи.

Перевагою ж те, що генерація лише одного виходу за прохід робить Temporal Ensembling швидшим за П-МОДЕЛЬ. Крім того,  $z_{t+1}$ , обчислений як ансамбль попередніх виходів, є менш зашумленим порівняно з  $z_t$  у П-МОДЕЛІ.

Mean Teacher — це метод напівконтрольованого навчання, який підвищує продуктивність моделей машинного навчання за рахунок використання як мічених, так і немічених даних. Він працює шляхом підтримки двох моделей: моделі «студента» та моделі «вчителя».

Модель студента – це звичайна модель, яка навчається на мічених даних за допомогою зворотного поширення помилки. Модель вчителя – це експоненційно рухоме середнє (EMA) ваг моделі студента. Вона не навчається безпосередньо за допомогою зворотного поширення, а її ваги поступово оновлюються на основі ваг студента.

Основна ідея полягає в тому, щоб заохотити модель студента робити узгоджені прогнози з моделлю вчителя для немічених даних. Це досягається шляхом мінімізації функції втрат узгодженості між виходами студента та вчителя для немічених прикладів. Як правило, для немічених даних застосовуються різні аугментації (наприклад, випадкові обертання,

масштабування, вирізання) для створення кількох версій одного і того ж вхідного зображення. Це допомагає моделям бути стійкими до варіацій і покращує узагальнення. Використання ЕМА для оновлення ваг вчителя призводить до більш стабільних і плавних ваг порівняно з прямим навчанням. Це допомагає моделі вчителя діяти як більш надійний цільовий показник для навчання студента, особливо на ранніх етапах навчання, коли модель студента ще нестабільна.

Наведемо спрощений алгоритм як це працює:

1. Модель студента отримує як мічені, так і немічені дані.
2. На мічених даних вона навчається як звичайна контрольована модель (наприклад, з використанням перехресної ентропії).
3. На немічених даних студент генерує прогнози.
4. Модель вчителя (з її більш стабільними вагами) також генерує прогнози для цих немічених даних.
5. Розраховується «втрата узгодженості» між прогнозами студента та вчителя (наприклад, MSE).
6. Загальна втрата є сумою контрольованої втрати та втрати узгодженості.
7. Ваги студента оновлюються на основі загальної втрати.
8. Ваги вчителя оновлюються як ЕМА ваг студента.

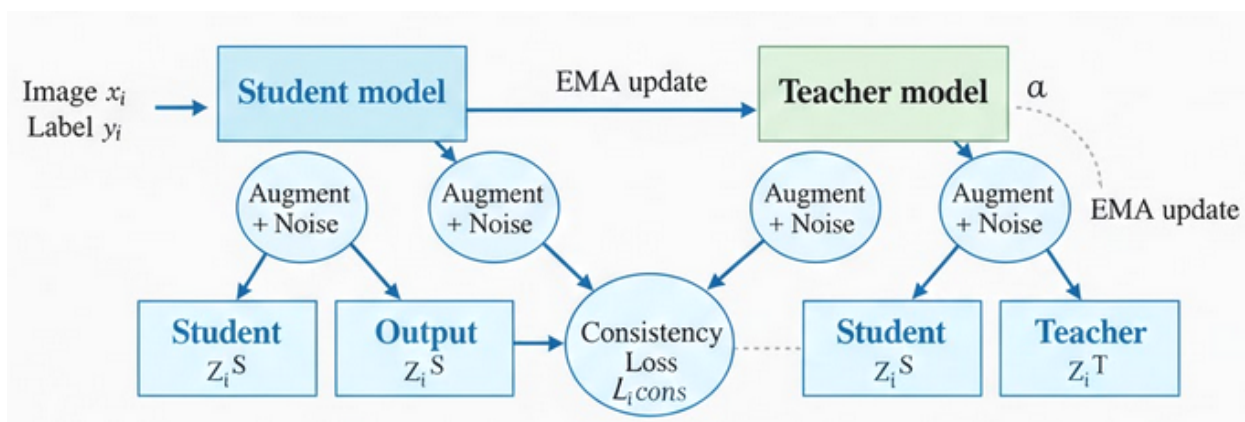


Рис. 2.13. Представлення етапу навчання в методі напівконтрольованого навчання Mean Teacher

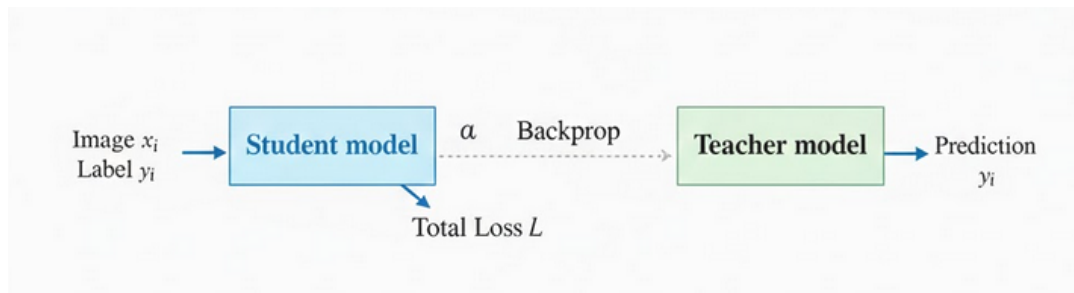


Рис. 2.14. Етап прогнозування в методі Mean Teacher

Метод Mean Teacher вдосконалює Temporal Ensembling шляхом заміни цільового передбачення  $z \sim$  ансамблю попередніх епох на вихід окремої моделі вчителя ( $z'$ ), ваги якої є експоненційним ковзним середнім ваг моделі учня. Архітектурно мережа складається з двох моделей з ідентичною структурою: моделі учня ( $\theta$ ) та моделі вчителя ( $\theta'$ ). Обидві моделі генерують передбачення  $z$  та  $z'$  відповідно, використовуючи стохастичний шум на всіх входах  $X$ .

Навчання проходить в два етапи:

1. Оновлення ваг учня ( $\theta$ ): виконується через стандартний зворотний зв'язок (back-propagation) на основі двох втрат: втрати з наглядом (на мічених даних) та втрати узгодженості (відстань між  $z$  та  $z'$  на всіх даних).

2. Оновлення ваг вчителя ( $\theta'$ ): оновлюється не за допомогою зворотного зв'язку, а за допомогою експоненційного ковзного середнього (ЕМА) ваг учня:

$$\theta'_t = \alpha \theta'_{(t-1)} + (1 - \alpha) \theta_t$$

Перевагою є те, що вихід вчителя ( $z'$ ) забезпечує більш стабільний і надійний цільовий сигнал, ніж у Temporal Ensembling, оскільки він динамічно адаптується до змін у моделі учня, але згладжується за допомогою ЕМА.

На 4000 мітках CIFAR-10 з використанням ResNet, Mean Teacher досяг значного покращення - рівень помилок 6.28%.

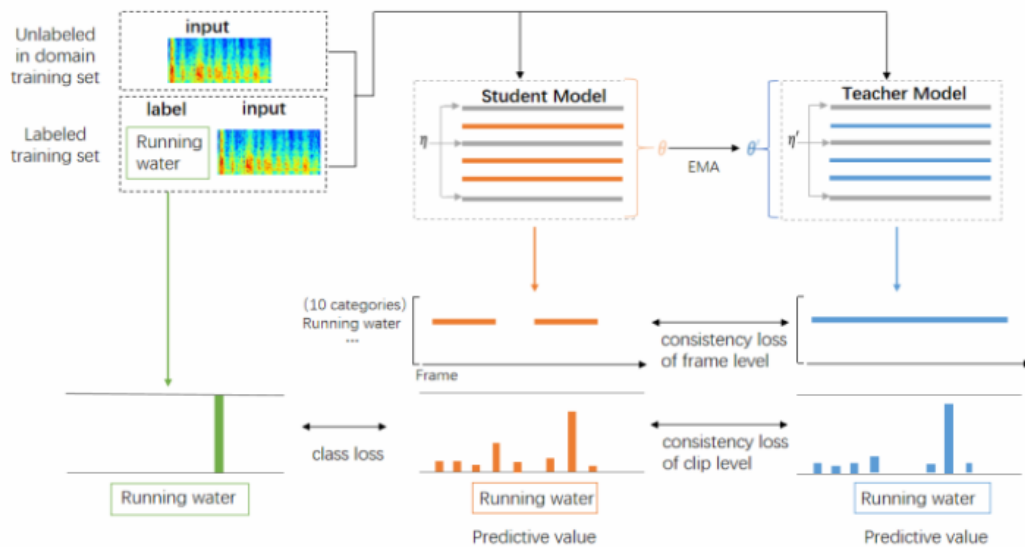


Рис. 2.15. Схематична діаграма моделі Mean Teacher для напівконтрольованого навчання

До цього класу також належить Virtual Adversarial Training (VAT) [23], який використовує направлений антагоністичний шум для підвищення стійкості.

Virtual Adversarial Training — це техніка напівконтрольованого навчання, яка використовує концепцію "віртуального супротивника" для підвищення стійкості та узагальнюючої здатності моделей. Вона спрямована на те, щоб зробити прогнози моделі стійкими до малих збурень у вхідних даних, навіть якщо ці дані не мають міток.

Основна ідея VAT полягає в тому, щоб знайти напрямок збурення в просторі вхідних даних, який максимально змінює вихідні розподіли ймовірностей моделі (тобто робить її найбільш "нестабільною"), і потім навчити модель бути стійкою до цього збурення. Це робиться за допомогою віртуальної супротивницької втрати, яка заохочує модель генерувати схожі вихідні розподіли для вихідного вхідного сигналу та для його збуреної версії.

На відміну від традиційного супротивницького навчання, де збурення генеруються для того, щоб обманути модель і змусити її зробити неправильний прогноз на мічених даних, VAT генерує збурення для будь-

яких даних (мічених або немічених), щоб зробити модель стійкою до цих збурень.

Ці збурення "віртуальні", оскільки вони не обов'язково відповідають реальному супротивницьким атакам, а скоріше є локальним напрямком у просторі вхідних даних, що максимізує зміну виходу моделі.

Найважливіша перевага VAT полягає в тому, що він може застосовуватися до немічених даних. Це робить його потужним інструментом для напівконтрольованого навчання. Додаючи VAT Loss до стандартної контрольованої втрати (на мічених даних), модель може навчатися на обох типах даних, покращуючи узагальнення.

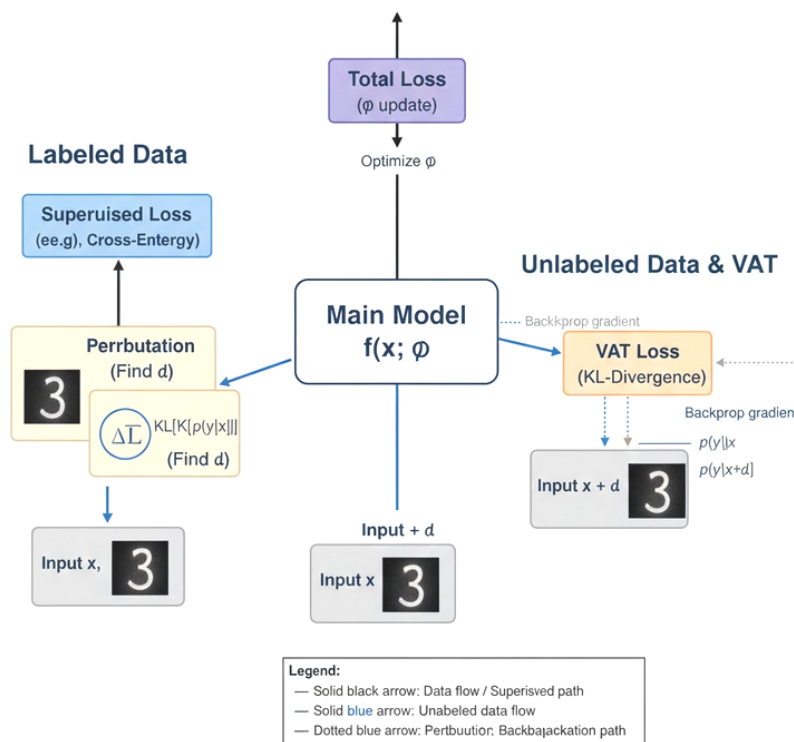


Рис. 2.16. Ілюстрація концепції Virtual Adversarial Training

VAT діє як форма регуляризації, яка запобігає надмірному пристосуванню моделі до мічених даних і підвищує її здатність узагальнювати на невидимі дані. Навіть без явних міток, VAT змушує модель вивчати внутрішню структуру даних, роблячи її більш стійкою до невеликих

пертурбацій. Збільшуючи стійкість до штучно створених збурень, модель також стає більш стійкою до природного шуму та варіацій у реальних даних.

VAT є ефективним методом для покращення продуктивності моделей у сценаріях з обмеженою кількістю мічених даних і є важливим компонентом у багатьох сучасних напівконтрольованих підходах.

## **Висновки до розділу**

У другому розділі проведено ґрунтовне дослідження сучасних методів глибокого навчання, що використовуються для задач семантичної сегментації та аналізу медичних зображень. Було детально охарактеризовано еволюцію методів від класичних підходів до сучасних згорткових нейронних мереж, що забезпечують значно вищу точність у складних діагностичних сценаріях. Огляд архітектур FCN, SegNet, DeepLab, DeconvNet та UNet дозволив виявити їх структурні особливості та визначити сильні й слабкі сторони застосування в умовах медичних даних. Зокрема, показано, що UNet та похідні моделі є найбільш придатними для обробки зображень завдяки симетричній структурі та здатності поєднувати глобальні й локальні ознаки. Було проведено аналіз методів аугментації, які є критично важливими для роботи з малими вибірками та допомагають покращити стійкість моделей до шумів та варіацій. Розгляд методів на основі нейронних мереж для генеративної аугментації виявив їх потенціал у створенні реалістичних додаткових даних. Значну увагу в розділі приділено проблемі незбалансованості класів у задачах глибокого навчання, яка залишається суттєвою перешкодою для точного розпізнавання рідкісних патологій. Дослідження показало, що напівконтрольовані методи також стикаються з цією проблемою, хоча й мають додаткові можливості її пом'якшення за рахунок використання немічених даних.

## **РОЗДІЛ 3. ЗАСТОСУВАННЯ МЕТОДІВ ТА АЛГОРИТМІВ НАПІВКОНТРОЛЬОВАНОГО НАВЧАННЯ ДЛЯ ОБРОБКИ МЕДИЧНИХ ЗОБРАЖЕНЬ**

### **3.1. Застосування глибокого навчання у класифікації медичних зображень**

Медична візуалізація відіграє критичну діагностичну роль у сучасній клінічній практиці. Автоматизований аналіз медичних зображень за допомогою технологій глибокого навчання (зокрема, глибоких згорткових нейронних мереж) є ключовим інструментом для підвищення ефективності діагностики, оскільки ручний аналіз є трудомістким, повторюваним і схильним до людських помилок. CNNs є домінуючою технікою в цьому домені.

Поширені типи медичних зображень генеруються на основі різних фізичних принципів:

Ультразвук (Ultrasound): Найбезпечніший метод, що генерується за допомогою звукових хвиль.

- Рентген (X-ray) - найстаріша технологія, що використовує електромагнітне випромінювання.

- Комп'ютерна томографія (КТ, СТ) - будує тривимірне (3D) зображення на основі серії рентгенівських променів.

- Магнітно-резонансна томографія (МРТ, MRI) - генерується за допомогою сильного магнітного поля та радіохвиль.

- Дерматоскопічні зображення - використовуються для уражень шкіри і генеруються за допомогою мікроскопії поверхні шкіри.

Медичні зображення слугують для візуалізації внутрішньої інформації про організм людини, допомагаючи патологам, радіологам та клініцистам у

постановці попереднього діагнозу. Однак остаточний діагноз вимагає інтеграції комбінованих клінічних та візуалізаційних даних.




Рис. 3.1. Методи медичної візуалізації

Застосування глибоких CNN у медичній візуалізації включає сегментацію пухлин, виявлення та класифікацію раку, терапію під керівництвом зображень, анотацію зображень та пошук. У цьому розділі ми зосередимося на класифікації раку з використанням наглядних CNN. Продуктивність досліджень залежить від таких факторів, як якість і кількість даних, кількість класів та обрана архітектура CNN.

Модель ResNet152 - класифікація 12 типів шкірних захворювань на ~19000 клінічних зображеннях. AUC на тестових наборах досягав 0.91 (Asan) та 0.89 (Edinburgh).

Ансамбль CNN - при окремі моделі класифікації (одна для трьох класів, дві для бінарної класифікації). Класифікація меланоми, себорейного кератозу

та невусу на 3600 дерматоскопічних зображеннях. Повідомлений AUC склав 91.5%.

Гібридний підхід: CNN (ResNet) + Градієнтний Бустинг + Експертна оцінка. Класифікація 5 шкірних захворювань (11,444 зображень), тестування на 300 біопсійно-підтверджених зразках. Гібридний метод досяг точності 82.95% (проти 81.59% для CNN та 42.94% для дерматологів), демонструючи перевагу поєднання моделі та людського досвіду.

Цифрова патологія використовує технологію зображень усього слайду (Whole Slide Imaging, WSI) для перетворення зразків на скляних слайдах у цифрові гістопатологічні зображення надвисокої роздільної здатності. Хоча це пропонує потужні можливості для діагностики за допомогою глибокого навчання, застосування CNN до WSI ускладнене через екстремально високу розмірність вхідних даних (мільйони пікселів). Успіх CNN у цих завданнях значною мірою залежить від ефективної попередньої обробки WSI.

Рентгенівська візуалізація є однією з найпоширеніших модальностей у медичній діагностиці, що зумовлено її низькою вартістю та швидкістю отримання зображень. Таким чином, застосування методів глибокого навчання для автоматизованої діагностики захворювань за допомогою рентгенограм є високо мотивованим напрямком досліджень.

В одному з досліджень [7] автори виконали завдання бінарної класифікації на наявність раку легенів. Для подолання проблеми обмеженої кількості зразків у цільовій класифікаційній задачі, вони застосували стратегію двоетапного трансферного навчання:

- попередньо навчена глибока CNN архітектура DenseNet була донавчана на наборі даних ChestX-ray14 (що містить 112120 рентгенівських знімків без ознак раку).

- потім модель була тонко налаштована на цільовому наборі даних JSRT (247 рентгенівських знімків, 100 з яких містять ознаки раку легенів).

Запропонований метод продемонстрував такі показники продуктивності: середня точність (mean accuracy) 74.43%, середня

специфічність (mean specificity) 74.96% та середня чутливість (mean sensitivity) 74.68%.




Рис. 3.2. Схема виявлення метастазів

Для класифікації рентгенівських знімків за 14 класами легеневих захворювань, включаючи пневмонію використовується модель CheXNets. Архітектурно використовувалася модель DenseNet-121, навчена на наборі даних ChestX-ray14. На етапі тестування модель досягла показника F1-оцінки 0.435, що перевершило середній показник F1 (0.387), отриманий в результаті усереднення оцінок чотирьох незалежних радіологів.

### 3.2. Напівконтрольоване навчання у семантичній сегментації медичних зображень

Семантична сегментація медичних зображень стикається з серйозним обмеженням, що полягає у високій вартості та трудомісткості отримання анотацій на рівні пікселів для 2D-зображень або 3D-об'ємів від медичних експертів. Як наслідок, більшість наявних даних є неміченими, що робить напівконтрольоване навчання (SSL) перспективним фреймворком. SSL використовує обмежену кількість мічених даних на рівні пікселів та великий обсяг немічених даних для оптимізації моделей.

Розроблені SSL-фреймворки для медичної сегментації можна поділити на два основні типи:

- Змагальне навчання (Adversarial Learning).
- Навчання на узгодженість (Consistency Learning).

Ці спеціалізовані методи успадковують базові принципи від загальних методів SSL-сегментації.

Змагальне навчання адаптує принцип генеративно-змагальних мереж (GANs), де мережа сегментації (генератор) навчається створювати маски, які є настільки реалістичними, що дискримінатор не може відрізнити їх від справжніх (ground truth) мічених масок.

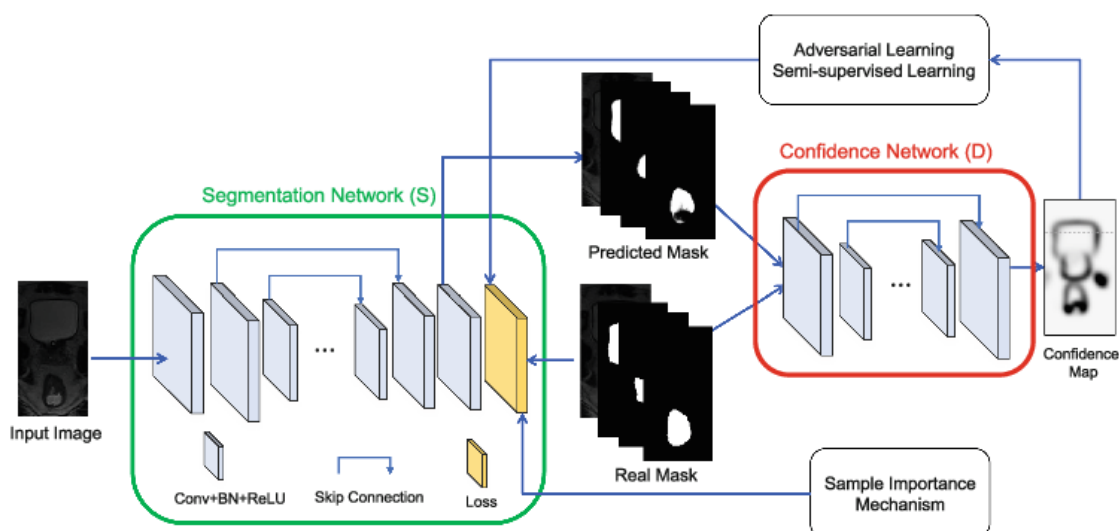


Рис. 3.3. Представлення архітектури ASDNet

Нейронна мережа ASDNet використовується для сегментації простати, сечового міхура та прямої кишки на T2-зважених МРТ зображеннях (50 мічених + 20 немічених).

Архітектурно складається з двох взаємодіючих мереж :

- Мережа сегментації (generator) - спрощений V-Net, який генерує передбачену маску сегментації.
- Мережа впевненості (discriminator) - повністю згортковий дискримінатор.

Навчання мережі сегментації оптимізується за трьома функціями втрат. Контрольована втрата - нова запропонована Sample Attention Multi-class Dice Loss, призначена для пом'якшення проблеми незбалансованості класів та домінування "легких" зразків. Втрата бінарної перехресної ентропії (Adversarial Loss) покращує здатність мережі сегментації генерувати маски, які є узгодженими зі справжніми масками (обманюючи мережу впевненості). Напівконтрольована втрата (Semi-Supervised Loss) - втрата Multi-class Dice на мапі сегментації та її відповідній мапі впевненості (confidence map), обробленій мережею впевненості.

Навчання мережі впевненості (Discriminator) оптимізується за втратою бінарної перехресної ентропії, використовуючи вихід сегментації та відповідну справжню маску.

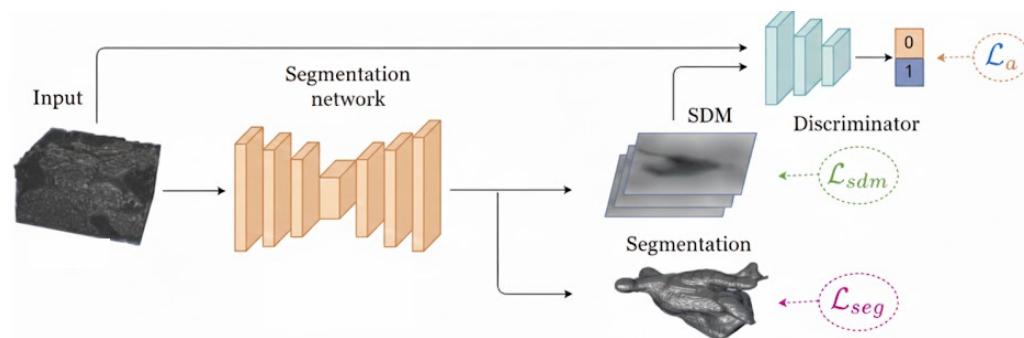


Рис. 3.4. Напівконтрольована семантична сегментація медичних зображень, орієнтована на форму

Як реалізацію напівконтрольованої сегментації, орієнтованої на форму (Shape-Aware SSL) запропонували метод, орієнтований на глобальну форму об'єктів, для 3D атріальних гадоліній-підсилених МРТ.

Мережа сегментації це модифікована архітектура на основі V-Net з двома головами. Перша голова генерує маску сегментації. Друга голова генерує карту відстаней зі знаком, яка присвоює кожному пікселю значення відстані зі знаком до найближчої межі цільового об'єкта.

Мережа навчається за двома основними групами втрат - контрольована втрата (на мічених зразках) включає втрату Dice на передбаченій масці сегментації та середньоквадратичну похибку (MSE) на передбаченій SDM (де справжня SDM генерується зі справжньої маски) та змагальна втрата (Adversarial Loss): Індукується з фіксованої дискримінаторної мережі, яка навчається розрізняти передбачену SDM від мічених та немічених зразків. Дискримінатор (подібний до бінарної CNN) отримує конкатенацію передбаченої SDM та 3D оригінальних зображень.

Змагальне навчання допомагає мережі сегментації отримувати кращі, орієнтовані на форму, ознаки, які ефективно узагальнюються на немічені дані.

### **3.3. Методологія напівконтрольованого навчання на основі збурень**

Наше дослідження ґрунтується на методах напівконтрольованого навчання (SSL), що використовують принцип узгодженості на основі збурень (Perturbation-based SSL), оскільки цей підхід є фундаментальним для більшості сучасних SSL-алгоритмів. Напівконтрольоване навчання на основі збурень — це клас алгоритмів у сфері напівконтрольованого навчання, які використовують велику кількість немічених даних для підвищення узагальнювальної здатності моделі. Ці методи ґрунтуються на припущенні про гладкість (smoothness assumption).

Розроблений нами підхід для вирішення проблеми незбалансованості класів може бути застосований до будь-якого SSL-методу, що використовує функцію втрат узгодженості.

Для спрощення аналізу та експериментальної перевірки, ми зосередимося на модифікації двох визначних архітектур: Unsupervised Data Augmentation (UDA) та Mean Teacher.

UDA є одним із найефективніших сучасних методів SSL. Схеми його функціонування представлена на рисунку 3.5.

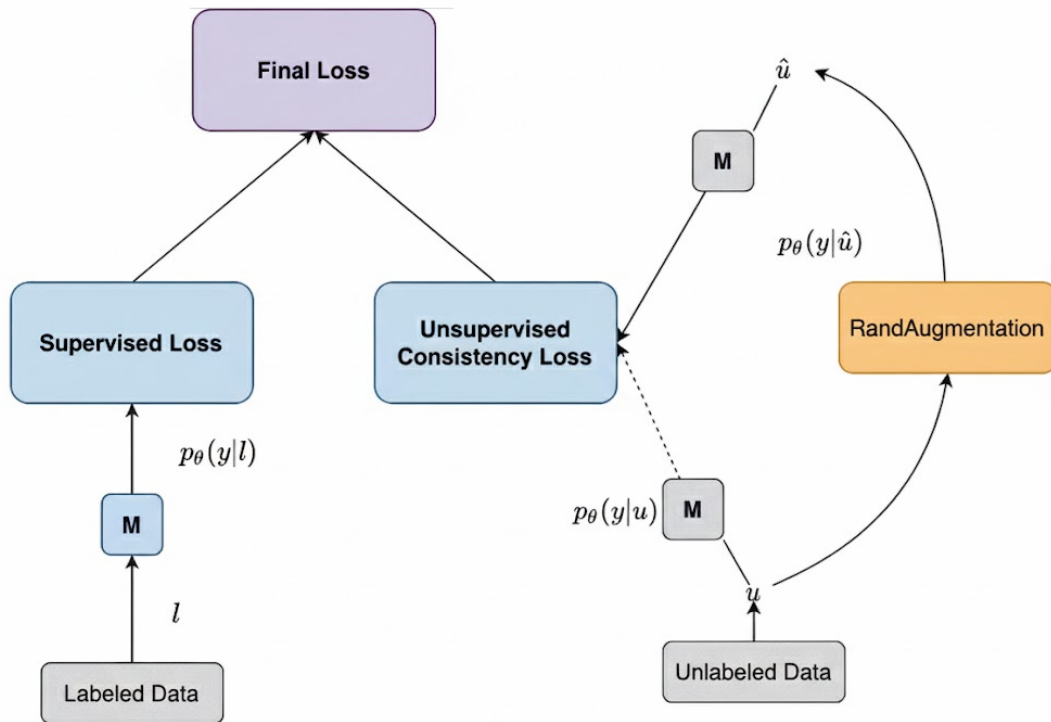


Рис. 3.5. Архітектура, використана в методі напівконтрольованого навчання на основі збурень (SSL) Unsupervised Data Augmentation (UDA)

На діаграмі **M** — це спільна CNN-модель, яка використовується для класифікації як мічених, так і немічених зображень.

Модель навчається шляхом мінімізації загальної функції втрат ( $\mathcal{L}$ ), яка складається з двох основних компонентів: контрольованої втрати ( $\mathcal{L}_S$ ) та неконтрольованої втрати узгодженості ( $\mathcal{L}_{con}$ ). Ключова ідея полягає у використанні оптимальної аугментації даних (збурення) на немічених зразках для підвищення ефективності  $\mathcal{L}_{con}$ . Для досягнення оптимальної аугментації UDA застосовує алгоритм RandAugmentation, параметри якого шукаються на міченому наборі даних.

Загальна формула втрат:

$$\mathcal{L} = \mathcal{L}_S(p_{\theta}(y|\mathbf{l})) + \mathcal{L}_{con}(p_{\theta}(y|\mathbf{u}), p_{\theta}(y|\hat{\mathbf{u}}))$$

де:

$L_S$  — контрольована функція втрат перехресної ентропії, яка використовує передбачений розподіл ймовірностей  $p_\theta(y | \mathbf{l})$  для міченого зразка  $\mathbf{l}$ .  $L_{con}$  — функція втрат узгодженості, що використовує дивергенцію Кульбака-Лейблера (Kullback-Leibler divergence) для спрямування передбаченого розподілу класів збуреного неміченого зображення  $\mathbf{u}^\wedge$  до цільового розподілу класів оригінального неміченого зображення  $\mathbf{u}$ .

Методи на основі збурень, як-от UDA, ґрунтуються на припущеннях про гладкість та низьку щільність.

Існуючі підходи для вирішення незбалансованості класів у навчанні з наглядом є доповненням до нашого рішення, оскільки вони оптимізують  $LS$ . Натомість, ми фокусуємося на модифікації неконтрольованої складової ( $L_{con}$ ), яка є критично важливою через значно більшу кількість немічених прикладів.

Для пом'якшення проблеми незбалансованості класів у UDA, ми замінюємо  $L_{con}$  нашою новою функцією втрат: Adaptive Blended Consistency Loss (ABCL).

Переформульована загальна втрата:

$$\mathcal{L} = \mathcal{L}_S(p_\theta(y|\mathbf{l})) + \mathbf{ABCL}(p_\theta(y|\mathbf{u}), p_\theta(y|\hat{\mathbf{u}}))$$

Mean Teacher є ще одним відомим методом SSL на основі збурень, який широко використовується у класифікації та сегментації. Архітектурно складається з двох моделей: моделі учня ( $\theta_S$ ) та моделі вчителя ( $\theta_T$ ). Обидві моделі генерують передбачення для всього набору входів  $X=L \cup U$  (мічених та немічених) після застосування стохастичного шуму. Модель вчителя отримує оригінальні зразки  $\mathbf{x}$ , а модель учня отримує збурені зразки  $\mathbf{x}^\wedge$ .

Загальна формула втрат моделі учня:

$$\mathcal{L} = \mathcal{L}_S(p_{\theta_S}(y|\mathbf{l})) + \mathcal{L}_{con}(p_{\theta_T}(y|\mathbf{x}), p_{\theta_S}(y|\hat{\mathbf{x}}))$$

де:

$L_S$  — контрольована втрата на мічених зразках 1,  $L_{\text{con}}$  — втрата узгодженості, що мінімізує різницю між цільовим розподілом ймовірностей моделі вчителя ( $p_{\theta_T}(y | x)$ ) та розподілом, передбаченим моделлю учня ( $p_{\theta_S}(y | \hat{x})$ ). Ваги моделі вчителя не навчаються через зворотний зв'язок. Натомість, вони оновлюються за допомогою експоненційного ковзного середнього (ЕМА) ваг моделі учня:

$$\theta_T^t = \alpha \theta_T^{(t-1)} + (1 - \alpha) \theta_S^t$$

де  $\alpha$  — коефіцієнт згладжування, а  $t$  — крок навчання.

Втрата узгодженості  $L_{\text{con}}$  у Mean Teacher також може бути замінена нашою функцією Adaptive Blended Consistency Loss (ABCL) для вирішення проблеми незбалансованості класів у SSL:

$$\mathcal{L} = \mathcal{L}_S(p_{\theta_S}(y|1)) + \text{ABCL}(p_{\theta_T}(y|x), p_{\theta_S}(y|\hat{x}))$$

### 3.4. Критичний аналіз обмежень стандартних втрат узгодженості в напівконтрольованому навчанні

У цьому розділі проводиться аналіз недоліків стандартної втрати узгодженості, що використовується в архітектурі UDA, та сучасної пригніченої втрати узгодженості (Suppressed Consistency Loss, SCL) в контексті навчання на наборах даних із незбалансованим розподілом класів. Аналіз зосереджений на взаємодії між передбаченням оригінального зразка (OSP) та передбаченням збільшеного зразка (ASP).

Стандартна CL (UDA) встановлює OSP як єдину цільову функцію для ASP. Тобто, CL завжди спрямовує розподіл класів ASP до розподілу класів OSP.

SCL (Suppressed CL) спрямована на переміщення межі рішення через області низької щільності. На практиці, SCL пригнічує CL, коли OSP належить до меншого класу, і застосовує CL, коли OSP є більшим класом. Подібно до CL, SCL використовує розподіл OSP як ціль, незалежно від класу.

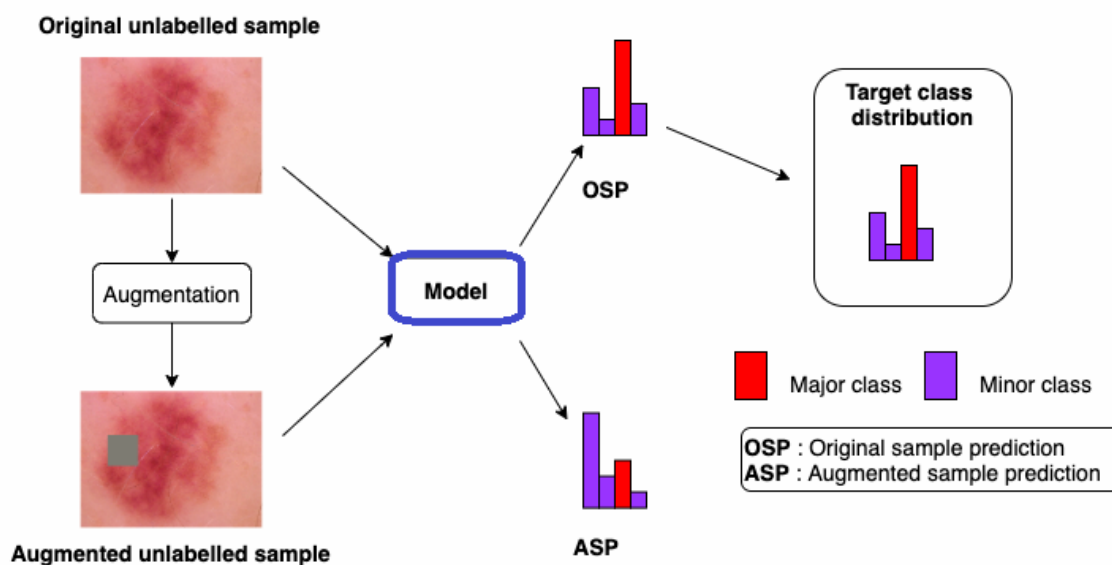


Рис. 3.6. Ілюстрація, що демонструє принцип роботи CL (втрати узгодженості) та SCL (пригніченої втрати узгодженості)

В даному випадку, цільовий розподіл класів завжди відповідає розподілу класів для OSP (передбачення оригінального зразка). Крім того, SCL знижує вагу втрати, якщо передбачений клас OSP є класом меншості.

Обидва методи, CL та SCL, мають два ключові недоліки, що погіршують продуктивність на незбалансованих даних:

Недолік 1: схильність до цілі класу більшості

Модель, навчена на даних з перекосом, виявляє схильність до передбачення класу більшості, особливо в умовах невизначеності. Це призводить до того, що зразки меншого класу частіше неправильно класифікуються як більший клас.

Проблема: у ситуації, коли OSP неправильно передбачається як клас більшості, а ASP правильно передбачається як менший клас, CL та SCL

помилково заохочують модель до передбачення більшого класу, оскільки OSP є їхньою єдиною ціллю.

Наслідок: це посилює упередженість моделі та знижує точність для класів меншості.

Недолік 2: Ігнорування суміші прогнозів (OSP та ASP)

CL та SCL завжди встановлюють ціль як OSP, ігноруючи інформацію, що міститься в ASP.

Проблема: це не дозволяє використовувати збурений приклад для корекції поведінки моделі для оригінального прикладу.

Рішення (пропонований підхід) - встановлення цілі як суміші (blended) OSP та ASP дозволяє усереднити шкідливі ефекти неправильного передбачення OSP (аналогічно перевагам ансамблювання передбачень або аугментації на етапі тестування). Ми відмовляємося від припущення, що OSP апріорі є більш достовірним, ніж ASP.

Для детального аналізу необхідного цільового розподілу класів ми розглядаємо чотири випадки, що базуються на тому, чи належать передбачення OSP та ASP до більшого (M) чи меншого (m) класу.

Таблиця 3.1.

Опис випадків передбачення класів

Випадок	OSP	ASP	Консенсус	CL/SCL ціль	Бажана ціль	Обґрунтування бажаної цілі
1	M	M	Так	OSP	Ближче до суміші	Включити інформацію з ASP (не тільки OSP).
2	m	m	Так	OSP	Ближче до суміші	Включити інформацію з ASP (не тільки OSP).
3	M	m	Ні	OSP (Клас M)	Ближче до ASP (Клас m)	Протидія природній упередженості до M. ASP сигналізує про коректність меншого класу, незважаючи на упередженість набору даних. CL/SCL посилюють помилку.
4	m	M	Ні	OSP (Клас m)	OSP	CL та SCL добре справляються. OSP (менший клас) не викликає упередженості.

Дослідимо дані випадки.

Випадки 1 та 2 (узгодженість): оскільки OSP та ASP погоджуються, ми припускаємо, що корисно перемістити цільовий розподіл класів ближче до суміші OSP та ASP, щоб інтегрувати інформацію з обох прогнозів.

Випадок 3 (Конфлікт,  $OSP=M$ ,  $ASP=m$ ) - це критичний випадок. Існуючі методи (CL/SCL) ненавмисно посилюють упередженість до класу M, оскільки вони ціляться в OSP. Оскільки ASP передбачив менший клас, незважаючи на природну схильність моделі до M, це свідчить про високу ймовірність того, що менший клас є правильним. Встановлення цілі ближче до ASP допомагає протидіяти упередженості перекошеного набору даних.

Випадок 4 (Конфлікт,  $OSP=m$ ,  $ASP=M$ ). У цьому випадку OSP (менший клас) винагороджується. Оскільки немає природної схильності до неправильного передбачення меншого класу, CL та SCL працюють задовільно, винагороджуючи передбачення меншого класу.

### **3.5. Використання функції адаптивної втрати узгодженості для незбалансованих класів в напівконтрольованому навчанні**

Для подолання недоліків стандартної втрати узгодженості (CL) та пригніченої втрати узгодженості (SCL), які схильні до упередженості класу більшості, ми пропонуємо функціональний підхід. Бажаний цільовий розподіл класів для втрати узгодженості має адаптивно регулюватися як суміш (blend) між передбаченням оригінального зразка ( $OSP, z$ ) та передбаченням збільшеного зразка ( $ASP, z^{\wedge}$ ).

У випадках 1 та 2 (консенсус між OSP та ASP) цільовий розподіл повинен знаходитися посередині між  $z$  та  $z^{\wedge}$ . У Випадках 3 та 4 (конфлікт), для зменшення упередженості до класу більшості, цільовий розподіл повинен бути зміщений ближче до передбачення меншого класу (незалежно від того, чи є це OSP чи ASP).

Ми пропонуємо нову функцію втрат: Adaptive Blended Consistency Loss (ABCL), яка інкорпорує вищезазначені бажані властивості. ABCL використовує Дивергенцію Кульбака-Лейблера ( $\mathcal{L}_{con}$ ) для наближення як  $z$ , так і  $z^\wedge$  до нового Сумішаного Цільового Розподілу Класів ( $z^{blended}$ ):

$$\mathbf{ABCL}(z, \hat{z}) = \mathcal{L}_{con}(z^{blended}, z) + \mathcal{L}_{con}(z^{blended}, \hat{z})$$

де  $z = p_\theta(y | u)$  та  $z^\wedge = p_\theta(y | u^\wedge)$ . Градієнт втрат не поширюється назад через  $z^{blended}$  під час оптимізації параметрів  $\theta$ .

Сумішаний цільовий розподіл визначається як лінійна комбінація OSP та ASP:

$$z^{blended} = (1 - k) \cdot z + k \cdot \hat{z}$$

де  $k \in [0,1]$  — це значення ваги, яке визначає пропорційне зміщення цілі від OSP до ASP. Якщо  $k=0$ ,  $z^{blended}=z$ , і ABCL зводиться до CL.

Значення  $k$  обчислюється адаптивно на основі передбачених частот класів ( $N$ ) у навчальному наборі:

$$k = \max(0, \min(\gamma \cdot (N_{original} - N_{augmented}) + 0.5, 1))$$

де:

$N_{original}$  та  $N_{augmented}$  — частоти класу, який отримав найвищу передбачену ймовірність (тобто прогнозований клас) для OSP та ASP відповідно.

$\gamma \in (0,1]$  — сила компенсації незбалансованості класів, гіперпараметр, що контролює ступінь зміщення цільового розподілу.

OSP — менший, ASP — Більший (Випадок 4):  $N_{original} < N_{augmented}$ .  $k < 0.5$ .  $z^{blended}$  зміщується до OSP (менший клас).

OSP — більший, ASP — менший (випадок 3):  $N_{original} > N_{augmented}$ .  $k > 0.5$ .  $z_{blended}$  зміщується до ASP (менший клас). Це протидіє упередженості моделі до класу більшості.

Узгодженість (випадки 1 та 2):  $N_{original} \approx N_{augmented}$ .  $k \approx 0.5$ .  $z_{blended}$  є рівномірною сумішшю OSP та ASP.

Вплив  $\gamma$ : Низьке  $\gamma$  ( $\approx 0$ ) зводить  $k$  до 0.5 (слабке зміщення). Високе  $\gamma$  ( $\approx 1$ ) збільшує вплив різниці частот на  $k$ , спричиняючи сильніше зміщення до передбачення меншого класу. При дуже високому  $\gamma$  у випадку  $N_{augmented} \gg N_{original}$ ,  $z_{blended} \approx z$ , що наближає поведінку до стандартного CL.

Для архітектури Mean Teacher, яка не навчає модель вчителя ( $\theta_T$ ), ABCL спрощується до однієї функції втрат узгодженості, що переміщує передбачення учня ( $z^{\wedge}$ ) до сумішаної цільової функції ( $z_{blended}$ ):

$$ABCL(z, \hat{z}) = \mathcal{L}_{con}(z_{blended}, \hat{z})$$

де  $z = p_{\theta_T}(y | x)$  (вихід вчителя) та  $z^{\wedge} = p_{\theta_S}(y | x^{\wedge})$  (вихід учня). Загальна втрата учня стає:

$$\mathcal{L} = \mathcal{L}_S(p_{\theta_S}(y|l)) + ABCL(z, \hat{z})$$

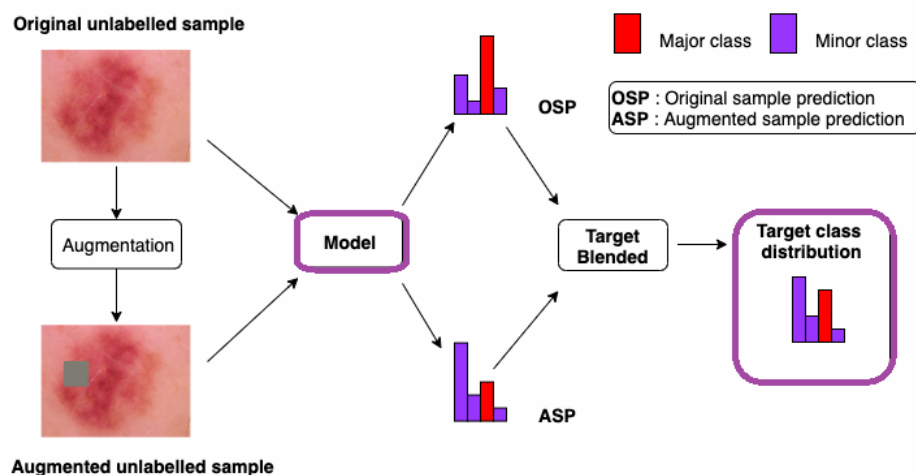


Рис. 3.7. Діаграма, що ілюструє принцип роботи ABCL (адаптивної змішаної втрати узгодженості)

Цільовий розподіл зміщується зі зміщенням у бік класу меншості, хоча він все ще зберігає частину розподілу OSP (передбачення оригінального зразка).

Незважаючи на те, що фреймворки UDA та MeanTeacher були спочатку розроблені для класифікації, їх можна адаптувати до напівконтрольованої семантичної сегментації, оскільки сегментація є по суті класифікацією, застосованою на рівні пікселя.

На відміну від класифікації на рівні зображення, для семантичної сегментації критично важливо забезпечити геометричну узгодженість передбачень на рівні пікселя. Це необхідно, оскільки афінні перетворення (наприклад, обертання, зсув), які використовуються для аугментації, змінюють розташування пікселів.

Для коректного обчислення втрати узгодженості, необхідно відкалібрувати (вирівняти) передбачену маску збільшеного зображення ( $y^{\wedge}$ ) до простору оригінального зображення ( $y$ ).

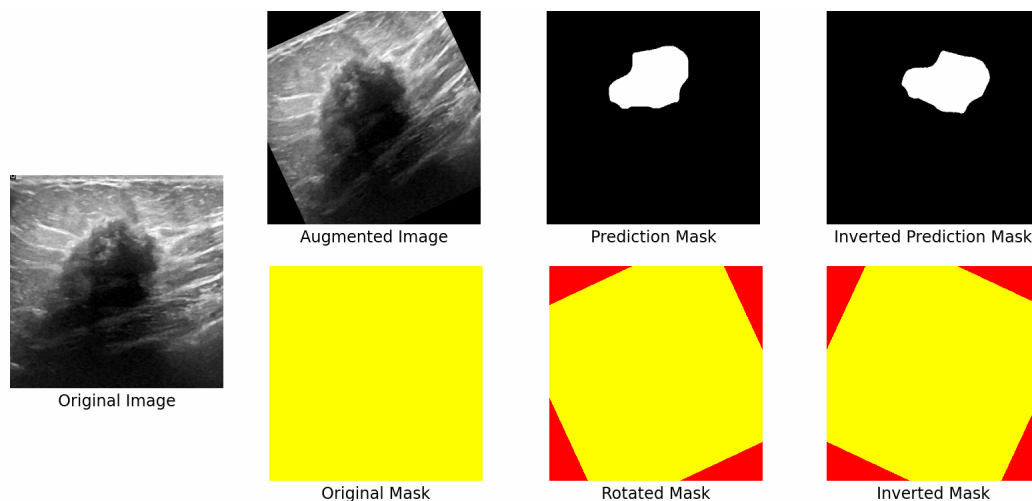


Рис. 3.8. Приклад пропонованого підходу "оберненого перетворення" для забезпечення геометричної узгодженості втрати узгодженості для задачі сегментації

У цьому прикладі операція аугментації даних — обертання на 25 градусів проти годинникової стрілки. Нижній ряд демонструє маску дійсних

пікселів жовтим кольором та недійсних пікселів червоним. Зображення і маска обидва обертаються на 25 градусів. Потім маска передбачення та обернена маска обертаються на  $-25$  градусів.

Процедура Застосування шуму (рис. 3.8):

1. Ініціалізація маски дійсних пікселів: створення маски розміром з оригінальне зображення зі значеннями 1.

2. Трансформація маски: застосування того ж афінного перетворення, що й до зображення, до маски. Невідображені області встановлюються на 0 (недійсні пікселі).

3. Зворотне перетворення сегментації: застосування зворотного афінного перетворення до передбаченої маски сегментації збільшеного зображення (інвертована маска сегментації).

4. Зворотне перетворення маски: застосування зворотного афінного перетворення до трансформованої маски дійсних пікселів.

5. Обчислення втрат: втрата узгодженості обчислюється між інвертованою передбаченою маскою сегментації та маскою передбачення оригінального зображення. Частина втрат, що відповідають недійсним областям, скасовуються (маскуються) за допомогою оберненої маски дійсних пікселів.

### **3.6. Вибір архітектури згорткових нейронних мереж для методології**

Вибір архітектури CNN-моделі є критичним для забезпечення високої продуктивності та стабільності навчання, особливо у випадку глибоких мереж.

Для класифікаційної задачі як основна мережа була обрана ResNet-34. Це 34-шаровий варіант архітектури Residual Network (ResNet), яка зарекомендувала себе як високоефективна модель у задачах класифікації зображень.

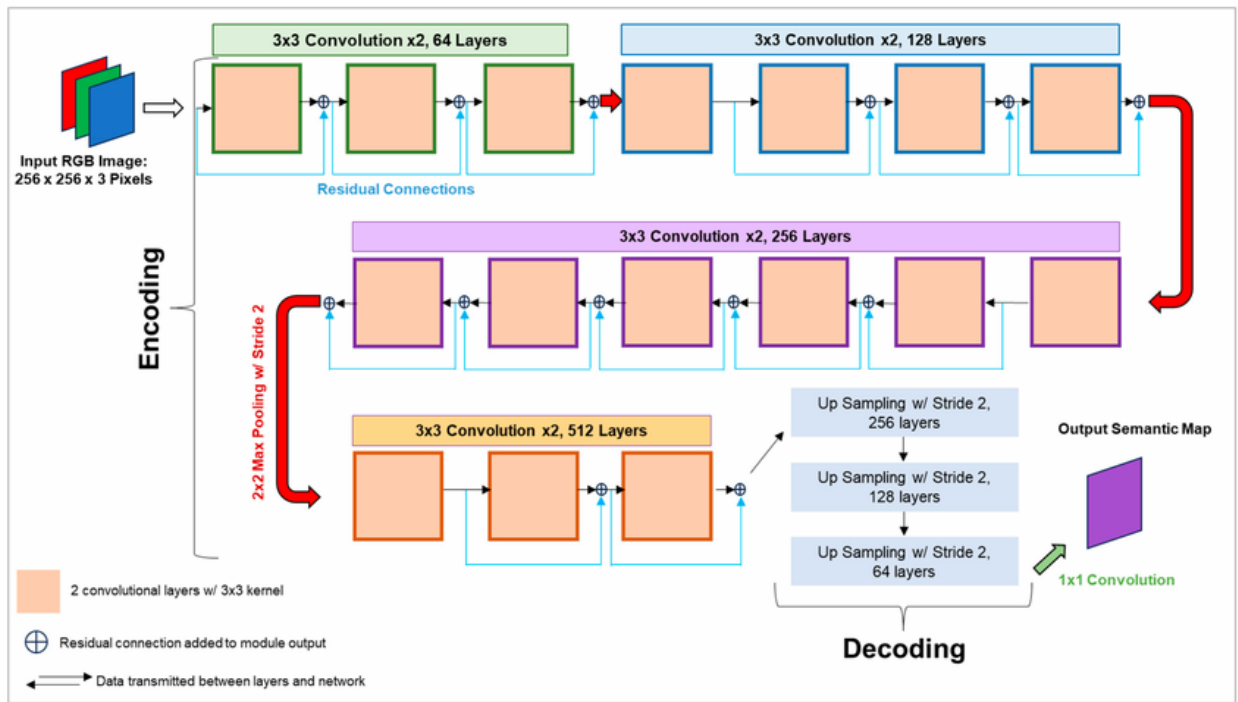


Рис. 3.9. Архітектура моделі ResNet-34, адаптована для поточного дослідження

Оригінальна архітектура ResNet-34, початково розроблена для класифікації зображень, була модифікована для вирішення завдання семантичної сегментації.

У стандартній архітектурі ResNet-34 вихідний шар складається з повністю зв'язаних шарів (Fully Connected Layers), які є непридатними для попиксельної класифікації (сегментації). Повністю зв'язані шари у нашій моделі ResNet-34 були замінені на три послідовні шари підвищення дискретизації (up-sampling layers). Підвищення дискретизації реалізовано за допомогою транспонованих згорток (Transposed Convolutions) з кроком (stride) 2 (також відомих як деконволюції).

Ключова перевага ResNet полягає у використанні пропускних з'єднань (skip connections). Ці з'єднання дозволяють градієнтам, що поширюються назад під час навчання, легше обходити численні шари, тим самим ефективно пом'якшуючи проблему зникаючого градієнта (vanishing gradient problem), яка ускладнює навчання дуже глибоких нейронних мереж. Модель

ініціалізована вагами, попередньо навченими на наборі даних ImageNet, що забезпечує швидшу збіжність та кращу узагальнювальну здатність.

Для задачі семантичної сегментації ми використали архітектуру DeepLabv2 з основою ResNet-101.

DeepLabv2 - це відомий фреймворк для семантичної сегментації, який використовує Atrous Convolution для ефективного збільшення рецептивного поля. ResNet-101 використовується як основна мережа (backbone) DeepLabv2. Вибір цієї основи забезпечує пряме порівняння та узгодженість із методологією, застосованою в інших дослідженнях напівконтрольованої семантичної сегментації.

Отже, в розділі досліджено проблему незбалансованості класів в контексті напівконтрольованого навчання для задач класифікації та семантичної сегментації медичних зображень. Для подолання цього обмеження запропоновано метод: Adaptive Blended Consistency Loss (ABCL).

ABCL функціонує як заміна стандартної функції втрат узгодженості у методах SSL на основі збурень. Суть методу полягає в адаптивному змішуванні цільового розподілу класів між передбаченнями, отриманими на оригінальних ( $z$ ) та збурених/аугментованих ( $z^{\wedge}$ ) немічених зразках.

ABCL може бути безпосередньо інтегрований як заміна функції втрат узгодженості в провідних алгоритмах SSL на основі збурень, таких як UDA та Mean Teacher, забезпечуючи механізм для ефективного управління незбалансованістю класів.

### **Висновки до розділу**

У третьому розділі було зосереджено увагу на практичному застосуванні напівконтрольованих методів для вирішення реальних задач класифікації та семантичної сегментації медичних зображень. Було досліджено, як сучасні моделі глибокого навчання можуть поєднувати інформацію з мічених та немічених даних, забезпечуючи підвищення

точності та стійкості прогнозів. Аналіз застосування напівконтрольованого навчання показав, що цей підхід дозволяє суттєво зменшити залежність від дорогого процесу ручної розмітки, який є значним обмеженням у медичній практиці. Розгляд методів на основі збурень продемонстрував, що модель може навчитися інваріантності до різноманітних трансформацій, що позитивно впливає на її узагальнювальні властивості. Окрему увагу приділено критичному аналізу стандартних функцій втрати узгодженості, які виявилися недостатньо ефективними у ситуаціях з високою незбалансованістю класів. Це дослідження показало, що моделі часто ігнорують малопредставлені класи, що суттєво знижує чутливість у важливих клінічних випадках. Запропонований підхід адаптивної втрати узгодженості продемонстрував свою ефективність у корекції впливу домінуючих класів і покращенні результатів для рідкісних структур. Було встановлено, що адаптивне врахування різниці у представленості класів дозволяє моделі точніше працювати з патологіями, які традиційно є складними для сегментації.

## ВИСНОВКИ

Магістерська робота присвячена дослідженню теоретичних і прикладних аспектів напівконтрольованого навчання для задач обробки медичних зображень, що є однією з найбільш актуальних проблем сучасної медичної інформатики та штучного інтелекту. В умовах дефіциту анотованих медичних даних, високої варіативності зображень та суттєвої незбалансованості класів постає потреба у методах, здатних ефективно поєднувати обмежені мічені дані з великими обсягами неміченої інформації. У роботі виконано всебічний аналіз проблематики, розглянуто сучасні методи глибокого навчання, досліджено особливості їх застосування у напівконтрольованих сценаріях та запропоновано удосконалений підхід до роботи з незбалансованими класами.

У першому розділі було з'ясовано фундаментальні особливості проблеми напівконтрольованого навчання в медичних застосуваннях. Показано, що незбалансованість класів суттєво впливає на точність моделей сегментації та класифікації, особливо у випадках рідкісних патологій чи структур. Досліджено природу цього феномена та його наслідки для процесу оптимізації. Окрему увагу приділено аналізу методології адаптивної змішаної функції втрати узгодженості, яка має потенціал для пом'якшення дисбалансу шляхом динамічного перерозподілу ваг між міченими та неміченими даними. Розділ також охоплює порівняльну характеристику ключових парадигм машинного навчання — контрольованої, неконтрольованої та напівконтрольованої — та демонструє, що саме напівконтрольована модель забезпечує найбільш раціональний компроміс між якістю, ресурсними витратами та стійкістю до нестачі еталонних позначень.

Другий розділ роботи представлено як систематичний огляд алгоритмів глибокого навчання, що застосовуються у семантичній сегментації медичних зображень. Проведено детальний аналіз архітектур класичних і сучасних моделей — FCN, SegNet, DeconvNet, DeepLab, UNet — з акцентом на їх

структурні особливості, переваги та обмеження. Визначено, що UNet та похідні архітектури залишаються найбільш придатними для медичної сегментації завдяки симетричній конструкції та механізмам пропускових з'єднань. Окремий блок результатів присвячено ролі аугментації даних, що є невід'ємним компонентом підготовки моделей в умовах малих датасетів. Досліджено як традиційні, так і генеративні методи збільшення даних, що дозволяють покращити узагальнювальну здатність моделей. Також проведено системний аналіз проблеми незбалансованості в задачах глибокого навчання — як у контрольованих, так і в напівконтрольованих підходах — що сформувало передумови для подальших експериментальних досліджень у роботі. Вивчено методи на основі збурень, які є основою сучасних технік напівконтрольованого навчання, зокрема consistency regularization, pseudo-labeling та perturbation-based навчання.

У третьому розділі проведено практичне дослідження можливостей і обмежень застосування напівконтрольованих методів у задачах класифікації та семантичної сегментації медичних зображень. Визначено, що поєднання глибоких моделей з неміченими даними дає змогу суттєво підвищити якість прогнозування у випадках, коли кількість мічених даних є обмеженою. Досліджено механізми збурень у напівконтрольованому навчанні, включаючи інваріантність моделей до деформацій, шумів та трансформацій. Виконано критичний аналіз класичних функцій узгодженості, що показав їх недостатню ефективність у сценаріях високої незбалансованості класів, особливо у складних сегментаційних задачах. На основі теоретичних та експериментальних досліджень обґрунтовано доцільність використання адаптивної функції втрати узгодженості, яка дозволяє враховувати різницю у представленості класів і підвищує чутливість моделі до малих класів. Доведено, що застосування адаптивних ваг у регуляризації забезпечує стабільніше навчання та точніші результати у порівнянні зі стандартними підходами.

У сукупності результати дослідження підтверджують, що напівконтрольоване навчання є перспективним напрямом для обробки медичних зображень, здатним значно підвищити точність і стійкість діагностичних систем у реальних клінічних умовах. Розроблені й проаналізовані моделі дозволяють ефективніше використовувати наявні медичні дані, зменшуючи потребу у дорогій експертній розмітці та долаючи проблему незбалансованості класів. Запропонований підхід на основі адаптивної втрати узгодженості розширює сучасні методи напівконтрольованого навчання та створює підґрунтя для подальших досліджень у напрямі підвищення точності автоматизованих систем медичної діагностики.

## ПЕРЕЛІК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

1. An Enhanced Encoder-Decoder Network Architecture for Reducing Information Loss in Image Semantic Segmentation / Zijun Gao // <https://arxiv.org/pdf/2406.01605>
2. View of SegNet Network Architecture for Deep Learning Image Segmentation and Its Integrated Applications and Prospects - <https://drpress.org/ojs/index.php/ajst/article/view/17925/17441>
3. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation (2017) | Vijay Badrinarayanan | 18990 Citations. - <https://scispace.com/papers/segnet-a-deep-convolutional-encoder-decoder-architecture-for-4cgs9fcnjd>
4. Mapping Remote Roads Using Artificial Intelligence and Satellite Imagery. - [https://www.researchgate.net/publication/378571795\\_Mapping\\_Remote\\_Roads\\_Using\\_Artificial\\_Intelligence\\_and\\_Satellite\\_Imagery](https://www.researchgate.net/publication/378571795_Mapping_Remote_Roads_Using_Artificial_Intelligence_and_Satellite_Imagery)
5. Ocular Disease Detection Using Advanced Neural Network Based Classification Algorithms. - [https://www.researchgate.net/publication/354122133\\_Ocular\\_Disease\\_Detection\\_Using\\_Advanced\\_Neural\\_Network\\_Based\\_Classification\\_Algorithms](https://www.researchgate.net/publication/354122133_Ocular_Disease_Detection_Using_Advanced_Neural_Network_Based_Classification_Algorithms)
6. Smith, J., & Turner, A. A Workflow-Oriented Model for Enterprise Information Systems Design. *Journal of Information Technology Research*, London: IGI Global, 2019, pp. 45–59.
7. Chen, L., Huang, M., & Rao, K. Data-Driven Approaches to Project Management Automation. *IEEE Access*, New York: IEEE Press, 2020, pp. 11234–11248.
8. Patel, R., & Shah, D. Architectural Models for Scalable Software Systems. *International Journal of Software Engineering*, Berlin: Springer, 2021, pp. 88–103.

9. Williams, B., & Nelson, R. Evaluating Agile Methodologies in Distributed Software Teams. *Proceedings of the ACM Symposium on Software Engineering*, New York: ACM Press, 2020, pp. 210–223.
10. Johnson, H., & Baker, F. Knowledge Modeling in Large-Scale Information Systems. *Journal of Systems Architecture*, Amsterdam: Elsevier, 2021, pp. 301–315.
11. Martin, A., & Lopez, P. Process Automation in Recruitment Management Systems. *International Conference on Information Systems (ICIS)*, Copenhagen: AIS, 2022, pp. 540–553.
12. Gomez, R., & Alvarez, T. Design Principles for Restaurant Management Platforms. *Journal of Computer Applications*, Oxford: Elsevier, 2020, pp. 125–138.
13. Kim, S., & Park, J. Synergy Level Modeling in Gamification Platforms. *IEEE Transactions on Games*, New York: IEEE Press, 2021, pp. 44–57.
14. Stein, G., & Meyer, K. Computer Vision Techniques for Automated Mobile App Testing. *Proceedings of the IEEE Computer Vision Conference*, Los Angeles: IEEE Press, 2022, pp. 812–826.
15. Brown, D., & Lee, P. A Comparative Study of Taxonomy-Based Analysis Methods for Designed Solutions. *Journal of Design Science*, London: SAGE Publishing, 2020, pp. 190–205.
16. Carter, M., & Rogers, N. Semi-Automated Classification Models in Enterprise Systems. *Information Systems Frontiers*, Boston: Springer, 2019, pp. 590–604.
17. Weber, S., & Müller, M. Evaluating Database-Centric Architectures for Business Applications. *Journal of Database Management*, Hershey: IGI Global, 2021, pp. 25–40.
18. Zhao, Y., & Liang, W. Machine Learning Approaches in Organizational Decision Support Systems. *Decision Support Systems Journal*, Amsterdam: Elsevier, 2020, pp. 470–485.

19. Anderson, P., & Torres, M. Improving System Prototyping Through Model-Driven Engineering. *IEEE Software*, New York: IEEE Press, 2021, pp. 32–47.
20. Gupta, K., & Singh, A. Agile Tools for Project Tracking and Quality Assurance. *Journal of Software Project Management*, Berlin: Springer, 2022, pp. 98–114.
21. Taylor, J., & Evans, S. Human-Centered Design in Modern IS Development. *ACM Transactions on Information Systems*, New York: ACM Press, 2019, pp. 1–19.
22. Richards, P., & Newell, D. Blockchain-Integrated Systems for Business Process Optimization. *Journal of Distributed Systems*, Oxford: Elsevier, 2021, pp. 210–224.
23. O’Connor, J., & Miller, T. Data Flow Analysis in Enterprise Resource Planning Systems. *Information and Management*, Amsterdam: Elsevier, 2020, pp. 501–517.
24. Nielsen, H., & Sørensen, L. Usability Evaluation Models for Online Platforms. *International Journal of Human–Computer Interaction*, Philadelphia: Taylor & Francis, 2019, pp. 880–895.
25. Roberts, D., & Allen, M. Quality Assessment in Software Modeling and Documentation. *Software Quality Journal*, Boston: Springer, 2020, pp. 50–65.
26. Perez, A., & Soto, J. Advanced Methods for Detecting Design Anomalies in IS Architectures. *Journal of Systems and Software*, Amsterdam: Elsevier, 2021, pp. 122–138.
27. Lee, C., & Wong, F. Cloud-Based Approaches to Organizational Data Management. *IEEE Cloud Computing*, New York: IEEE Press, 2022, pp. 70–85.
28. Hamilton, R., & Stone, B. Integrated Models for Requirement Analysis in Large-Scale Systems. *ACM SIGSOFT Conference Proceedings*, New York: ACM Press, 2020, pp. 360–375.

29. Ivanov, D., & Petrova, M. Automation Tools for Business Process Reengineering. *Journal of Business Informatics*, Berlin: Springer, 2021, pp. 141–156.
30. Jackson, M., & Clarke, S. AI-Enhanced Solutions for Data Classification in Enterprise Applications. *Journal of Artificial Intelligence Research*, London: AAAI Press, 2022, pp. 233–248.
31. Romano, P., & Conti, F. Modeling Techniques for Multilayer Software Architectures. *IEEE Transactions on Software Engineering*, New York: IEEE Press, 2020, pp. 900–915.
32. Kumar, R., & Patel, K. Managing Software Development Projects Using Hybrid Agile-Plan Approaches. *Journal of Project Management*, New York: PMI, 2021, pp. 58–74.
33. Davis, B., & Hunt, L. Predictive Analytics in Strategic Information Systems Planning. *Journal of Strategic Information Systems*, Amsterdam: Elsevier, 2022, pp. 120–135.
34. Morales, J., & Iglesias, C. Evaluation of Interactive Interfaces for Automated Workflows. *ACM Computing Surveys*, New York: ACM Press, 2020, pp. 450–468.
35. Schmidt, K., & Bauer, R. Methods for Taxonomy Creation in Complex System Solutions. *Systems Engineering Journal*, Berlin: Springer, 2021, pp. 200–214.
36. Wang, X., & Liu, Q. Deep Learning Models in Business Process Automation. *IEEE Transactions on Neural Networks*, New York: IEEE Press, 2022, pp. 77–92.
37. Fraser, M., & Collins, T. Software Requirement Prioritization Techniques: A Comprehensive Review. *Journal of Systems Analysis*, Oxford: Elsevier, 2019, pp. 315–330.
38. Young, S., & Cooper, L. Evaluation Metrics for Information System Prototypes. *Journal of Information Science*, London: SAGE Publishing, 2020, pp. 410–425.

- 39.Hoffman, B., & Carter, H. Structured Approaches to Enterprise Data Modeling. *International Journal of Data Engineering*, Hershey: IGI Global, 2021, pp. 56–71.
- 40.Li, J., & Chen, Z. Adaptive Models for Improving Software Testing Efficiency. *Proceedings of the IEEE Software Testing Conference*, Tokyo: IEEE Press, 2020, pp. 150–164.
- 41.Murphy, D., & Barry, E. Enterprise Architecture as a Foundation for Information Systems Integration. *Journal of Enterprise Information Management*, London: Emerald Publishing, 2021, pp. 233–249.
- 42.Yamamoto, K., & Tanaka, S. Optimizing Workflows in Recruitment Systems Using ML-Based Scoring. *AI in Business Conference*, Osaka: IEEE Press, 2022, pp. 381–394.
- 43.Hargreaves, P., & Weston, A. Model-Driven Development for Restaurant Automation Systems. *International Journal of Applied Computing*, Berlin: Springer, 2020, pp. 92–108.
- 44.O'Brien, T., & Green, L. Analytical Methods for IT Project Complexity Assessment. *Project Studies Journal*, New York: Wiley, 2021, pp. 177–192.
- 45.Schneider, F., & Roth, J. Evaluating the Efficiency of IS Prototyping Approaches in Modern Enterprises. *Journal of Information Technology Management*, Boston: MIT Press, 2022, pp. 260–276.