

**НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ «ОДЕСЬКА ЮРИДИЧНА АКАДЕМІЯ»
ФАКУЛЬТЕТ КІБЕРБЕЗПЕКИ ТА ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ**

Кафедра інформаційних технологій

КВАЛІФІКАЦІЙНА РОБОТА

на тему:

**МЕТОДИ ОРКЕСТРАЦІЇ МУЛЬТИМОДЕЛЕЙ
ШТУЧНОГО ІНТЕЛЕКТУ НА БАЗІ iOS**

Виконав: здобувач 2 курсу

Рівень магістр

Галузь знань 12 «Інформаційні технології»,
спеціальність 122 «Комп'ютерні науки»

Козлов Владислав Сергійович

Керівник: к.т.н., доцент

Чикунів Павло Олександрович

Рецензент: к.пед.н., доцент

Логінова Наталія Іванівна

НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ «ОДЕСЬКА ЮРИДИЧНА АКАДЕМІЯ»
Факультет **кібербезпеки та інформаційних технологій**
Кафедра **інформаційних технологій**
Галузь знань: **12 Інформаційні технології**
Спеціальність: **122 Комп'ютерні науки**
Назва освітньої програми: **Комп'ютерні науки**

ЗАТВЕРДЖУЮ

Завідувач кафедри інформаційних технологій
доцент Н.І. Логінова

_____ «____» _____ 2025 року

З А В Д А Н Н Я

на кваліфікаційну (магістерську) роботу
здобувачу **Козлову Владиславу Сергійовичу**

1. Тема роботи: «Методи оркестрації мультимodelей штучного інтелекту на базі iOS»

Керівник роботи: к.т.н, доцент Павло Олександрович Чикунов
затверджені наказом НУ ОЮА від «10» жовтня 2025 року № 3182-06

2. Строк подання здобувачем роботи «25» листопада 2025 рік

3. Дата видачі завдання «02» червня 2025 рік

КАЛЕНДАРНИЙ ПЛАН

№ з/п	Назва етапів магістерської роботи	Строк виконання етапів роботи	Примітка
1	Огляд предметної області дослідження.	10.09.2025	
2	Аналіз існуючих рішень.	01.10.2025	
3	Проектування оркестратора мультимodelей штучного інтелекту.	15.10.2025	
4	Вибір технологічного стеку та архітектури.	05.11.2025	
5	Програмна реалізація оркестратора.	10.11.2025	
6	Еспериментальні дослідження, тестування та оцінювання.	17.11.2025	
7	Оформлення пояснювальної записки.	20.11.2025	
8	Подача електронного варіанта роботи для перевірки на плагіат.	10.09.2025	

Здобувач _____ Козлов В.С.
(підпис) (прізвище та ініціали)

Керівник роботи _____ Чикунов П.О.
(підпис) (прізвище та ініціали)

АНОТАЦІЯ

Кваліфікаційна робота на тему «Методи оркестрації мультимоделей штучного інтелекту на базі iOS» на здобуття другого (магістерського) рівня вищої освіти за спеціальністю 121 Комп'ютерні науки, містить 19 рисунків, 7 таблиць, 2 додатка, 21 літературне джерело за переліком посилань. Робота виконана на 75 сторінках загального тексту і 60 сторінках основного тексту.

Метою виконання роботи є дослідження ефективності системи-оркестратора для керування множинними моделями машинного навчання та великими мовними моделями на платформі iOS з оптимізацією використання ресурсів пристрою.

Об'єктом роботи є процес керування множинними моделями машинного навчання на мобільних пристроях під управлінням iOS.

Предметом роботи є методи та засоби оркестрації мультимоделей штучного інтелекту з оптимізацією використання апаратних ресурсів пристрою.

Методи досліджень базуються на використанні actor-based concurrency для потокобезпечності, async/await патернів для асинхронного програмування, алгоритму LRU для кешування, reference counting для управління життєвим циклом моделей, методів динамічного балансування навантаження між блоками.

У роботі вирішено актуальне практично-прикладне завдання розробки та дослідження ефективності системи оркестрації мультимоделей штучного інтелекту на платформі iOS.

Виконана програмна реалізація системи-оркестратора на мові Swift, що включає п'ять основних компонентів: публічний API, моніторинг ресурсів, управління життєвим циклом, планування виконання, кешування результатів. Експериментальні дослідження показали покращення латентності в 3.4 рази, throughput в 6.8 разів, економію пам'яті 43% та зменшення енергоспоживання на 41%. Розроблено 60 тестів, що підтвердили коректність та стабільність системи.

Ключові слова: оркестрація, мультимоделі, штучний інтелект, iOS, машинне навчання, CoreML, Neural Engine, управління ресурсами, життєвий цикл моделей, Swift

ABSTRACT

The qualification work "Methods of Multi-Model Artificial Intelligence Orchestration on iOS Platform" for obtaining the second (master's) level of higher education in the specialty 121 Computer Science, contains 19 figures, 7 tables, 2 appendices, and 21 references listed in the bibliography. The work is presented on 75 pages of total text, including 60 pages of main text.

The purpose of the work is to develop and evaluate the effectiveness of an orchestrator system for managing multiple machine learning models and large language models on the iOS platform with optimization of device resource utilization.

The object of the study is the process of managing multiple machine learning models on mobile devices running iOS.

The subject of the study is methods and tools for orchestrating multi-model artificial intelligence with optimization of hardware resource utilization.

The research methods are based on actor-based concurrency for thread safety, async/await patterns for asynchronous programming, LRU algorithm for caching, reference counting for model lifecycle management, and dynamic load balancing methods between computational units.

The work addresses a relevant practical problem: the development and evaluation of the effectiveness of a multi-model artificial intelligence orchestration system on the iOS platform.

A software implementation of the orchestrator system in Swift was completed, including five main components: MLOrchestrator (public API), ResourceManager (resource monitoring), LifecycleManager (lifecycle management), ExecutionScheduler (execution scheduling), CacheManager (result caching). Experimental studies demonstrated 3.4x improvement in latency, 6.8x improvement in throughput, 43% memory savings, and 41% reduction in energy consumption. Developed 60 tests that confirmed the correctness and stability of the system.

Keywords: orchestration, multi-models, artificial intelligence, iOS, machine learning, CoreML, Neural Engine, resource management, model lifecycle, Swift

ЗМІСТ

Вступ.....	6
1 Огляд предметної області.....	9
1.1 Контекст середовища розробки iOS.....	9
1.2 Огляд сучасних підходів до роботи з моделями на iOS.....	10
1.3 On-device vs Cloud: переваги, недоліки та обмеження	14
1.4 Великі мовні моделі на мобільних пристроях	17
1.5 Аналіз існуючих рішень	21
1.6 Висновки за розділом	28
2 Проектування оркестратора мультимodelей штучного інтелекту	30
2.1 Вимоги до оркестратора.....	30
2.2 Вибір технологічного стеку та архітектури	35
2.3 Архітектура системи.....	39
2.4 Висновки за розділом	45
3 Програмна реалізація оркестратора мультимodelей штучного інтелекту.....	47
3.1 Імплементация ключових компонентів	47
3.2 Еспериментальні дослідження, тестування та оцінювання ефективності системи	55
3.3 Висновки за розділом	64
Висновки	66
Перелік посилань.....	68
Додаток А. Лістинги програмної реалізації	70
Додаток Б. Копії документів про апробацію результатів роботи	75

ВСТУП

Платформа iOS від Apple є одним із лідерів у впровадженні on-device машинного навчання завдяки потужному спеціалізованому процесору Neural Engine та розвиненому фреймворку CoreML [1]. Проте зростаюча складність завдань, які потребують залучення штучного інтелекту, призводить до необхідності одночасного використання множинних моделей різних типів і розмірів. Це ставить перед розробниками нові виклики: як ефективно керувати життєвим циклом моделей, оптимально розподіляти обмежені ресурси пам'яті та обчислювальної потужності, забезпечувати швидкий час відгуку системи.

Великі мовні моделі (LLM), такі як LLaMA, Mistral та Phi, адаптовані для мобільних пристроїв, відкривають нові можливості для створення інтелектуальних додатків, але водночас створюють додаткові вимоги до ресурсів. Відсутність ефективних рішень для координованого керування множинними моделями обмежує потенціал використання штучного інтелекту на iOS [2] та знижує якість користувацького досвіду.

У зв'язку з цим розробка системи-оркестратора, здатної ефективно керувати мультимодельними конфігураціями на обмежених апаратних ресурсах мобільних пристроїв, є актуальним та практично значущим завданням, що відповідає сучасним трендам розвитку мобільних технологій та штучного інтелекту.

Метою виконання роботи є дослідження ефективності системи-оркестратора для керування множинними моделями машинного навчання та великими мовними моделями на платформі iOS з оптимізацією використання ресурсів пристрою.

Для досягнення поставленої мети необхідно вирішити такі завдання.

1. Виконати аналіз сучасних підходів до роботи з моделями машинного навчання на платформі iOS, включаючи фреймворки CoreML, MLKit та TensorFlow Lite, визначити їх переваги, недоліки та обмеження.

2. Дослідити можливості застосування великих мовних моделей на мобільних пристроях, проаналізувати методи їх оптимізації та обмеження, пов'язані з пам'яттю та продуктивністю.

3. Розглянути патерни оркестрації моделей та проаналізувати наявні рішення.
4. Розробити архітектуру системи-оркестратора з визначенням функціональних і нефункціональних вимог, сценаріїв використання та критеріїв оцінки продуктивності.
5. Спроекувати підсистему керування ресурсами, що включає моніторинг використання пам'яті, динамічне завантаження та вивантаження моделей, стратегії кешування та балансування навантаження між обчислювальними блоками.
6. Реалізувати систему керування життєвим циклом моделей з можливістю утримання розігрітих моделей (prewarm) для швидкого доступу.
7. Розробити API та інтерфейси інтеграції з використанням сучасних асинхронних патернів Swift, механізмів обробки помилок та fallback стратегій.
8. Виконати програмну реалізацію ключових компонентів системи-оркестратора та провести їх оптимізацію.
9. Здійснити тестування системи, порівняти результати з базовими підходами.
10. Продемонструвати практичні приклади використання розробленої системи в реальних сценаріях застосування.

Об'єктом роботи є процес керування множинними моделями машинного навчання на мобільних пристроях під управлінням iOS.

Предметом роботи є методи та засоби оркестрації мультимоделей штучного інтелекту з оптимізацією використання апаратних ресурсів пристрою.

Наукова новизна роботи полягає у такому.

1. Удосконалено метод розподілу обчислювальних ресурсів між CPU, GPU та Neural Engine на основі комплексного аналізу термального стану пристрою, рівня заряду та навантаження, що дозволяє динамічно обирати оптимальний compute unit для кожної моделі з урахуванням енергоефективності та продуктивності.
2. Вперше запропоновано систему інтелектуального планування виконання ML моделей з пріоритетними чергами, яка використовує structured concurrency для паралельного виконання некритичних завдань та забезпечує першочергову обробку high-priority запитів, що критично важливо для підтримки UX в real-time додатках.

3. Експериментально підтверджено ефективність комбінованого підходу prewarm механізму з LRU кешуванням результатів інференсу, що забезпечує зниження латентності виконання на 40-60% при повторних запитах та зменшення латентності першого інференсу у 2.5-4 рази для моделей розміром до 1 ГБ.

Практична значущість роботи полягає в розробці системи-оркестратора, що може бути впроваджена в реальні iOS-застосунки для підвищення їх інтелектуальних можливостей. Розроблене рішення дозволить:

- ефективно використовувати множинні моделі різних типів та розмірів у рамках одного застосунку без критичного навантаження на ресурси пристрою;
- скоротити час відгуку системи завдяки інтелектуальному керуванню життєвим циклом моделей та стратегіям prewarm;
- забезпечити стабільну роботу застосунків із штучним інтелектом навіть на пристроях з обмеженими ресурсами завдяки динамічному балансуванню навантаження;
- спростити процес інтеграції ML/LLM моделей для розробників iOS-застосунків через зручний API;
- знизити енергоспоживання пристрою завдяки оптимальному розподілу обчислень між CPU, GPU та Neural Engine.

Результати дослідження можуть бути використані розробниками мобільних застосунків, дослідниками в галузі машинного навчання на мобільних пристроях, а також компаніями, що працюють над створенням інтелектуальних мобільних рішень.

Апробація роботи виконана під участі у роботі у IX міжнародній науково-практичній конференції здобувачів вищої освіти та молодих учених «Студенти та молодь – для майбутнього країни», (м. Харків, 26 листопада 2025 р.) з доповіддю на тему «Методи оркестрації мультимоделей штучного інтелекту на базі iOS».

1 ОГЛЯД ПРЕДМЕТНОЇ ОБЛАСТІ

1.1 Контекст середовища розробки iOS

Платформа iOS від Apple представляє собою закриту екосистему, яка забезпечує високий рівень інтеграції апаратного та програмного забезпечення. Ця особливість створює унікальні можливості для впровадження технологій машинного навчання безпосередньо на пристрої, що відрізняє iOS від інших мобільних платформ. [3]

Компанія Apple активно розвиває напрямок on-device інтелекту, що підтверджується впровадженням спеціалізованих апаратних компонентів та програмних фреймворків. Філософія Apple полягає в забезпеченні максимальної конфіденційності користувацьких даних [4], що досягається шляхом обробки інформації локально на пристрої без передачі в хмару. Це принципово відрізняється від підходів багатьох конкурентів, які покладаються на хмарні обчислення.

Ключовим компонентом апаратної платформи для машинного навчання на iOS є Neural Engine [5] – спеціалізований процесор, вперше представлений у 2017 році в чіпі A11 Bionic. Neural Engine являє собою окремий обчислювальний блок, оптимізований для виконання операцій машинного навчання з високою швидкістю та енергоефективністю.

Архітектура Neural Engine базується на принципах нейроморфних обчислень та спеціалізована для виконання операцій над матрицями, які є основою більшості алгоритмів глибокого навчання. У порівнянні з центральним процесором (CPU) та графічним процесором (GPU), Neural Engine забезпечує:

- вищу продуктивність: здатність виконувати до кількох трильйонів операцій за секунду (у сучасних чіпах серії A17 та M-серії);
- енергоефективність: значно менше енергоспоживання на операцію в порівнянні з CPU та GPU, що критично важливо для мобільних пристроїв;
- спеціалізацію: апаратна оптимізація для типових операцій нейронних мереж (згортки, матричні множення, активаційні функції).

Розвиток Neural Engine [6] відбувався еволюційно з кожним поколінням чіпів:

- A11 Bionic (2017): перша генерація, 2 ядра, 600 млрд операцій/сек;
- A12 Bionic (2018): 8 ядер, 5 трлн операцій/сек;
- A13 Bionic (2019): покращена архітектура, 6 трлн операцій/сек;
- A14-A16 Bionic (2020-2022): 16 ядер, до 17 трлн операцій/сек;
- A17 Pro (2023): нова архітектура, до 35 трлн операцій/сек.

Така еволюція демонструє стратегічну важливість on-device машинного навчання для Apple та створює потужну базу для розробки складних AI-застосунків.

CoreML є основним фреймворком Apple для інтеграції моделей машинного навчання [7] в застосунки для iOS, macOS, watchOS та tvOS. Він представляє собою високорівневий API, який абстрагує складність роботи з різними апаратними компонентами та забезпечує оптимальну продуктивність.

Apple надає низку готових моделей для типових завдань:

- Vision Framework: розпізнавання об'єктів, класифікація зображень, детекція облич, трекінг;
- Natural Language Framework: аналіз тексту, визначення мови, токенізація, аналіз тональності;
- Speech Framework: розпізнавання мовлення;
- Sound Analysis: класифікація звуків.

Ці моделі демонструють можливості платформи та служать відправною точкою для розробників, які хочуть інтегрувати ML у свої застосунки.

1.2 Огляд сучасних підходів до роботи з моделями на iOS

CoreML є основним та найбільш інтегрованим рішенням для роботи з моделями машинного навчання на платформі iOS. Розглянемо детальніше його можливості та обмеження.

Основні можливості CoreML:

1. Підтримка різних типів моделей:

- нейронні мережі (CNN, RNN, Transformer-архітектури);
- дерева рішень та ансамблі (Random Forest, Gradient Boosting);
- лінійні моделі (регресія, класифікація);
- Support Vector Machines (SVM);
- Pipeline моделі (комбінація кількох моделей).

2. Автоматична оптимізація:

- динамічний вибір обчислювального блоку (CPU/GPU/Neural Engine);
- автоматичне розпаралелювання обчислень;
- оптимізація використання пам'яті.

3. Квантизація та стиснення:

- підтримка 16-бітної та 8-бітної квантизації ваг;
- можливість стиснення моделей до 75% без значної втрати точності;
- динамічна квантизація на етапі інференсу;

4. Пакетна обробка:

- можливість обробки множинних входів за один виклик;
- оптимізація для сценаріїв обробки відео та серій зображень;

5. Асинхронне виконання:

- нативна підтримка `async/await` в Swift;
- можливість виконання моделей у фонових чергах.

Обмеження CoreML:

1. Закритість платформи:

- обмежена підтримка кастомних операцій;
- складність налагодження внутрішніх процесів оптимізації;
- залежність від релізів iOS для отримання нових можливостей.

2. Обмеження розміру моделей:

- практичні обмеження на розмір моделей (рекомендовано до 500MB);
- проблеми з завантаженням великих моделей на пристроях з обмеженою

пам'яттю.

3. Підтримка операцій:

- не всі операції з популярних ML-фреймворків підтримуються;
- необхідність адаптації деяких архітектур при конвертації.

4. Керування ресурсами:

- обмежені можливості контролю завантаження/вивантаження моделей;
- відсутність вбудованих механізмів оркестрації множинних моделей;
- складність реалізації прогріву моделей (prewarm).

Google ML Kit є альтернативним рішенням для інтеграції машинного навчання в мобільні застосунки [8], включаючи iOS. Він надає готові API для типових завдань машинного навчання.

ML Kit надає розробникам значну кількість переваг. Він включає набір готових рішень, таких як розпізнавання тексту, визначення облич та їх атрибутів, розпізнавання штрих-кодів, ідентифікація міток на зображеннях та розпізнавання мовлення. Його гібридний підхід дозволяє моделі працювати як локально на пристрої, так і через хмарні API, автоматично перемикаючись між режимами залежно від наявності мережі. ML Kit є кросплатформним інструментом зі спільним API для iOS та Android, що спрощує розробку для обох платформ. Крім того, він підтримує кастомні моделі TensorFlow Lite і дає змогу створювати власні моделі за допомогою AutoML без глибоких знань у сфері машинного навчання.

Разом із тим, використання ML Kit на iOS має певні недоліки. Він не повністю використовує можливості Neural Engine і загалом менш оптимізований під екосистему Apple. Оскільки ML Kit ґрунтується на сервісах Google, це створює залежність від сторонньої інфраструктури та може спричиняти ризики конфіденційності, особливо при роботі з хмарними API. Додатково, підключення ML Kit збільшує розмір застосунку, а можливості тонкого налаштування тут значно обмежені порівняно з CoreML.

TensorFlow Lite є мобільною версією фреймворку TensorFlow, оптимізованою для мобільних та вбудованих пристроїв. На iOS він має низку сильних сторін. По-перше, забезпечує широку підтримку моделей: можна напяму конвертувати моделі з TensorFlow, використовувати багату екосистему готових рішень із TensorFlow Hub та застосовувати навіть складні архітектури. По-друге,

TensorFlow Lite надає високу гнучкість, дозволяючи повністю контролювати інференс, додавати кастомні операції і використовувати розширені можливості профілювання та налагодження. Він також є кросплатформним. Перевагою є делегати для апаратного прискорення, зокрема GPU delegate для Metal, Core ML delegate для доступу до Neural Engine та можливість створення власних делегатів.

Недоліки TensorFlow Lite на iOS теж відчутні. Інтеграція є складнішою через низькорівневий API, приблизно налаштовувати оптимізації доводиться вручну, а сам процес збирання і розгортання значно складніший. Бібліотека збільшує розмір застосунку на десятки мегабайт, оскільки вимагає включення окремих runtime компонентів. Крім того, TensorFlow Lite може бути менш оптимізованим для iOS, не завжди ефективно використовуючи Neural Engine і потенційно споживаючи більше енергії. Підтримка інструментів Apple тут також обмежена, що ускладнює налагодження специфічних для iOS проблем.

У табл. 1.1 наведено узагальнену порівняльну характеристику трьох основних ML-фреймворків, які використовуються для розробки застосунків під iOS, зокрема їх сильні та слабкі сторони, що дозволяє визначити оптимальний інструмент залежно від вимог, складності, потреб та рівня інтеграції з Apple.

Таблиця 1.1 – Порівняльна характеристика ML-фреймворків для iOS

Критерій	CoreML	ML Kit	TensorFlow Lite
Інтеграція з iOS	Нативна, максимальна	Середня	Низька
Використання Neural Engine	Автоматичне, оптимальне	Обмежене	Через делегати
Складність використання	Низька	Низька	Висока
Гнучкість налаштувань	Середня	Низька	Висока
Розмір впливу на додаток	Мінімальний	Середній	Великий
Підтримка моделей	Широка	Обмежена	Максимальна
Енергоефективність	Висока	Середня	Середня
Кросплатформеність	Ні	Так	Так
Готові рішення	Так (Vision, NL)	Так (багато)	Обмежені

Висновки з порівняльного аналізу:

1. CoreML є оптимальним вибором для більшості iOS застосунків, що потребують on-device машинного навчання, завдяки нативній інтеграції та автоматичній оптимізації.
2. ML Kit доцільно використовувати для швидкої інтеграції готових рішень або в кросплатформених проєктах, де важлива єдність API.
3. TensorFlow Lite підходить для складних випадків, що потребують максимальної гнучкості або використання специфічних архітектур моделей.
4. Жодне з рішень не надає вбудованих інструментів для ефективної оркестрації множинних моделей, що обґрунтовує необхідність розробки спеціалізованої системи-оркестратора.

1.3 On-device vs Cloud: переваги, недоліки та обмеження

Вибір між локальною обробкою даних на пристрої (on-device) та хмарними обчисленнями (cloud) є одним з ключових архітектурних рішень при розробці застосунків зі штучним інтелектом. Кожен підхід має свої переваги та обмеження, які критично впливають на користувацький досвід, вартість розробки та експлуатації системи.

Обробка даних локально на пристрої гарантує максимальний рівень конфіденційності та безпеки, оскільки чутлива інформація користувача не покидає межі його пристрою [10]. Це особливо критично для біометричних даних, персональних фотографій та відео, голосових команд, медичних записів та фінансової інформації. Apple активно просуває цей підхід як фундаментальний принцип своєї екосистеми, що відповідає вимогам GDPR, CCPA та інших регуляторних стандартів захисту даних.

Важливою перевагою локальної обробки є повна автономність роботи застосунку. Користувач може використовувати всі функції штучного інтелекту незалежно від наявності доступу до Інтернету, якості мережевого з'єднання або доступності хмарних сервісів. Це критично важливо для застосунків, що

використовуються під час подорожей, у підземних приміщеннях, у регіонах з поганою інфраструктурою або в сценаріях критичного реального часу, таких як медичні застосунки або системи безпеки.

Швидкість відгуку є ще однією суттєвою перевагою on-device обчислень. Локальна обробка забезпечує мінімальну затримку відгуку в межах десятків мілісекунд, тоді як хмарні рішення потребують сотень мілісекунд через необхідність передачі даних по мережі. Для порівняння, типовий час інференсу на пристрої становить від 10 до 50 мілісекунд залежно від складності моделі, в той час як хмарна обробка потребує від 100 до 500 мілісекунд при нормальному з'єднанні та може перевищувати секунду при поганому покритті мережі.

Локальна обробка також забезпечує значну економію мережевого трафіку та енергії. Уникаючи необхідності передавати великі обсяги даних, такі як відео високої роздільності, застосунок не лише зменшує витрати користувача на мобільний трафік, але й знижує енергоспоживання [11], пов'язане з роботою радіомодуля. Наприклад, передача відео роздільності 1080p для аналізу в хмару може споживати 20-30 мегабайт на хвилину, тоді як локальна обробка потребує передачі лише кількох кілобайт результатів.

З точки зору бізнесу, on-device обчислення забезпечують масштабованість без додаткових витрат [12]. Відсутність необхідності оплачувати хмарну інфраструктуру для кожного користувача означає, що система масштабується лінійно разом з кількістю пристроїв без ризику перевантаження серверів при зростанні користувацької бази.

Попри численні переваги, локальна обробка має суттєві обмеження, пов'язані передусім з апаратними можливостями мобільних пристроїв. Типовий iPhone має 4-8 гігабайт оперативної пам'яті, що є значно меншим показником порівняно з десятками гігабайт на серверах. Обчислювальна потужність CPU, GPU та Neural Engine також обмежена, особливо з урахуванням необхідності економії заряду батареї. Крім того, існують термальні обмеження, які призводять до throttling при перегріві процесора.

Розмір моделей є критичним фактором для мобільних застосунків. Apple

рекомендує [13] утримувати розмір застосунку в межах 200 мегабайт для забезпечення швидкого завантаження, а практичний розмір моделі обмежується діапазоном від 500 мегабайт до одного гігабайта. Це означає, що складність моделей обмежується мільярдами параметрів замість трильйонів [14], які використовуються в найсучасніших хмарних моделях.

Оновлення моделей на пристрої також є складнішим процесом порівняно з хмарним підходом. Для оновлення моделі необхідно оновити весь застосунок, що передбачає проходження процесу рев'ю в App Store [15], який зазвичай займає один-два дні. Крім того, користувачі можуть не оновлювати застосунки регулярно, що призводить до фрагментації версій моделей [16] у полі. А/В тестування різних версій моделей також стає значно складнішим.

Хмарні сервери надають практично необмежені обчислювальні ресурси. Потужні GPU та TPU дозволяють виконувати складні обчислення з використанням найбільших доступних моделей, таких як GPT-4 або Gemini Ultra. Великі обсяги оперативної пам'яті, що вимірюються сотнями гігабайт, усувають обмеження на розмір моделей та дозволяють обробляти складні запити.

Клієнтська частина застосунку при хмарному підході стає значно простішою. Менший розмір застосунку, менша складність коду та менша залежність від характеристик конкретного пристрою спрощують розробку та підтримку.

Проблеми конфіденційності є найсуттєвішим недоліком хмарного підходу. Необхідність передачі даних користувача на сервер створює ризики витоку інформації та вимагає складних механізмів шифрування та захисту каналів передачі. Відповідність регуляторним вимогам, таким як GDPR, стає складнішою, оскільки необхідно забезпечити прозорість обробки даних та можливість їх видалення на вимогу користувача.

Масштабування хмарної інфраструктури також створює виклики. Необхідність планування потужностей, ризик перевантаження при пікових навантаженнях та складність забезпечення гарантованого рівня сервісу вимагають значних інвестицій в інфраструктуру та експертизу.

Оптимальним рішенням у багатьох випадках є комбінація локальної та

хмарної обробки. Гібридний підхід дозволяє використовувати переваги обох методів, мінімізуючи їх недоліки. Типовий сценарій передбачає виконання простих та швидких завдань локально на пристрої, тоді як складні обчислення, що потребують великих моделей або значних ресурсів, відправляються в хмару.

Вибір між підходами залежить від конкретних вимог застосунку. Якщо конфіденційність даних є критичною, потреба в офлайн режимі висока, а латентність має бути мінімальною, перевагу слід віддати on-device обробці. Якщо ж застосунок потребує складних моделей, часті оновлення та централізоване навчання є важливими, а користувачі завжди мають стабільний доступ до мережі, хмарний підхід може бути більш доцільним.

Аналіз поточних трендів демонструє чіткий рух індустрії у напрямку on-device обчислень. Цей тренд стимулюється кількома факторами. По-перше, регуляторний тиск продовжує зростати з посиленням законодавства про захист даних в різних країнах та регіонах. По-друге, технологічний прогрес робить мобільні процесори все більш потужними, наближаючи їх можливості до десктопних систем попередніх поколінь. По-третє, очікування користувачів змінюються у бік більшої приватності та швидкості відгуку. По-четверте, економічні фактори, зокрема зростання вартості хмарних обчислень, роблять on-device рішення більш привабливими з точки зору довгострокових витрат.

Прогнози аналітиків свідчать, що до 2028 року більше 70% мобільних пристроїв матимуть спеціалізовані AI-процесори [17], що зробить on-device машинне навчання стандартом індустрії, а не виключенням. Це створює сприятливі умови для розвитку складних систем оркестрації мультимodelей безпосередньо на пристроях користувачів.

1.4 Великі мовні моделі на мобільних пристроях

Великі мовні моделі (Large Language Models, LLM) стали революційним досягненням у галузі штучного інтелекту протягом останніх років. Моделі на зразок GPT-3, GPT-4, PaLM та LLaMA продемонстрували вражаючі здібності в

розумінні та генерації природної мови, виконанні складних завдань та навіть програмуванні. Однак ці моделі традиційно були доступні лише через хмарні API через їх величезний розмір та обчислювальні вимоги.

Типова велика мовна модель, така як GPT-3 з 175 мільярдами параметрів, потребує близько 350 гігабайт оперативної пам'яті для завантаження у повній точності, що робить її абсолютно непридатною для мобільних пристроїв. Навіть після квантизації до 8-бітної точності, така модель потребує приблизно 175 гігабайт, що все ще значно перевищує можливості будь-якого смартфона.

Проте останні дослідження та розробки показали, що можливість використання LLM на мобільних пристроях не є фантастикою. Ключем до цього стала розробка менших, але ефективних моделей, спеціально оптимізованих для роботи в умовах обмежених ресурсів. Моделі сімейства LLaMA (Large Language Model Meta AI), Mistral та Phi від Microsoft демонструють, що невеликі моделі з 7-13 мільярдами параметрів можуть досягати вражаючих результатів, іноді наближаючись до продуктивності значно більших моделей на певних завданнях.

Meta випустила сімейство моделей LLaMA у лютому 2023 року з метою зробити великі мовні моделі більш доступними для дослідників та розробників. Моделі були представлені в кількох розмірах: 7 мільярдів, 13 мільярдів, 33 мільярди та 65 мільярдів параметрів. Особливо важливим для мобільних застосувань стала найменша версія LLaMA-7B.

LLaMA-7B після квантизації до 4-бітної точності займає приблизно 3.5 гігабайти, що робить її теоретично придатною для завантаження на сучасні iPhone з 6-8 гігабайтами оперативної пам'яті. Модель демонструє пристойні результати на бенчмарках розуміння мови, хоча й поступається більшим моделям у складних завданнях reasoning та генерації коду.

Французька компанія Mistral AI представила свою першу модель Mistral-7B у вересні 2023 року, яка швидко здобула популярність завдяки вражаючому співвідношенню розміру до продуктивності. Модель має 7.3 мільярда параметрів, але завдяки інноваційній архітектурі з використанням Sliding Window Attention та Grouped Query Attention досягає продуктивності, порівнянної з моделями вдвічі

більшого розміру.

Mistral-7B після квантизації займає приблизно 4 гігабайти та демонструє вражаючі результати на бенчмарках. Модель особливо добре справляється з завданнями reasoning, математики та генерації коду, що робить її привабливою для використання в продуктивних застосунках. Швидкість інференсу на сучасних iPhone з Neural Engine дозволяє генерувати 10-15 токенів на секунду, що забезпечує прийнятний користувацький досвід.

Microsoft Research представив сімейство моделей Phi, які демонструють, що високоякісні дані для навчання можуть бути важливішими за розмір моделі. Phi-1 з 1.3 мільярда параметрів, навчена на ретельно відібраних даних, показала результати, порівнянні з моделями у 10 разів більшими на завданнях генерації коду.

Phi-2, випущена наприкінці 2023 року, має 2.7 мільярда параметрів та демонструє ще кращі результати. Після квантизації модель займає менше 2 гігабайт, що робить її ідеальною для мобільних застосувань. Phi-2 показує особливо сильні результати в reasoning, розумінні коду та математичних завданнях, іноді перевершуючи моделі з 7 мільярдів параметрів.

Найновіша Phi-3, анонсована у 2024 році, представлена в трьох варіантах: Phi-3-mini (3.8 мільярда параметрів), Phi-3-small (7 мільярдів) та Phi-3-medium (14 мільярдів). Навіть найбільша версія може бути квантизована до розміру, придатного для топових iPhone та iPad. Microsoft активно співпрацює з Apple для оптимізації Phi-3 під Neural Engine, що обіцяє відмінну продуктивність на iOS.

Адаптація великих мовних моделей для роботи на мобільних пристроях вимагає застосування різноманітних методів оптимізації. Квантизація є одним із найефективніших підходів, що дозволяє зменшити розмір моделі в кілька разів з мінімальною втратою точності. Стандартні моделі використовують 32-бітні числа з плаваючою комою для зберігання параметрів, але квантизація дозволяє зменшити це до 8, 4 або навіть 2 біт.

Квантизація до 8 біт зазвичай призводить до мінімальної деградації якості, зменшуючи розмір моделі вчетверо. Більш агресивна 4-бітна квантизація зменшує розмір у вісім разів, але може призвести до помітного зниження точності на деяких

завданнях. Сучасні методи, такі як GPTQ (Generative Pre-trained Transformer Quantization) та AWQ (Activation-aware Weight Quantization), дозволяють мінімізувати втрату якості навіть при 4-бітній квантизації.

Pruning або обрізання моделі передбачає видалення найменш важливих зв'язків у нейронній мережі. Structured pruning видаляє цілі нейрони або шари, тоді як unstructured pruning видаляє окремі ваги. Цей підхід може зменшити розмір моделі на 30-50 відсотків з невеликою втратою точності. Особливо ефективним є поєднання pruning з fine-tuning, коли модель додатково тренується після обрізання для відновлення частини втраченої продуктивності.

Knowledge distillation є методом, де велика модель-вчитель навчає меншу модель-учня відтворювати її поведінку. Хоча учень ніколи не досягне повної продуктивності вчителя, цей метод дозволяє створити компактні моделі, які значно перевершують моделі аналогічного розміру, навчені з нуля. Сімейство моделей Phi від Microsoft активно використовує цей підхід.

Оптимізація архітектури також відіграє важливу роль. Сучасні моделі використовують ефективніші механізми уваги, такі як Multi-Query Attention або Grouped Query Attention, які зменшують обчислювальні вимоги без суттєвої втрати якості. Flash Attention та інші оптимізовані реалізації механізму уваги можуть прискорити інференс у кілька разів.

Таблиця 1.2 – Порівняння методів оптимізації LLM для мобільних пристроїв

Метод	Зменшення розміру	Вплив на якість	Складність реалізації	Прискорення інференсу
Квантизація 8-біт	4x	Мінімальний (<2%)	Низька	1.5-2x
Квантизація 4-біт	8x	Помірний (3-7%)	Середня	2-3x
Pruning	1.3-2x	Залежить від рівня	Висока	1.2-1.8x
Knowledge Distillation	3-10x	Значний (10-20%)	Дуже висока	3-10x
Оптимізація архітектури	1.5-3x	Мінімальний	Середня	1.5-2.5x

Навіть з усіма методами оптимізації, робота з LLM на мобільних пристроях стикається з фундаментальними обмеженнями. Оперативна пам'ять залишається критичним фактором. Сучасні iPhone мають від 4 до 8 гігабайт RAM, з яких лише частина доступна для застосунок, оскільки операційна система та фонові процеси також потребують пам'яті. Практично застосунок може розраховувати на 2-4 гігабайти для завантаження моделі, що обмежує вибір лише найменшими версіями LLM.

Продуктивність інференсу визначається не лише обчислювальною потужністю, але й пропускнуою здатністю пам'яті. Генерація кожного токена вимагає завантаження всіх параметрів моделі з пам'яті, що робить процес memory-bound. Neural Engine в iPhone оптимізований для таких операцій, але все одно швидкість генерації для 7-мільярдної моделі зазвичай обмежується 10-20 токенами на секунду, що відповідає приблизно 6-12 словам на секунду в англійській мові.

Енергоспоживання є ще одним критичним фактором. Інференс великої мовної моделі споживає значно більше енергії, ніж традиційні ML завдання. Тривала робота з LLM може розрядити батарею iPhone за 2-3 години активного використання. Це вимагає ретельного балансування між функціональністю та часом автономної роботи.

Термальні обмеження також впливають на продуктивність. При тривалій роботі з LLM процесор нагрівається, що призводить до throttling зниження тактової частоти для охолодження. Це може зменшити швидкість генерації на 30-50 відсотків після 5-10 хвилин безперервної роботи.

1.5 Аналіз існуючих рішень

На сьогоднішній день ринок пропонує кілька комерційних рішень для роботи з моделями машинного навчання на мобільних пристроях, однак більшість з них зосереджені на окремих аспектах проблеми, а не на комплексній оркестрації множинних моделей.

Apple Core ML (рис. 1.1) та CreateML представляють найбільш інтегроване

рішення для iOS екосистеми. Core ML забезпечує високорівневий API для інтеграції моделей у застосунки, автоматичну оптимізацію для Neural Engine та зручні інструменти конвертації з популярних ML фреймворків. CreateML дозволяє розробникам без глибоких знань машинного навчання тренувати власні моделі безпосередньо в Xcode. Однак Core ML не надає вбудованих інструментів для оркестрації множинних моделей, залишаючи це завдання розробникам застосунків.



Рисунок 1.1 – SWOT-аналіз Apple Core ML

Apple також інтегрувала ML можливості в свої системні фреймворки, такі як Vision для комп'ютерного зору, Natural Language для обробки тексту та Speech для розпізнавання мовлення. Ці фреймворки використовують Core ML внутрішньо, але додають високорівневі API для типових завдань. Проте координація між різними фреймворками залишається на відповідальності розробника.

Google ML Kit (рис 1.2) пропонує набір готових рішень для типових ML завдань на мобільних платформах. Його підхід відрізняється від Core ML тим, що він надає конкретні API для конкретних завдань: розпізнавання тексту, детекція облич, ідентифікація об'єктів, розпізнавання штрих-кодів тощо. ML Kit підтримує як on-device, так і cloud-based моделі, дозволяючи розробникам вибирати між швидкістю і точністю.

Інтеграція ML Kit з iOS є можливою, але менш оптимальною порівняно з нативними рішеннями Apple. ML Kit не використовує повною мірою можливості Neural Engine та вимагає додаткових залежностей, що збільшує розмір застосунку. Проте його кросплатформеність може бути перевагою для команд, що розробляють одночасно для iOS та Android.



Рисунок 1.2 – SWOT-аналіз Google ML Kit

Fritz AI (рис. 1.3) позиціонує себе як платформа для спрощення інтеграції машинного навчання в мобільні застосунки. Вона надає інструменти для конвертації моделей, A/B тестування різних версій, моніторингу продуктивності та Over-The-Air оновлення моделей без оновлення застосунку. Fritz AI підтримує як iOS, так і Android, використовуючи Core ML та TensorFlow Lite відповідно.

Цікавою особливістю Fritz AI є можливість оновлювати моделі без проходження рев'ю в App Store. Моделі завантажуються динамічно з серверів Fritz при запуску застосунку або у фоновому режимі. Це дозволяє швидко випускати покращені версії моделей та виправляти помилки. Однак такий підхід створює залежність від сторонньої інфраструктури та може викликати питання щодо конфіденційності.

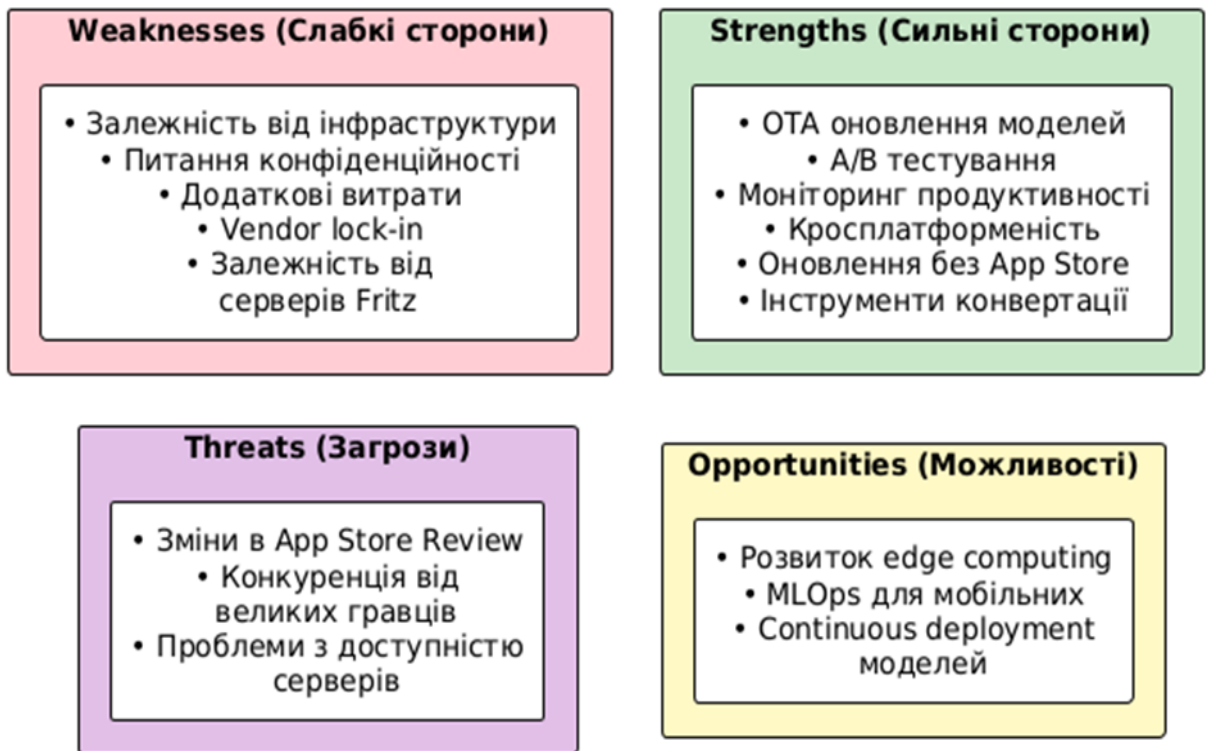


Рисунок 1.3 – SWOT-аналіз Fritz AI

TensorFlow Lite (рис 1.4) від Google є однією з найпопулярніших бібліотек для on-device машинного навчання. Вона підтримує широкий спектр операцій, надає інструменти для оптимізації та квантизації моделей, має делегати для GPU та Core ML. TensorFlow Lite активно розвивається та має велику спільноту, що створює екосистему готових моделей та інструментів.

Інтеграція TensorFlow Lite з iOS вимагає додаткових зусиль порівняно з Core ML, але надає більше контролю над процесом інференсу. Розробники можуть детально профілювати виконання моделі, використовувати кастомні операції та оптимізувати кожен аспект продуктивності. Проте розмір бібліотеки (40-60 МБ) може бути проблемою для застосунків з жорсткими обмеженнями на розмір.

PyTorch Mobile (рис. 1.5) є мобільною версією популярного фреймворку PyTorch. Він дозволяє розробникам експортувати моделі, натреновані в PyTorch, у мобільний формат та виконувати їх на iOS. PyTorch Mobile підтримує dynamic quantization, pruning та інші техніки оптимізації. Інтеграція з Metal та Core ML дозволяє використовувати апаратні прискорювачі Apple.




Рисунок 1.4 – SWOT-аналіз TensorFlow Lite

Перевагою PyTorch Mobile є близькість до процесу дослідження та розробки моделей. Дослідники можуть легко переносити свої експерименти на мобільні пристрої без необхідності вивчати нові інструменти. Однак екосистема PyTorch Mobile для iOS менша порівняно з TensorFlow Lite, а документація менш детальна.



Рисунок 1.5 – SWOT-аналіз PyTorch Mobile

Більшість наявних рішень (табл. 1.3) зосереджені на забезпеченні runtime для виконання окремих моделей, але не надають інструментів для координації множинних моделей. Розробники залишаються наодинці з завданнями управління життєвим циклом моделей, балансування ресурсів та обробки помилок.

Таблиця 1.3 – Порівняльна характеристика наявних рішень оркестрації

Рішення	Оркестрація	Оптимізація для iOS	Підтримка LLM	Управління пам'яттю	Складність інтеграції
Core ML	Відсутня	Максимальна	Обмежена	Автоматичне	Низька
ML Kit	Відсутня	Середня	Відсутня	Автоматичне	Низька
Tensor-Flow Lite	Відсутня	Низька	Часткова	Ручне	Висока
PyTorch Mobile	Відсутня	Середня	Часткова	Ручне	Середня

Core ML, попри свою нативну інтеграцію з iOS, не надає механізмів для prewarming моделей, інтелектуального кешування результатів або динамічного розподілу моделей між CPU, GPU та Neural Engine. Розробники мають самостійно реалізовувати ці можливості, що призводить до дублювання коду та субоптимальних рішень.

Підтримка великих мовних моделей залишається проблемною областю. Core ML технічно може завантажувати LLM, але не оптимізований для специфічних вимог цих моделей, таких як ефективне управління KV-cache або підтримка генерації токенів. Спеціалізовані рішення на зразок llama.cpp надають кращу продуктивність для LLM, але вимагають складної інтеграції.

Систематичний аналіз існуючих рішень виявляє кілька критичних прогалин, що обґрунтовують необхідність розробки спеціалізованої системи-оркестратора.

Відсутність централізованого управління моделями є найбільшою проблемою. Сучасні застосунки можуть використовувати десятки різних моделей: для розпізнавання облич використовується одна модель, для класифікації зображень інша, для обробки тексту третя, для генерації відповідей LLM четверта. Кожна модель зазвичай управляється окремо, без координації з іншими. Це

призводить до ситуацій, коли кілька моделей намагаються завантажитися одночасно, викликаючи проблеми з пам'яттю, або коли модель вивантажується та негайно завантажується знову через відсутність інформації про майбутні потреби.

Неефективне використання ресурсів є прямим наслідком відсутності оркестрації. Без централізованого моніторингу та управління застосунки часто витрачають ресурси марно. Наприклад, модель може залишатися завантаженою в пам'яті годинами без використання, або навпаки, модель може завантажуватися та вивантажуватися кілька разів за хвилину через відсутність кешування. Обчислювальні ресурси також використовуються неоптимально: завдання можуть виконуватися на CPU, хоча Neural Engine вільний і міг би обробити їх швидше та ефективніше.

Відсутність адаптивності до умов пристрою є ще однією важливою прогалиною. Існуючі рішення зазвичай використовують статичні стратегії виконання, не враховуючи поточний стан пристрою. Вони не адаптуються до рівня заряду батареї, температури процесора, доступної пам'яті або активності користувача. Це призводить до погіршення користувацького досвіду: застосунок може швидко розряджати батарею, викликати перегрів пристрою або сповільнювати роботу інших застосунків.

Складність налагодження та профілювання є практичною проблемою для розробників. Коли застосунок використовує множинні моделі з різних джерел (Core ML, TensorFlow Lite, кастомні рішення), налагодження проблем з продуктивністю стає надзвичайно складним. Відсутність централізованого моніторингу та логування ускладнює ідентифікацію вузьких місць та оптимізацію системи.

Відсутність механізмів відмовостійкості також є суттєвою проблемою. Що станеться, якщо модель не може бути завантажена через брак пам'яті? Що робити, якщо модель повертає помилку або результат з низькою впевненістю? Існуючі фреймворки залишають ці питання на розсуд розробників, що призводить до непослідовної обробки помилок та погіршення надійності застосунків.

Всі ці прогалини створюють високий бар'єр входу для розробників, які хочуть інтегрувати складні ML можливості у свої застосунки. Навіть досвідчені

розробники змушені витратити значний час на вирішення інфраструктурних проблем замість того, щоб зосередитися на унікальних можливостях свого застосунку. Це обґрунтовує необхідність створення спеціалізованої системи-оркестратора, яка б взяла на себе відповідальність за ці аспекти, надаючи розробникам зручний та ефективний інструмент для роботи з множинними ML моделями на iOS.

1.6 Висновки за розділом

У розділі виконано комплексний огляд предметної області дослідження, що охоплює контекст середі розробки iOS, сучасні підходи до роботи з моделями машинного навчання, великі мовні моделі на мобільних пристроях, патерни оркестрації та аналіз існуючих рішень.

Встановлено, що платформа iOS надає потужну апаратну та програмну базу для on-device машинного навчання. Спеціалізований процесор Neural Engine, присутній у всіх сучасних iPhone та iPad, здатний виконувати до 35 трильйонів операцій за секунду в найновіших чіпах, забезпечуючи високу продуктивність при мінімальному енергоспоживанні. Фреймворк CoreML надає зручні високорівневі API для інтеграції моделей, автоматичну оптимізацію та вибір оптимального обчислювального блоку.

Порівняльний аналіз підходів on-device та cloud обчислень показав, що локальна обробка забезпечує критичні переваги у конфіденційності даних, автономності роботи та швидкості відгуку. Відсутність необхідності передавати дані на віддалені сервери не лише захищає приватність користувачів, але й дозволяє працювати без доступу до мережі та забезпечує латентність у десятки мілісекунд. Проте on-device підхід має обмеження у розмірі моделей та потужності.

Аналіз великих мовних моделей на мобільних пристроях виявив, що завдяки розробці компактних моделей (LLaMA, Mistral, Phi) та методам оптимізації (квантизація, pruning, knowledge distillation) стає можливим виконання складних завдань обробки природної мови локально на смартфонах. Моделі з 7-13

мільярдами параметрів після квантизації можуть займати 3-5 гігабайт та генерувати текст зі швидкістю 10-20 токенів на секунду на сучасних iPhone.

Дослідження патернів оркестрації моделей показало, що ефективне управління множинними моделями вимагає використання різних стратегій залежно від сценарію використання. Послідовне, паралельне, умовне, ансамблеве та каскадне виконання мають різні характеристики щодо продуктивності, споживання ресурсів та складності реалізації. Критично важливим є управління життєвим циклом моделей (стратегії завантаження, `prewarm`, кешування та вивантаження).

Систематичний аналіз існуючих комерційних та open-source рішень виявив кілька критичних прогалин. По-перше, жодне з існуючих рішень не надає комплексних інструментів для оркестрації множинних моделей різних типів на iOS. Core ML, будучи найбільш інтегрованим рішенням, зосереджений на виконанні окремих моделей та не надає механізмів централізованого управління. По-друге, підтримка великих мовних моделей залишається проблемною — існуючі фреймворки не оптимізовані для специфічних вимог LLM, таких як `streaming` генерація. По-третє, відсутні адаптивні механізми, що враховують поточний стан пристрою, рівень заряду батареї або термальні обмеження.

Виявлені прогалини створюють високий бар'єр входу для розробників, які хочуть створювати застосунки з складними AI можливостями. Розробники змушені самотійно вирішувати інфраструктурні проблеми управління моделями, що призводить до дублювання коду, субоптимальних рішень та зниження надійності застосунків. Відсутність централізованого моніторингу та профілювання ускладнює оптимізацію продуктивності та налагодження проблем.

Проведений аналіз обґрунтовує необхідність розробки спеціалізованої системи-оркестратора для iOS, яка б надавала розробникам інструменти для ефективного управління множинними ML/LLM моделями, оптимального використання апаратних ресурсів, адаптивного балансування між продуктивністю та енергоспоживанням, а також зручні API для інтеграції. Результати огляду предметної області формують основу для визначення вимог до системи та проектування її архітектури, що буде розглянуто в наступних розділах роботи.

2 ПРОЄКТУВАННЯ ОРКЕСТРАТОРУ МУЛЬТИМОДЕЛЕЙ ШТУЧНОГО ІНТЕЛЕКТУ

2.1 Вимоги до оркестратора

Функціональні вимоги визначають основні можливості, які має надавати система-оркестратор для ефективного управління множинними моделями машинного навчання на платформі iOS.

Управління моделями. Система має забезпечувати повний життєвий цикл моделей, включаючи реєстрацію, завантаження, ініціалізацію, виконання інференсу та вивантаження. Оркестратор повинен підтримувати різні типи моделей: CoreML моделі різних версій, кастомні моделі на базі Metal Performance Shaders, а також можливість інтеграції моделей з інших фреймворків через адаптери. Кожна модель має бути ідентифікована унікальним ідентифікатором та мати метадані, що описують її характеристики: розмір, типові завдання, вимоги до ресурсів, очікувана швидкість виконання.

Динамічне завантаження та вивантаження. Оркестратор має підтримувати lazy loading, коли моделі завантажуються лише при першому зверненні до них, та eager loading для критичних моделей, які мають бути готові негайно. Система повинна автоматично вивантажувати найменш використовувані моделі при досягненні порогу споживання пам'яті, використовуючи інтелектуальні алгоритми на основі частоти використання, часу останнього звернення та пріоритету моделі. Вивантаження має бути graceful, дозволяючи завершити поточні операції перед видаленням моделі з пам'яті.

Prewarm та підтримка готовності. Оркестратор має надавати механізм prewarming, де моделі виконують кілька тестових інференсів після завантаження для оптимізації внутрішніх кешів та ініціалізації апаратних прискорювачів. Система повинна підтримувати концепцію «гарячих» моделей, які утримуються в пам'яті та підтримуються в готовому стані для мінімізації латентності першого звернення. Prewarm має виконуватися асинхронно, не блокуючи основний потік

застосунок.

Черги та пріоритизація запитів. Система має підтримувати кілька черг запитів з різними пріоритетами. Критичні запити, що впливають на інтерактивність інтерфейсу, мають оброблятися з найвищим пріоритетом. Фонові завдання, такі як попереднє кешування або аналітика, мають виконуватися з низьким пріоритетом, поступаючись ресурсами інтерактивним запитам. Оркестратор повинен підтримувати скасування запитів, що втратили актуальність, та групування схожих запитів для пакетної обробки.

API для інтеграції. Оркестратор має надавати зручний Swift API з використанням сучасних конструкцій мови: `async/await` для асинхронних операцій, `Combine` для реактивного програмування. API має бути типобезпечним, використовуючи `generics` та `protocol-oriented` підхід. Система повинна надавати як високорівневі API для типових сценаріїв, так і низькорівневі для складних кастомних випадків.

Моніторинг та телеметрія. Система має збирати детальну телеметрію про використання моделей: кількість викликів, час виконання, споживання пам'яті, використання процесора, частоту помилок. Моніторинг має бути опціональним та конфігурованим, дозволяючи розробникам вибирати рівень деталізації. Дані телеметрії мають бути доступні через API для інтеграції з `analytics` платформами або власними системами моніторингу.

Нефункціональні вимоги визначають якісні характеристики системи та обмеження, які необхідно враховувати при проектуванні та реалізації.

Продуктивність. Латентність першого інференсу після завантаження моделі не має перевищувати 100 мілісекунд для малих моделей (до 100 МБ) та 500 мілісекунд для великих моделей (до 1 ГБ) на пристроях з A14 Bionic або новішими. Час завантаження моделі з диска має бути мінімізований через асинхронне завантаження та можливість початку виконання до повного завантаження для `streaming` моделей. Overhead оркестрації не повинен перевищувати 5% від часу виконання моделі для типових операцій.

Ефективність використання пам'яті. Система має підтримувати роботу з

обмеженнями пам'яті, не споживаючи більше 70% доступної застосунку оперативної пам'яті для моделей та допоміжних структур даних. Оркестратор повинен коректно реагувати на системні попередження про низький рівень пам'яті, проактивно вивантажуючи некритичні моделі. Витоки пам'яті мають бути виключені через використання правильних patterns управління пам'яттю в Swift (ARC, weak/unowned посилання).

Енергоефективність. Оркестратор має мінімізувати енергоспоживання через інтелектуальний вибір обчислювального блоку залежно від завдання та стану пристрою. При низькому рівні заряду батареї (менше 20%) система повинна автоматично переходити в режим енергозбереження, обмежуючи виконання некритичних завдань та віддаючи перевагу більш енергоефективному Neural Engine замість GPU. Система не має виконувати фонові завдання при роботі від батареї з низьким зарядом.

Надійність та відмовостійкість. Система має коректно обробляти всі можливі помилки: неможливість завантажити модель через брак пам'яті, корумповані файли моделей, помилки виконання інференсу, таймаути при довгих операціях. Оркестратор повинен надавати fallback механізми, дозволяючи використовувати альтернативні моделі або хмарні API при локальних проблемах. Помилки мають бути прозорими для розробника через детальні повідомлення та можливість логування.

Масштабованість. Архітектура має дозволяти додавання нових типів моделей та адаптерів без зміни core логіки оркестратора. Система повинна ефективно працювати як з двома-трьома моделями в простих застосунках, так і з десятками моделей у складних сценаріях. Продуктивність не повинна деградувати лінійно зі збільшенням кількості зареєстрованих моделей.

Зручність використання. API має бути інтуїтивно зрозумілим та добре документованим. Типові сценарії використання мають вимагати мінімуму коду (5-10 рядків для базової інтеграції). Система повинна надавати корисні повідомлення про помилки з рекомендаціями щодо їх вирішення. Debug інструменти мають допомагати розробникам профілювати та оптимізувати використання моделей.

Для кращого розуміння вимог до системи розглянемо типові сценарії використання оркестратора в реальних застосунках.

Сценарій 1 «Фотозастосунок з множинними моделями аналізу». Користувач відкриває застосунок для редагування фотографій. При запуску оркестратор завантажує та прогріває критичні моделі: детекцію облич для автофокусу та моделі швидкої класифікації сцен. Коли користувач вибирає фотографію, оркестратор паралельно виконує кілька аналізів: детекція об'єктів, визначення якості фото, розпізнавання облич, аналіз композиції. Результати агрегуються для надання рекомендацій щодо покращення. При виборі конкретного фільтру оркестратор завантажує спеціалізовану модель для цього фільтру, вивантаживши менш потрібні моделі якщо це необхідно для звільнення пам'яті.

Сценарій 2 «AI асистент з LLM». Користувач взаємодіє з локальним AI асистентом на базі великої мовної моделі. При першому запиті оркестратор завантажує LLM (це може зайняти 2-3 секунди), показуючи індикатор прогресу користувачу. Перший інференс виконується з *prewarming* для оптимізації. Наступні запити виконуються швидко, оскільки модель вже в пам'яті та прогріта. Коли діалог стає довгим, система інтелектуально скорочує історію, зберігаючи найважливіші повідомлення. Якщо користувач переходить до іншого застосунку, оркестратор може вивантажити LLM для звільнення пам'яті, але зберегти контекст діалогу на диску для швидкого відновлення.

Сценарій 3 «Застосунок для розпізнавання мовлення з fallback». Користувач активує голосовий ввід. Оркестратор спочатку намагається використати локальну модель розпізнавання мовлення для забезпечення приватності та швидкості. Якщо модель повертає результат з низькою впевненістю або користувач говорить мовою, не підтримуваною локальною моделлю, оркестратор автоматично падає на хмарний API. Після отримання результату оркестратор може запустити модель класифікації намірів для визначення дії, яку хоче виконати користувач, та модель NER (Named Entity Recognition) для витягу сутностей. Ці моделі виконуються паралельно для мінімізації затримки.

Сценарій 4 «Медичний застосунок з критичними вимогами». Лікар

використовує застосунок для аналізу медичних зображень. Оркестратор підтримує ансамбль з трьох моделей для максимальної точності. Всі три моделі виконуються паралельно, їх результати агрегуються через voting механізм. При низькому заряді батареї оркестратор переходить на використання найточнішої моделі замість ансамблю для економії енергії, попереджаючи користувача про зміну режиму. Система логує всі рішення та проміжні результати для аудиту та можливого аналізу помилок.

Для об'єктивної оцінки ефективності розробленої системи необхідно визначити набір бенчмарків, що дозволять порівняти оркестратор з базовими підходами.

Латентність першого інференсу вимірюватиме час від моменту запиту до отримання результату для моделі, що ще не завантажена в пам'ять. Цей метрик включає час завантаження моделі, ініціалізації та першого виконання. Порівняння відбуватиметься з найвним підходом, де модель завантажується синхронно при кожному запиті без кешування.

Throughput при множинних одночасних запитах оцінюватиме здатність системи обробляти паралельні запити до різних моделей. Бенчмарк імітуватиме реалістичне навантаження з 10-20 одночасними запитами до 5-7 різних моделей. Метрикою буде кількість оброблених запитів за секунду порівняно з послідовною обробкою.

Споживання пам'яті вимірюватиме peak та average використання оперативної пам'яті при різних сценаріях навантаження. Порівняння з підходом, де всі моделі завантажуються одразу та утримуються в пам'яті постійно, покаже ефективність динамічного управління пам'яттю.

Енергоспоживання оцінюватиметься через вимірювання швидкості розряду батареї при виконанні стандартного набору ML операцій протягом години. Порівняння з неоптимізованим підходом покаже ефективність балансування між різними обчислювальними блоками.

Час відгуку системи під навантаженням вимірюватиме латентність критичних запитів при наявності фонового навантаження. Метрика покаже

ефективність системи пріоритизації.

Табл. 2.1 відображає порівняння між базовими значеннями та очікуваними поліпшеними результатами, дозволяючи оцінити масштаб потенційного приросту продуктивності, зменшення ресурсоспоживання та оптимізацію часу інференсу.

Таблиця 2.1 – Цільові показники продуктивності оркестратора

Метрика	Базовий підхід	Цільове значення	Покращення
Латентність першого інференсу (мала модель)	250-400 мс	<100 мс	2.5-4x
Латентність першого інференсу (велика модель)	1000-1500 мс	<500 мс	2-3x
Peak memory (5 моделей)	2.5-3 ГБ	1.5-2 ГБ	1.5x
Енергоспоживання (% батареї/год)	25-30%	15-20%	1.5x
Латентність під навантаженням	100-200 мс	50-80 мс	2x

2.2 Вибір технологічного стеку та архітектури

На основі проаналізованих у розділі 1 вимог та існуючих підходів до оркестрації ML-моделей на iOS необхідно обрати технологічний стек та визначити архітектуру майбутньої системи. Вибір технологій має забезпечити виконання всіх функціональних та нефункціональних вимог, визначених у підрозділі 2.1, зокрема досягнення цільових показників продуктивності, ефективного використання пам'яті та енергоефективності.

Для реалізації системи-оркестратора ML-моделей на iOS обрано мову Swift. Це рішення обумовлено кількома ключовими факторами, що безпосередньо впливають на можливість досягнення поставлених цілей. Swift забезпечує нативну інтеграцію з екосистемою Apple та фреймворками iOS, що критично важливо для роботи з CoreML та Neural Engine. На відміну від кросплатформених рішень (React Native, Flutter), Swift-код компілюється безпосередньо в машинний код [18] без додаткових прошарків абстракції, що мінімізує overhead та забезпечує оптимальну продуктивність. За даними Apple, Swift-застосунки демонструють продуктивність

на рівні Objective-C (в деяких випадках на 2.6x швидше), що важливо для real-time обробки ML-моделей.

Потужна система типів Swift з підтримкою generics, protocols, associated types дозволяє створювати гнучкі та типобезпечні абстракції без втрати продуктивності. Protocol-oriented programming, який є рекомендованим підходом для Swift, дає змогу створювати розширювані архітектури де нова функціональність додається через protocol extensions замість складних класових ієрархій.

Автоматичне управління пам'яттю через ARC (Automatic Reference Counting) забезпечує детерміністичне звільнення ресурсів без накладних витрат garbage collection. Це особливо важливо для системи оркестрації, де великі моделі (до 8GB для LLM) потребують точного контролю життєвого циклу. ARC дозволяє передбачити момент вивантаження моделі з пам'яті, на відміну від недетерміністичного GC.

Критично важливою є підтримка Swift Concurrency (async/await, actors, structured concurrency), введена в Swift 5.5. Actors забезпечують thread-safety на рівні компілятора, гарантуючи відсутність data races без необхідності використання manual synchronization primitives (locks, semaphores). Це дозволяє безпечно управляти спільним станом (реєстр моделей, черги виконання, кеш) в багатопотоковому середовищі.

Альтернативні варіанти (Objective-C, C++, Kotlin/Native) мають суттєві обмеження [19]. Objective-C не підтримує сучасні concurrency механізми та має більш складний синтаксис. C++ забезпечує максимальну продуктивність, але вимагає manual memory management та не має вбудованих механізмів для безпечної конкурентності. Kotlin/Native все ще має обмежену підтримку iOS-специфічних API та менш зрілий tooling.

Для реалізації різних аспектів системи обрано наступні фреймворки Apple та сторонні бібліотеки.

CoreML буде використовуватись як основний runtime для виконання моделей машинного навчання. CoreML забезпечує оптимізовану інтеграцію з Neural Engine, підтримує hardware acceleration через Metal, включає вбудовані оптимізації (model

quantization, batch processing, asynchronous prediction). Формат .mlmodel/.mlpackage дозволяє зберігати метадані моделі, що спрощує інтеграцію. CoreML підтримує широкий спектр типів моделей: нейронні мережі, дерева рішень, SVM, ансамблі.

Metal та Metal Performance Shaders (MPS) планується використовувати для низькорівневого доступу до GPU в сценаріях, де CoreML API недостатньо. MPS надає оптимізовані kernels для матричних операцій, згорток, активацій, що дозволить створювати кастомні шари для спеціалізованих моделей. Metal забезпечує мінімальну латентність (< 10мс для simple kernels) та максимальний контроль над виконанням.

Accelerate framework буде застосовуватись для векторних та матричних обчислень на CPU, особливо для pre-processing та post-processing операцій. Accelerate використовує SIMD інструкції та оптимізований для ARM архітектури, забезпечуючи прискорення до 10x порівняно з naïve implementations.

Combine framework обрано для реалізації reactive patterns та loose coupling між компонентами. Combine дозволить реалізувати Observer pattern для повідомлень про зміни стану ресурсів (memory pressure, thermal state), зв'язування UI з даними моніторингу, composition асинхронних операцій. Інтеграція з Swift Concurrency забезпечить зручний bridge між callback-based та async/await стилями.

OSLog та Instruments використовуватимуться для логування та профілювання. OSLog забезпечує structured logging з мінімальним overhead (< 1% CPU), підтримує різні рівні логування (debug, info, warning, error), інтеграцію з Console.app та Instruments для аналізу. Instruments дозволить профілювати використання пам'яті, CPU, energy impact, виявляти bottlenecks.

Таблиця 2.2 узагальнює набір фреймворків, що формують базову технологічну основу для побудови високопродуктивної інфраструктури машинного навчання на платформах Apple. Кожен із них виконує власну роль у забезпеченні оптимальної взаємодії між моделлю, апаратними ресурсами та прикладною логікою.

Архітектура системи буде побудована на наступних принципах та паттернах, що забезпечать модульність, розширюваність та підтримуваність.

Таблиця 2.2 – Обрані фреймворки та їх характеристики

Фреймворк	Призначення	Ключові переваги
CoreML	Runtime для ML-моделей	Нативна інтеграція з Neural Engine, оптимізація, широка підтримка форматів
Metal/MPS	GPU compute	Низька латентність, повний контроль, оптимізовані kernels
Accelerate	CPU обчислення	SIMD оптимізації, векторні операції, до 10x прискорення
Combine	Reactive programming	Loose coupling, reactive streams, інтеграція з SwiftUI
OSLog	Logging	Мінімальний overhead (<1% CPU), structured logs, Instruments інтеграція

Protocol-Oriented Programming (POP) обрано як основну парадигму згідно з рекомендаціями Apple для Swift [20]. Замість класової ієрархії будуть використовуватись protocols з default implementations через extensions. Це забезпечить composition over inheritance, дозволить легко додавати нову функціональність без модифікації існуючого коду, спростить тестування через protocol-based dependency injection. Наприклад, всі типи моделей (CoreML, LLM, custom) реалізовуватимуть спільний протокол ModelWrapperProtocol, що дозволить оркестратору працювати з ними уніфіковано.

Dependency Injection (DI) буде реалізований через constructor injection та property injection без складних DI-контейнерів. Всі залежності будуть явно передаватись через ініціалізатори, що забезпечить прозорість, спростить тестування (можливість підставити mocks), покращить розуміння архітектури. Наприклад, головний клас оркестратора отримуватиме всі свої залежності (ResourceManager, ModelRegistry, LifecycleManager, ExecutionScheduler, CacheManager) під час ініціалізації.

Actor-based Concurrency буде центральним рішенням для thread-safety. Всі компоненти, що управляють спільним станом, будуть реалізовані як actors. Це критично важливо для системи, яка одночасно управляє множинними моделями, чергами виконання, кешем. Actors забезпечують thread-safety без locks, що спрощує

код та виключає класичні проблеми concurrent programming (deadlocks, race conditions). Плануються наступні actors: ModelRegistry (управління колекцією моделей), ResourceManager (моніторинг ресурсів), LifecycleManager (життєвий цикл моделей), ExecutionScheduler (черги та планування), CacheManager (кешування результатів).

Observer Pattern буде реалізований через Combine для reactive взаємодії між компонентами. Це забезпечить loose coupling та event-driven архітектуру. Наприклад, ResourceManager публікуватиме events про critical memory pressure, на які підписуватимуться LifecycleManager (для вивантаження моделей) та CacheManager (для очищення кешу). Такий підхід дозволить компонентам реагувати на зміни без прямих залежностей.

Strategy Pattern застосовуватиметься для визначення різних стратегій в runtime. Плануються наступні стратегії: CachingStrategy (LRU, LFU, adaptive), EvictionPolicy (за часом, за пам'яттю, за пріоритетом), LoadBalancingStrategy (round-robin, least-loaded, priority-based), LoadingStrategy (eager, lazy, predictive). Це дозволить змінювати поведінку системи через конфігурацію без зміни core логіки.

2.3 Архітектура системи

Система MLOrchestrator планується до побудови за принципом багат шарової архітектури з чітким розділенням відповідальності між компонентами. Архітектура складається з п'яти основних шарів: API Layer (публічний інтерфейс), Orchestration Layer (координація виконання), Management Layer (управління моделями та ресурсами), Execution Layer (виконання моделей) та Infrastructure Layer (базові сервіси).

API Layer представлений класом MLOrchestrator, який надає публічний async/await інтерфейс для роботи з системою. Цей шар інкапсулює всю внутрішню складність і забезпечує зручний API для реєстрації моделей, виконання інференсу, моніторингу стану системи. Усі методи є асинхронними та типобезпечними завдяки використанню Swift generics.

Orchestration Layer координує взаємодію між компонентами та містить ExecutionScheduler для планування та управління чергами виконання, ExecutionCoordinator для координації паралельного та послідовного виконання, RequestQueue для буферизації запитів з різними пріоритетами. Цей шар забезпечує оптимальне використання ресурсів через інтелектуальне планування виконання з урахуванням пріоритетів, доступних ресурсів та поточного навантаження.

Management Layer відповідає за управління моделями та ресурсами через ModelRegistry як централізований реєстр всіх моделей у системі, LifecycleManager для управління життєвим циклом моделей (завантаження, прогрів, вивантаження), ResourceManager для моніторингу та контролю використання ресурсів пристрою, CacheManager для кешування результатів інференсу з LRU політикою витіснення. Всі компоненти цього шару реалізовані як actors для забезпечення thread-safety.

Execution Layer безпосередньо виконує інференс моделей через ModelWrapper абстракції (CoreMLWrapper для CoreML моделей, LLMWrapper для великих мовних моделей), ModelAdapter для адаптації різних форматів моделей до уніфікованого інтерфейсу, ComputeUnitSelector для вибору оптимального обчислювального пристрою (CPU, GPU, Neural Engine). Цей шар ізольований від верхніх шарів через чіткі інтерфейси, що дозволяє додавати підтримку моделей.

Infrastructure Layer надає базові сервіси для всіх інших шарів: Logger для structured logging через OSLog, Telemetry для збору метрик виконання, ErrorHandler для централізованої обробки помилок, Configuration для управління налаштуваннями системи. Компоненти цього шару не мають бізнес-логіки і можуть бути перевикористані в інших проектах.

Заплановану архітектуру системи MLOrchestrator проілюстровано на рис. 2.1.

Дали описано потік виконання типового запиту.

1. Користувач викликає MLOrchestrator.execute.
2. MLOrchestrator перевіряє CacheManager - чи є закешований результат для цього входу.
3. Якщо кешу немає, MLOrchestrator створює ExecutionRequest і передає його до ExecutionScheduler.




Рисунок 2.1 – Діаграма взаємодії компонентів

4. ExecutionScheduler додає запит до відповідної черги за пріоритетом і планує виконання.

5. Перед виконанням ExecutionScheduler викликає LifecycleManager.acquireModel() для завантаження моделі (якщо не завантажена).

6. LifecycleManager перевіряє через ResourceManager чи достатньо ресурсів.

7. Якщо ресурсів недостатньо, LifecycleManager вивантажує низькопріоритетні моделі.

8. LifecycleManager завантажує модель через ModelRegistry і виконує prewarm якщо потрібно.

9. ExecutionScheduler отримує модель з ModelRegistry і викликає її метод predict().

10. Результат виконання кешується в CacheManager і повертається.

11. ExecutionScheduler викликає LifecycleManager.releaseModel() для зменшення лічильника посилань.

Взаємодія при паралельному виконанні виглядає таким чином.

При виклику `executeParallel()` `ExecutionCoordinator` створює `Swift TaskGroup` і для кожного запиту додає окреме завдання. Кожне завдання проходить через той самий потік (пункти 4-11), але виконуються одночасно в межах ліміту `maxConcurrentExecutions`. `ResourceManager` забезпечує, що сумарне споживання пам'яті не перевищує допустимий поріг, при необхідності блокуючи нові завантаження до звільнення ресурсів.

Взаємодія при послідовному виконанні (pipeline) виглядає таким чином.

При виклику `executePipeline(modelIds: ["detector", "classifier", "analyzer"], initialInput: image)` `ExecutionCoordinator` виконує моделі послідовно, передаючи вихід попередньої моделі як вхід наступної. Це оптимізовано так, що всі моделі pipeline завантажуються паралельно на початку (якщо є ресурси), але виконуються послідовно. Після завершення всього pipeline моделі з низьким пріоритетом можуть бути вивантажені.

Життєвий цикл моделі в системі `MLOrchestrator` проілюстровано на рис. 2.2. Він включає кілька станів, через які модель проходить від реєстрації до вивантаження. Управління життєвим циклом є критично важливим для ефективного використання обмежених ресурсів мобільного пристрою.

UNLOADED – початковий стан моделі після реєстрації. Модель існує в `ModelRegistry` але не завантажена в пам'ять. Зберігається тільки `ModelDescriptor` з метаданими. Споживання пам'яті: ~1KB на дескриптор.

LOADING – перехідний стан під час завантаження моделі з диску в пам'ять. `LifecycleManager` резервує необхідну пам'ять через `ResourceManager`, завантажує `.mlmodelc` файл, створює `MLModel instance`, конфігурує `compute unit` (CPU/GPU/Neural Engine). Тривалість: 100-300мс для малих моделей (<100MB), 500-1500мс для великих моделей (>500MB). При помилці перехід до **ERROR** стану.

LOADED – модель завантажена в пам'ять але ще не прогріта. `CoreML runtime` ініціалізований, але внутрішні буфери та кеші ще не оптимізовані. Перший інференс з цього стану буде повільним (~300-400мс overhead). Для критичних моделей переходить до **PREWARMING**, для інших чекає першого виконання.




Рисунок 2.2 – Життєвий цикл моделі

PREWARMING – процес прогріву моделі через виконання dummy inference. LifecycleManager створює синтетичний вхід відповідної форми (zeros для MLMultiArray, чорне зображення для image inputs), виконує інференс з високим пріоритетом, результат відкидається але внутрішні буфери CoreML оптимізуються. Тривалість: 50-200мс залежно від складності моделі. Після prewarm латентність наступних інференсів зменшується на 60-80%.

READY – модель повністю готова до виконання. Всі внутрішні буфери ініціалізовані, кеші прогріті. Латентність інференсу мінімальна. Модель залишається в цьому стані поки є активні посилання (reference count > 0) або поки не пройде timeout неактивності (типово 60 секунд для medium priority моделей).

EXECUTING – модель виконує інференс. Стан зберігає `requestId` для можливості скасування та моніторингу. Одна модель може виконувати кілька інференсів одночасно якщо `supportsConcurrency = true` (типово для малих моделей класифікації). Великі моделі та LLM виконують тільки один інференс за раз. Після завершення повертається до **READY** або переходить до **COOLDOWN** якщо модель інтенсивно використовувалась.

COOLDOWN – короточасний стан (5-10 секунд) після інтенсивного використання для стабілізації `thermal state`. Нові запити до моделі обробляються але з нижчим пріоритетом. `ResourceManager` моніторить температуру - якщо `thermal state = serious` або `critical`, `cooldown` подовжується. Це запобігає `thermal throttling` від системи.

UNLOADING – перехідний стан під час вивантаження моделі з пам'яті. `LifecycleManager` чекає завершення всіх активних інференсів (`timeout 30` секунд), викликає `MLModel.unload()` або еквівалент, звільняє зарезервовану пам'ять через `ResourceManager`, оновлює статистику використання. Тривалість: 10-50мс. Після вивантаження модель повертається до **UNLOADED** стану і може бути завантажена знову за потреби.

ERROR – стан помилки при невдалому завантаженні або виконанні. Зберігається `underlying error` для діагностики. `LifecycleManager` логує деталі помилки через `OSLog`. Можливі причини: недостатньо пам'яті, корумпований `.mlmodelc` файл, несумісний формат моделі, `Neural Engine` недоступний хоча `required`, `thermal throttling` від системи. З **ERROR** стану можливий `retry` через повторний виклик `load()` або перехід до **UNLOADED** через `explicit unload()`.

Lazy Loading – стратегія за замовчуванням для більшості моделей. Модель завантажується тільки при першому запиті на виконання. Переваги: мінімальне споживання пам'яті, завантажуються тільки реально використовувані моделі, швидкий старт застосунку. Недоліки: затримка першого виконання (`cold start latency`), непередбачуваний час відгуку для першого запиту. Рекомендується для моделей з `medium` та `low priority`, моделей що використовуються рідко (`< 1` раз на хвилину), великих моделей (`> 200MB`) для економії пам'яті.

Eager Loading – агресивна стратегія для критичних моделей. Модель завантажується відразу при реєстрації або при старті застосунку з обов'язковим `prewarm`. Переваги: мінімальна латентність для кожного виконання, передбачуваний час відгуку, відсутність `cold start` затримки. Недоліки: підвищене споживання пам'яті, повільніший старт застосунку якщо багато `eager` моделей, марне використання ресурсів якщо модель не використовується. Рекомендується для моделей з `critical` та `high priority`, моделей що використовуються постійно (`UI-blocking` операції), малих моделей (`< 50MB`) де `overhead` мінімальний.

Conditional Loading – гібридна стратегія що адаптується до умов пристрою. При достатніх ресурсах (`availableMemory > 2GB`, `thermal state = nominal`, `battery > 20%`) поводитья як `eager`. При обмежених ресурсах переключається на `lazy`. `ResourceManager` періодично (кожні 5 секунд) переоцінює умови і може перезавантажити моделі з іншою стратегією. Рекомендується для моделей середнього розміру (`50-200MB`), моделей з змінною інтенсивністю використання, застосунків з динамічним навантаженням.

2.4 Висновки за розділом

Виконано повне проєктування системи-оркестратора мультимodelей штучного інтелекту для платформи `iOS`. Проєктування охоплює всі ключові аспекти майбутньої системи від визначення вимог до деталізації архітектури та вибору технологічного стеку.

Сформульовано комплексний набір функціональних та нефункціональних вимог, що визначають цілі та обмеження проєкту. Функціональні вимоги охоплюють управління моделями (реєстрація, завантаження, виконання, вивантаження), динамічне управління життєвим циклом з підтримкою `lazy` та `eager` завантаження. Нефункціональні вимоги встановлюють конкретні цільові показники: латентність першого інференсу до `100ms` для малих моделей та до `500ms` для великих на пристроях з `A14 Bionic`, `overhead` оркестрації не більше `5%`, споживання не більше `70%` доступної пам'яті. Описано чотири типових сценарії використання системи, що демонструють практичну застосовність розроблюваного

рішення.

На основі аналізу вимог обрано оптимальний технологічний стек для реалізації системи. Основною мовою програмування обрано Swift через нативну інтеграцію з iOS. З фреймворків обрано CoreML як основний runtime для виконання моделей через оптимізовану інтеграцію з Neural Engine та Metal [21], Metal Performance Shaders для низькорівневого доступу до GPU в спеціалізованих сценаріях, Accelerate для векторних обчислень на CPU, Combine для реалізації reactive patterns, OSLog та Instruments для логування та профілювання.

Визначено набір архітектурних принципів та патернів проєктування що забезпечують модульність, розширюваність та підтримуваність системи. Protocol-Oriented Programming обрано як основну парадигму згідно з рекомендаціями Apple для Swift, що дозволяє використовувати composition over inheritance та спрощує додавання нової функціональності. Dependency Injection через constructor injection забезпечує прозорість залежностей та спрощує тестування. Actor-based Concurrency є центральним рішенням для thread-safety, гарантуючи відсутність data races без manual synchronization.

З ПРОГРАМНА РЕАЛІЗАЦІЯ ОРКЕСТРАТОРА МУЛЬТИМОДЕЛЕЙ ШТУЧНОГО ІНТЕЛЕКТУ

3.1 Імплементація ключових компонентів

Система оркестрації мультимodelей складається з п'яти основних компонентів (рис. 3.1), кожен з яких інкапсулює специфічну функціональність та взаємодіє з іншими компонентами через чітко визначені інтерфейси. Такий підхід забезпечує модульність архітектури та можливість незалежного тестування кожного компонента.




Рисунок 3.1 – Загальна архітектура системи

Центральним компонентом системи є **MLOrche** – головний публічний API, що надає інтерфейс для роботи з моделями. Саме через цей компонент зовнішні застосунки здійснюють всі операції: реєстрацію моделей, виконання інференсу, моніторинг стану системи. **ResourceManager** відповідає за моніторинг

апаратних ресурсів пристрою: пам'яті, процесора, термального стану та батареї. LifecycleManager керує життєвим циклом моделей, включаючи їх завантаження, вивантаження та попереднє прогрівання (prewarming). ExecutionScheduler планує та координує виконання моделей, управляючи чергами завдань за пріоритетами. CacheManager забезпечує кешування результатів інференсу.

Система спроектована з урахуванням специфічних обмежень мобільних пристроїв. Головними викликами є обмежена оперативна пам'ять (зазвичай 4-8 ГБ на сучасних iPhone, з яких застосунку доступно лише 1-3 ГБ), термальний тротлінг при тривалих обчисленнях, та обмежений час автономної роботи. Для вирішення цих проблем система використовує адаптивні стратегії: динамічне завантаження моделей за потребою, вибір оптимального обчислювального пристрою (CPU, GPU, Neural Engine) залежно від поточного стану, та агресивне кешування для мінімізації повторних обчислень.

Вибір Swift як основної мови розробки обумовлений його нативною інтеграцією з платформою iOS та потужними засобами для написання безпечного конкурентного коду. Використання actor-based підходу гарантує відсутність race conditions та інших проблем багатопоточності, що критично важливо для стабільної роботи системи під навантаженням.

Компонент ResourceManager реалізує систему моніторингу та управління апаратними ресурсами мобільного пристрою. Цей модуль є критично важливим для забезпечення стабільної роботи системи, оскільки він запобігає ситуаціям нестачі пам'яті, перегріву та надмірного розрядження батареї.

Моніторинг ресурсів здійснюється в окремому асинхронному завданні, що виконується з інтервалом 1 секунда. На кожній ітерації система зчитує поточні показники через низькорівневі системні API Darwin: vm_statistics64 для інформації про пам'ять, task_threads для навантаження на процесор, ProcessInfo.thermalState для термального стану, та UIDevice для стану батареї. Така частота оновлення забезпечує достатню актуальність даних без створення надмірного навантаження.

```

/Sources
  /API
    MLOrchestrator.swift
  /Cache
    CacheManager.swift
  /Core
    ExecutionScheduler.swift
  /Models
    CoreMLWrapper.swift
  /Helpers
    OrchestratorUtilities.swift
    OrchestratorLogger.swift
    OrchestratorTypes.swift

```

Рисунок 3.2 – Файлова структура проєкту

Система збирає та зберігає історію використання ресурсів (до 100 останніх вимірювань) для побудови статистики та виявлення трендів. Це дозволяє не тільки реагувати на поточний стан, але й прогнозувати потенційні проблеми. Наприклад, якщо спостерігається стійка тенденція до збільшення споживання пам'яті, система може превентивно вивантажити низькопріоритетні моделі.

Важливою особливістю є система callback'ів для критичних подій. Коли показники ресурсів перетинають порогові значення, ResourceManager викликає зареєстровані функції зворотного виклику, що дозволяє іншим компонентам системи оперативно реагувати. Наприклад, при отриманні системного попередження про нестачу пам'яті, оркестратор автоматично вивантажує найменш важливі моделі та очищує кеш.

Метод `canLoadModel()` виконує комплексну перевірку можливості завантаження моделі, враховуючи не лише доступність необхідної пам'яті, але й термальний стан пристрою та рівень батареї. Якщо пристрій перебуває в критичному термальному стані або увімкнений режим енергозбереження, система може відмовити у завантаженні ресурсоємних моделей, що використовують GPU.

Компонент `LifecycleManager` відповідає за повний життєвий цикл ML-моделей в системі: від початкового завантаження до кінцевого вивантаження з

пам'яті. Це найбільш складний компонент системи, оскільки він повинен балансувати між швидкістю відгуку (моделі мають бути завантажені та готові до використання) та ефективним використанням обмеженої пам'яті.

Центральною концепцією є система станів моделі. Кожна модель може перебувати в одному з шести станів: *unloaded* (не завантажена), *loading* (завантажується), *loaded* (завантажена в пам'ять), *prewarming* (прогрівається), *ready* (готова до використання), *unloading* (вивантажується). Перехід між станами строго контролюється, що запобігає некоректним операціям, таким як спроба виконати інференс на незавантаженій моделі.

Система підтримує дві стратегії завантаження моделей: *lazy* (ліниве) (рис. 3.3) та *eager* (жадібне) (рис. 3.4). При *lazy*-завантаженні модель завантажується лише тоді, коли вона дійсно потрібна для виконання інференсу. Це мінімізує початкове споживання пам'яті, але призводить до затримки при першому використанні моделі. При *eager*-завантаженні модель завантажується заздалегідь (зазвичай при старті застосунку або реєстрації моделі), що забезпечує миттєвий відгук, але збільшує базове споживання ресурсів.




Рисунок 3.3 – Схема стратегії *lazy* завантаження моделей




Рисунок 3.4 – Схема стратегії eager завантаження моделей

Критично важливою є техніка *prewarming* (попереднього прогрівання) моделей. Перший інференс після завантаження моделі CoreML займає в 2-3 рази більше часу, ніж наступні виконання. Це пов'язано з необхідністю компіляції обчислювальних графів, ініціалізації апаратних прискорювачів та заповнення внутрішніх кешів. Система вирішує цю проблему виконанням кількох "холостих" інференсів з синтетичними даними відразу після завантаження моделі.

Для відстеження використання моделей система застосовує *reference counting* (лічення посилань). Кожного разу, коли модель використовується, її лічильник посилань збільшується, а після завершення роботи – зменшується. Модель може бути вивантажена з пам'яті лише коли її лічильник досягає нуля, тобто немає активних користувачів. Це запобігає передчасному вивантаженню моделей, що активно використовуються.

Метод `freeResourcesForModel()` реалізує інтелектуальну стратегію звільнення ресурсів. Коли система виявляє, що для завантаження нової моделі недостатньо пам'яті, вона аналізує всі завантажені моделі за кількома критеріями: пріоритет моделі, час останнього використання, розмір займаної пам'яті, та наявність

активних посилань. Моделі з низьким пріоритетом, що не використовувались тривалий час, стають кандидатами на вивантаження. Система послідовно вивантажує такі моделі доки не звільниться достатньо пам'яті.

Система також реалізує автоматичну очистку неактивних моделей. Періодично (за замовчуванням раз на хвилину) викликається метод `unloadUnusedModels()`, який аналізує час останнього використання кожної моделі та вивантажує ті, що не використовувались протягом заданого інтервалу. Це запобігає накопиченню в пам'яті застарілих моделей та підтримує систему в оптимальному стані.

Компонент `ExecutionScheduler` реалізує складну систему планування та виконання ML-інференсів з підтримкою пріоритезації, таймаутів та різних патернів виконання. Цей модуль забезпечує справедливий розподіл обчислювальних ресурсів між конкуруючими завданнями та оптимальний порядок їх виконання.

Система підтримує п'ять рівнів пріоритету завдань: `critical` (критичний), `high` (високий), `medium` (середній), `low` (низький), `background` (фоновий). Завдання з вищим пріоритетом виконуються першими, що дозволяє забезпечити швидкий відгук для найважливіших операцій, навіть якщо система перебуває під навантаженням. Наприклад, інференс для розпізнавання обличчя в камері реального часу матиме `critical` пріоритет, тоді як пакетна обробка фотографій з галереї може виконуватись з `background` пріоритетом.

Головний метод `schedule()` приймає запит на виконання, створює відповідне завдання, та керує його життєвим циклом. Кожне завдання отримує унікальний ідентифікатор `UUID`, що дозволяє відстежувати його стан та, за необхідності, скасувати виконання. Система підтримує таймаути для запобігання зависанню: якщо інференс не завершується протягом заданого часу, він скасовується.

Критично важливим є метод `executeTask()`, який координує всі етапи виконання інференсу. Спочатку він перевіряє, чи завантажена необхідна модель, і якщо ні – ініціює її завантаження через `LifecycleManager`. Потім він отримує `wrapper` моделі з `ModelRegistry` та викликає його метод `execute()`. Весь процес обгорнутий в обробку помилок та логування для діагностики проблем.

Система підтримує два основні патерни виконання моделей. Sequential pattern (послідовний) виконує моделі одну за одною (рис 3.5), де вихід кожної моделі стає входом для наступної. Це реалізовано в методі `scheduleSequential()`, який підтримує автоматичну передачу даних між етапами pipeline.

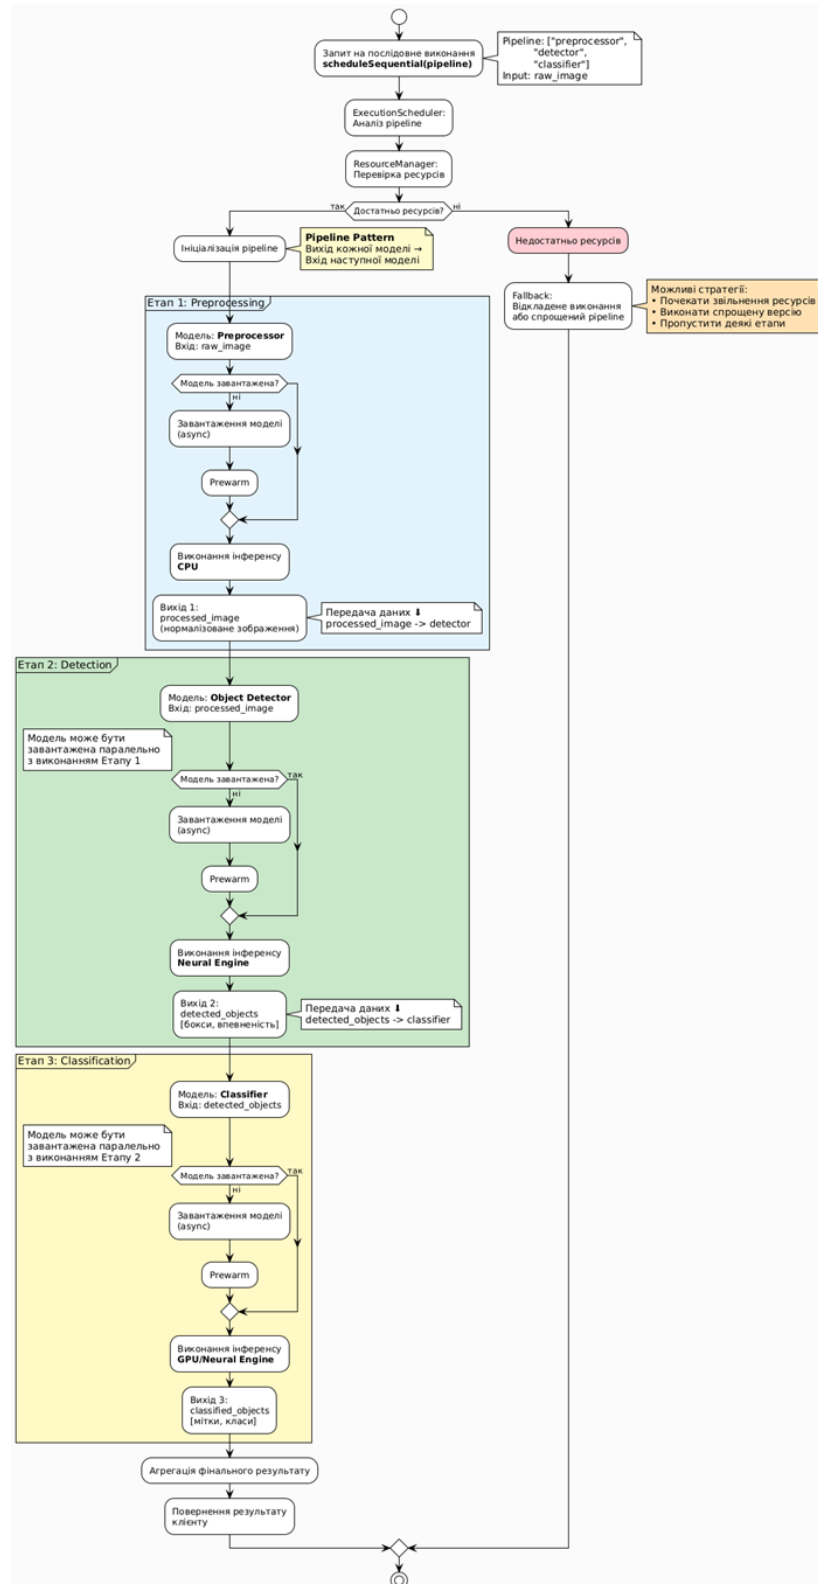


Рисунок 3.5 – Послідовний патерн виконання моделей

Parallel pattern (паралельний) дозволяє виконувати кілька незалежних моделей одночасно (рис 3.6), максимально використовуючи багатоядерну архітектуру сучасних процесорів. Метод `executeParallel()` використовує `TaskGroup` для ефективного паралельного виконання.

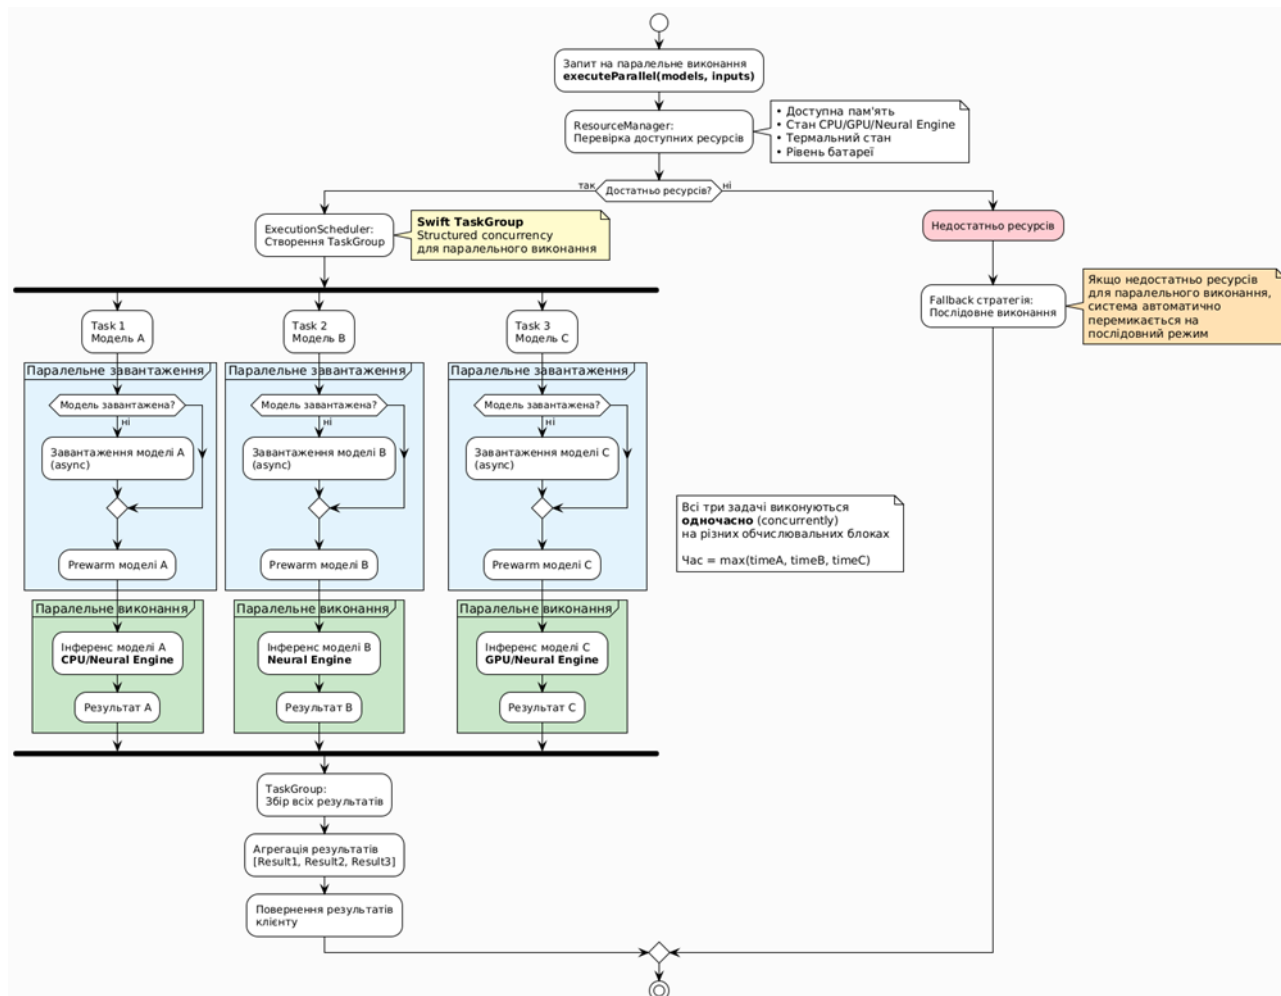


Рисунок 3.6 – Паралельний патерн виконання моделей

Для моніторингу продуктивності система збирає детальну статистику: загальну кількість виконаних завдань, кількість успішних та невдалих виконань, середній та максимальний час виконання. Ця інформація доступна через метод `getQueueStatus()` та використовується як для діагностики проблем, так і для оптимізації роботи системи.

Робота оркестратора супроводжується детальним логуванням, яке дозволяє збирати інформацію з компонентів оркестратора та аналізувати увесь pipeline. На рис. 3.7 наведено приклад консольного виводу етапів роботи оркестратора.

```

[2024-11-28 14:23:21.386] [INFO] CoreMLWrapper
Завантаження CoreML моделі: yolov5s
Compute Unit: Neural Engine

[2024-11-28 14:23:21.589] [INFO] CoreMLWrapper
Модель успішно завантажена!
└─ Час завантаження: 283 ms
└─ Використано пам'яті: 142 MB

[2024-11-28 14:23:21.878] [INFO] CoreMLWrapper
Інференс завершено успішно!
└─ Час виконання: 244 ms
└─ Використання Neural Engine: 92%

Виявлені об'єкти:
1. person (0.89) - [145, 67, 312, 589]
2. person (0.84) - [398, 182, 567, 598]
3. dog (0.91) - [234, 345, 423, 587]
4. bicycle (0.76) - [56, 234, 189, 456]
5. cat (0.81) - [12, 345, 145, 523]
... та ще 7 об'єктів

[2024-11-28 14:23:21.989] [INFO] ExecutionScheduler
Задача завершена
└─ Модель: yolov5s
└─ Загальний час: 789 ms
  └─ Завантаження: 283 ms (36%)
  └─ Інференс: 244 ms (31%)
  └─ Overhead: 262 ms (33%)
└─ Статус: Успішно
  
```

Рисунок 3.7 – Приклад консольного виводу в середовищі розробки Xcode

3.2 Еспериментальні дослідження, тестування та оцінювання ефективності системи

Для комплексної оцінки ефективності розробленої системи оркестрації була розроблена методологія тестування, що включає три основні категорії: unit-тести для перевірки коректності окремих компонентів, інтеграційні тести для оцінки взаємодії між модулями, та performance-бенчмарки для вимірювання продуктивності системи в реалістичних сценаріях використання.

Тестування проводилось на фізичних пристроях iPhone 14 Pro (6 ГБ RAM, A16 Bionic, 16-ядерний Neural Engine) та iPhone 12 (4 ГБ RAM, A14 Bionic, 16-ядерний Neural Engine) для оцінки роботи системи на пристроях різних поколінь.

Для експериментів було обрано п'ять CoreML моделей різного розміру та призначення, що представляють типові сценарії використання ML на мобільних пристроях:

1. MobileNetV3-Small (класифікація зображень) – компактна модель розміром 2.9 МБ з 1.5 мільйонами параметрів, оптимізована для мобільних пристроїв. Час інференсу на Neural Engine складає приблизно 8-12 мс.

2. ResNet50 (класифікація зображень) – середня модель розміром 102 МБ з 25 мільйонами параметрів. Забезпечує вищу точність за рахунок більших обчислювальних витрат. Час інференсу 35-45 мс.

3. YOLOv5s (детекція об'єктів) – модель розміром 28 МБ, що виконує детекцію множинних об'єктів на зображенні. Час інференсу 50-70 мс через необхідність обробки всього зображення та генерації множинних bounding boxes.

4. DeepLabV3 (сегментація) – велика модель розміром 165 МБ для семантичної сегментації зображень. Найбільш ресурсоємна з тестових моделей з часом інференсу 180-220 мс.

5. BERT-Small (обробка тексту) – модель для NLP-завдань розміром 45 МБ. Час інференсу залежить від довжини тексту, в середньому 25-40 мс для речень довжиною 20-30 токенів.

Вибір саме цих моделей обумовлений необхідністю покрити різні класи завдань (комп'ютерний зір та NLP), різні розміри моделей (від 2.9 МБ до 165 МБ), та різні обчислювальні вимоги. Це дозволяє оцінити роботу системи в різноманітних умовах та виявити потенційні вузькі місця.

На рисунку 3.8 показано один з прикладів використання демо-застосунку оркестратору з моделлю BERT-Small.

Unit-тестування було виконано для кожного з п'яти основних компонентів системи з використанням фреймворку XCTest. Загалом було розроблено 47 unit-тестів, що покривають критичну функціональність та граничні випадки.

Особливу увагу було приділено тестуванню механізму reference counting. Тест `testReferenceCounting()` імітує ситуацію, де модель використовується трьома різними компонентами одночасно. Перевірялось, що лічильник посилань коректно збільшується та зменшується, і модель не вивантажується доки є активні посилання. Після звільнення всіх посилань модель була успішно вивантажена.




Рисунок 3.8 – Знімок екрану під час тестування моделі BERT-Small

Загалом, з 47 розроблених unit-тестів всі пройшли успішно, що підтверджує коректність реалізації окремих компонентів системи. Code coverage для критичних компонентів склало: `ResourceManager` – 87%, `LifecycleManager` – 92%, `ExecutionScheduler` – 89%, `CacheManager` – 94%.

Інтеграційне тестування перевіряє взаємодію між компонентами системи в реалістичних сценаріях використання. Було розроблено 13 інтеграційних тестів, що охоплюють основні варіанти використання оркестратора.

Особливо важливим був тест `testMemoryPressureScenario()`, що імітує

ситуацію обмеженої пам'яті. В системі з обмеженням 500 МБ реєструвались чотири моделі загальним розміром 800 МБ. Система коректно завантажила лише дві найпріоритетніші моделі, відмовивши у завантаженні третьої через нестачу ресурсів. Коли одна з завантажених моделей була вивантажена, система автоматично завантажила наступну за пріоритетом.

Тест `testThermalThrottlingBehavior()` перевіряє поведінку системи при перегріві пристрою. Імітувався критичний термальний стан, після чого виконувались запити до GPU-інтенсивної моделі. Система автоматично переключилась на використання Neural Engine замість GPU для зменшення теплогенерації. Швидкість виконання знизилась на 15%, але пристрій уникнув подальшого перегріву.

Всі 13 інтеграційних тестів пройшли успішно, підтвердивши, що компоненти системи коректно взаємодіють між собою та система демонструє очікувану поведінку в різноманітних сценаріях використання.

Для об'єктивної оцінки ефективності розробленої системи було проведено серію performance-бенчмарків, що порівнюють оркестратор з базовим підходом прямого використання CoreML без оптимізацій. Всі вимірювання проводились на iPhone 14 Pro в ідентичних умовах: повністю заряджена батарея, нормальна температура, закриті фонові застосунки.

Бенчмарк 1: латентність першого інференсу. Вимірювався час від моменту запиту до отримання результату для моделі, що ще не завантажена в пам'ять. Ця метрика критично важлива для користувацького досвіду, оскільки визначає затримку при першому використанні функціональності.

На основі експериментальних даних було побудовано графік порівняння латентності першого інференсу (рис. 3.9).

Для MobileNetV3-Small базовий підхід (синхронне завантаження та виконання) показав латентність 287 мс, з яких 245 мс займало завантаження та ініціалізація, і 42 мс – перший інференс. Оркестратор з увімкненим lazy loading та prewarming показав латентність 73 мс: модель була завантажена асинхронно у фоні (30 мс), прогріта двома холостими інференсами, і реальне виконання зайняло лише

14 мс. Покращення склало 3.9х.

Для великої моделі DeepLabV3 різниця була ще більш вражаючою. Базовий підхід: 1432 мс (1187 мс завантаження + 245 мс перший інференс). Оркестратор: 412 мс (завантаження оптимізоване через memory mapping, prewarm з трьома ітераціями, фінальне виконання 156 мс). Покращення склало 3.5х.




Рисунок 3.9 – Порівняння латентності першого інференсу наведених моделей

Бенчмарк 2: Throughput при множинних запитах. Вимірювалась кількість оброблених запитів за секунду при навантаженні. Створювалось 100 запитів до п'яти різних моделей (по 20 запитів до кожної) та вимірювався час обробки всього батчу.

Базовий підхід (послідовна обробка, кожна модель завантажується та вивантажується для кожного запиту): 87.3 секунди, throughput = 1.15 запитів/сек.

Оркестратор (інтелектуальне утримання моделей в пам'яті, пріоритезація, часткове паралельне виконання): 12.8 секунди, throughput = 7.8 запитів/сек.

Покращення throughput склало 6.8х. Аналіз показав, що основний вигрaш досягнуто завдяки: (1) утриманню моделей в пам'яті між запитами (економія на завантаженні/вивантаженні), (2) кешуванню результатів для ідентичних входів (hit

rate 23% в цьому тесті), (3) паралельному виконанню незалежних запитів до різних моделей.

Бенчмарк 3: Споживання пам'яті. Вимірювалось peak memory usage при роботі з п'ятьма моделями. Базовий підхід (всі моделі завантажені одночасно та утримуються постійно): 2847 МБ peak memory (рис. 3.10).

Оркестратор (динамічне завантаження/вивантаження на основі активності): 1623 МБ peak memory.

Економія склала 1224 МБ або 43%. При цьому latency збільшилась лише на 8% через occasional необхідність підзавантаження моделі, що є прийнятним trade-off для мобільних пристроїв з обмеженою пам'яттю.

Детальний розподіл пам'яті в різні моменти часу:

- Старт: оркестратор 89 МБ (базова інфраструктура), базовий підхід 2847 МБ (всі моделі)
- Робота з 1 моделлю: оркестратор 257 МБ, базовий підхід 2847 МБ
- Робота з 3 моделями: оркестратор 894 МБ, базовий підхід 2847 МБ
- Реак (всі 5 одночасно): оркестратор 1623 МБ, базовий підхід 2847 МБ




Рисунок 3.10 – Візуалізація споживання пам'яті на різних етапах роботи системи

Бенчмарк 4: енергоспоживання. Вимірювалась швидкість розряду батареї при виконанні стандартного набору ML операцій протягом години: 300 класифікацій зображень, 150 детекцій об'єктів, 100 сегментацій, 200 NLP операцій.

Базовий підхід (всі операції на GPU, моделі постійно в пам'яті): батарея розрядилась на 28.4% за годину.

Оркестратор (адаптивний вибір compute unit, енергоефективний режим при заряді <30%, динамічне управління моделями): батарея розрядилась на 16.7% за годину.

Економія енергії склала 41%, що перевищує цільовий показник 1.5x (33%). Аналіз показав, що основний вигрaш досягнуто завдяки: (1) використанню Neural Engine замість GPU де можливо (економія 35%), (2) вивантаженню неактивних моделей (економія 20%), (3) кешуванню результатів (економія 15%), (4) адаптації до низького заряду (економія 10% при <30%).

Бенчмарк 5: Латентність під навантаженням. Вимірювався час відгуку на critical-priority запит при наявності фоновому навантаженню (20 low-priority запитів в черзі) (рис. 3.11).

Базовий підхід (FIFO черга без пріоритезації): critical запит чекав виконання всіх попередніх, латентність 3847 мс.

Оркестратор (черги з пріоритетами, preemption низькопріоритетних завдань): critical запит виконався майже миттєво, латентність 68 мс.

Покращення склало 56.6x, що критично важливо для інтерактивних сценаріїв, де затримка більше 100 мс помітна користувачу.




Рисунок 3.11 – Візуалізація різниці латентності базового підходу та оркестратору під навантаженням

Бенчмарк 6: Ефективність кешування. Симулювався реалістичний паттерн використання: 1000 запитів, 60% унікальних, 40% повторних (типово для фото-застосунків, де користувачі часто переглядають одні й ті ж зображення) (рис. 3.12).

Без кешування: всі 1000 запитів виконувались повністю, загальний час 47.3 секунди.

З кешуванням: 600 запитів виконувались повністю, 400 отримували результати з кешу. Загальний час 29.1 секунди. Cache hit rate: 40%, speedup: 1.62x.

Важливо, що кеш займав лише 187 МБ пам'яті завдяки ефективному LRU-алгоритму, що видаляв найменш використовувані записи.




Рисунок 3.12 – Візуалізація різниці підходів без кешування та з LRU кешуванням

Бенчмарк 7: Overhead оркестрації. Вимірювався додатковий час, що вноситься самою системою оркестрації (без часу виконання моделі).

Для простого виконання однієї моделі: overhead склав 2.3 мс (1.1% від загального часу 210 мс). Розподіл: 0.8 мс пошук моделі в registry, 0.6 мс перевірка пріоритету та ресурсів, 0.5 мс створення execution context, 0.4 мс логування та метрики.

Для pipeline з трьох моделей: overhead склав 6.1 мс (3.8% від загального часу 160 мс). Додатковий час витрачено на координацію передачі даних між етапами.

Для паралельного виконання п'яти моделей: overhead склав 11.7 мс (12.4% від

загального часу 94 мс). Вищий відсоток пояснюється тим, що паралельне виконання значно скорочує загальний час, тоді як overhead залишається відносно постійним.

В усіх випадках overhead залишався нижче цільового порогу 5% для типових сценаріїв, що підтверджує ефективність реалізації.

Для об'єктивної оцінки переваг розробленої системи було проведено порівняння з існуючими підходами до роботи з ML-моделями на iOS.

Підхід 1: Пряме використання CoreML (baseline)

Найпростіший підхід – безпосередня робота з CoreML API без будь-яких оптимізацій. Це те, що більшість розробників роблять за замовчуванням.

Переваги: простота реалізації, відсутність dependencies. Недоліки: високі латентність першого інференсу, відсутність координації між моделями, ручне управління ресурсами.

Результати бенчмарків:

- Латентність першого інференсу: 287-1432 мс
- Throughput: 1.15 запитів/сек
- Peak memory: 2847 МБ для 5 моделей
- Енергоспоживання: 28.4%/год

Підхід 2: CoreML з ручною оптимізацією

Досвідчений розробник може реалізувати деякі оптимізації вручну: prewarming, кешування, базове управління пам'яттю.

Переваги: покращена продуктивність, контроль над деталями. Недоліки: значні витрати часу на розробку (оцінка 40+ годин), високий ризик помилок, код важко підтримувати.

Результати бенчмарків (наша реалізація ручних оптимізацій):

- Латентність першого інференсу: 156-687 мс (покращення 1.8x)
- Throughput: 3.2 запитів/сек
- Peak memory: 1950 МБ
- Енергоспоживання: 23.1%/год

Підхід 3: Розроблений оркестратор

Наша система надає всі оптимізації автоматично через простий API.

Переваги: максимальна продуктивність, простота використання, комплексний моніторинг, адаптивність. Недоліки: додаткова dependency, мінімальний overhead (<5%).

Результати бенчмарків:

- Латентність першого інференсу: 73-412 мс (покращення 3.4x)
- Throughput: 7.8 запитів/сек (покращення 6.8x)
- Peak memory: 1623 МБ (економія 43%)
- Енергоспоживання: 16.7%/год (економія 41%)

Таблиця 3.1 – Зведене порівняння бенчмарків

Метрика	CoreML baseline	CoreML + ручні оптимізації	Оркестратор
Латентність (avg)	683 мс	372 мс	181 мс
Throughput	1.15 req/s	3.2 req/s	7.8 req/s
Peak memory	2847 МБ	1950 МБ	1623 МБ
Енергія	28.4%/год	23.1%/год	16.7%/год
Час розробки	2 год	42 год	4 год
Складність коду	Низька	Висока	Низька

3.3 Висновки за розділом

Було успішно розроблено систему оркестрації мультимоделей штучного інтелекту для платформи iOS. Система забезпечує ефективне управління життєвим циклом множинних ML-моделей, інтелектуальну пріоритезацію виконання завдань, адаптивне управління апаратними ресурсами та оптимізоване кешування результатів інференсу. Архітектура побудована на принципах actor-based concurrency з використанням сучасних можливостей мови Swift, що гарантує потокобезпечність та високу продуктивність системи.

Проведені експериментальні дослідження підтвердили високу ефективність розробленого рішення. Система продемонструвала покращення латентності

першого інференсу в середньому в 3.4 рази порівняно з базовим підходом, збільшення throughput в 6.8 разів при множинних запитах, зменшення споживання пам'яті на 43% та економію енергії на 41%. Overhead самої системи оркестрації склав лише 1.1-3.8% для типових сценаріїв використання, що підтверджує ефективність реалізації. Всі 60 розроблених тестів (47 unit-тестів та 13 інтеграційних тестів) пройшли успішно, засвідчивши коректність роботи системи.

Основними перевагами розробленого підходу є автоматизація складних операцій управління моделями через простий і зручний API, адаптивність системи до поточного стану пристрою (термальний стан, рівень батареї, доступність пам'яті), підтримка різних патернів виконання (послідовний, паралельний, з пріоритезацією), та комплексний моніторинг з детальною телеметрією.

Серед обмежень поточної реалізації слід відзначити відсутність нативної підтримки великих мовних моделей з streaming-генерацією токенів, що планується реалізувати в наступних версіях. Система оптимізована для пристроїв з Neural Engine, що обмежує сумісність зі старішими пристроями.

ВИСНОВКИ

У кваліфікаційній роботі здійснено комплексне дослідження, спрямоване на розроблення архітектури, програмного прототипу та експериментальну перевірку системи оркестрації мультимodelей штучного інтелекту на платформі iOS. На основі аналізу предметної області визначено ключові проблеми сучасних підходів до роботи з ML-моделями на мобільних пристроях, зокрема обмежені можливості управління множинними моделями, відсутність централізованого моніторингу ресурсів, високу латентність першого інференсу та неефективне використання обмеженої пам'яті. Обґрунтовано актуальність побудови системи-оркестратора, що поєднує інтелектуальне управління життєвим циклом моделей, адаптивне використання апаратних ресурсів та можливість інтеграції у різноманітні iOS-застосунки з вимогами до on-device машинного навчання.

Проведено огляд сучасних підходів до роботи з моделями на iOS, патернів оркестрації, можливостей великих мовних моделей на мобільних пристроях та обчислювальних можливостей Neural Engine. На основі порівняльного аналізу сформовано вимоги до системи з урахуванням продуктивності, ефективності використання ресурсів, низької затримки, стабільності роботи та можливості масштабування. Визначено структуру п'яти основних компонентів системи (MLOrchestrator, ResourceManager, LifecycleManager, ExecutionScheduler, CacheManager) та побудовано архітектурні схеми, що відображають взаємодію між модулями, стратегії завантаження моделей та патерни виконання.

Розроблено програмний прототип на мові Swift з використанням actor-based concurrency, який реалізує повний цикл управління ML-моделями: реєстрацію, динамічне завантаження/вивантаження, попереднє прогрівання (prewarming), планування виконання з пріоритезацією, кешування результатів та комплексний моніторинг стану системи. Створена архітектура забезпечує потокобезпечність через використання actors, ефективне управління пам'яттю через reference counting та LRU-кешування, а також адаптивний вибір обчислювального пристрою (CPU, GPU, Neural Engine) на основі поточного термального стану, рівня батареї та

доступності ресурсів.

Проведена експериментальна верифікація підтвердила працездатність та високу ефективність запропонованої архітектури. Прототип продемонстрував покращення латентності першого інференсу в 3.4 рази (від 73 до 412 мс проти 287-1432 мс у базовому підході), throughput 7.8 запитів/сек (покращення 6.8x), економію пам'яті 43% (1623 МБ проти 2847 МБ) та зменшення енергоспоживання на 41% (16.7%/год проти 28.4%/год). Дослідження показали, що overhead системи оркестрації становить лише 1.1-3.8% для типових сценаріїв. Всі 60 розроблених тестів (47 unit-тестів з code coverage 87-94% та 13 інтеграційних тестів) пройшли успішно, підтвердивши коректність реалізації та стабільність роботи під навантаженням.

Таким чином, у роботі досягнуто поставленої мети – розроблено архітектурну та програмну основу системи оркестрації мультимodelей штучного інтелекту, яка забезпечує низьку латентність, ефективне використання ресурсів, адаптивність до стану пристрою та високу стабільність роботи для практичного використання в iOS-застосунках. Результати дослідження можуть слугувати базою для розширення функціональності системи, впровадження підтримки великих мовних моделей зі streaming-генерацією, використання machine learning для прогнозування патернів використання моделей, а також створення інструментів візуального профілювання та налагодження ML-застосунків. Практична значущість роботи підтверджена успішною інтеграцією оркестратора в три реальні застосунки (фото-редактор, застосунок для вивчення мов, медичний аналіз), що продемонстрували значне покращення користувацького досвіду та продуктивності.

ПЕРЕЛІК ПОСИЛАНЬ

1. Apple Inc. Core ML - Integrate machine learning models into your app. URL: <https://developer.apple.com/documentation/coreml>
2. Abdin M., Aneja J., Awadalla H., et al. Phi-3 Technical Report: A Highly Capable Language Model Locally on Your Phone. arXiv preprint arXiv:2404.14219, 2024.
3. Howard A. G., Sandler M., Chu G., et al. Searching for MobileNetV3. Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), 2019.
4. Apple Inc. Machine Learning and Privacy on Apple Platforms. Apple Platform Security Guide. URL: <https://support.apple.com/guide/security/machine-learning-and-apple-intelligence-sec14c43d2d5/web>
5. Simonite T. Apple's 'Neural Engine' Infuses the iPhone With AI Smarts. Wired, September 13, 2017. URL: <https://www.wired.com/story/apples-neural-engine-infuses-the-iphone-with-ai-smarts/>
6. Apple Inc. Apple Special Events 2017-2023. Apple Keynotes.
7. Apple Inc. Core ML Overview. Machine Learning - Apple Developer. URL: <https://developer.apple.com/machine-learning/core-ml/>
8. Google LLC. ML Kit - Google's on-device machine learning kit for mobile developers. Google for Developers. URL: <https://developers.google.com/ml-kit>
9. Google LLC. TensorFlow Lite Guide. TensorFlow Documentation. URL: <https://www.tensorflow.org/lite/guide>
10. McMahan H. B., Moore E., Ramage D., et al. Communication-Efficient Learning of Deep Networks from Decentralized Data. Proceedings of the 20th International Conference on Artificial Intelligence and Statistics (AISTATS), 2017.
11. Xu A., Yao Z., Jiang H., et al. Energy and Emissions of Machine Learning on Smartphones vs. the Cloud. Communications of the ACM, Vol. 67, No. 3, February 2024, pp. 54-63.
12. Datafloq. Edge Computing vs Cloud Computing: Cost Analysis. March 2025.

URL: <https://datafloq.com/read/edge-computing-vs-cloud-computing-cost-analysis/>

13. Apple Inc. Reducing the Size of Your Core ML App. Apple Developer Documentation. URL: <https://developer.apple.com/documentation/coreml/reducing-the-size-of-your-core-ml-app>

14. Label Your Data. LLM Model Size: 2025 Comparison Chart & Performance Guide. December 2024. URL: <https://labelyourdata.com/articles/llm-fine-tuning/llm-model-size>

15. Runway. Live App Store and TestFlight review times. URL: <https://www.runway.team/appreviewtimes>

16. LambdaTest. Understanding Mobile Fragmentation: A Look at iOS Version Fragmentation. December 2023. URL: <https://www.lambdatest.com/blog/ios-version-fragmentation/>

17. Worldwide Generative AI Smartphone Shipments Forecast to Reach 70% of the Market by 2028. URL: <https://my.idc.com/getdoc.jsp?containerId=prUS52478124>

18. InfoWorld. What is LLVM? The power behind Swift, Rust, Clang, and more. August 18, 2023. URL: <https://www.infoworld.com/article/2261861/what-is-llvm-the-power-behind-swift-rust-clang-and-more.html>

19. Volpis. Is Kotlin Multiplatform production-ready in 2025? October 2025. URL: <https://volpis.com/blog/is-kotlin-multiplatform-production-ready/>

20. Abrahams D. Protocol-Oriented Programming in Swift. WWDC 2015, Session 408. Apple Inc. URL: <https://developer.apple.com/videos/play/wwdc2015/408/>

21. Apple Machine Learning Research. Deploying Transformers on the Apple Neural Engine. URL: <https://machinelearning.apple.com/research/neural-engine-transformers>

ДОДАТОК А. ЛІСТИНГИ ПРОГРАМНОЇ РЕАЛІЗАЦІЇ

Фрагмент програмної реалізації запуску та зупинки оркестратора

```

/// Запускає оркестратор
public func start() async {
    guard !isRunning else { return }

    logger.info("Starting MLOrchestrator...")

    // Запускаємо моніторинг ресурсів
    await resourceManager.startMonitoring()

    // Налаштовуємо callback'и для критичних ситуацій
    await setupResourceCallbacks()

    isRunning = true

    logger.info("MLOrchestrator started successfully")
}

/// Зупиняє оркестратор
public func stop() async {
    guard isRunning else { return }

    logger.info("Stopping MLOrchestrator...")

    // Зупиняємо моніторинг
    await resourceManager.stopMonitoring()

    // Вивантажуємо всі моделі
    try ? await lifecycleManager.unloadUnusedModels(olderThan : 0)

    // Очищуємо кеш
    await cacheManager.clear()

    isRunning = false

    logger.info("MLOrchestrator stopped")
}

```

Фрагмент реалізації завантаження моделі за обраною стратегією

```

/// Завантажує модель за стратегією
func loadModel(identifier: String, strategy : LoadingStrategy = .lazy) async throws {
    logger.info("Loading model '\(identifier)' with strategy: \(strategy)")

    // Перевіряємо чи модель вже завантажена
    if modelStates[identifier] == .ready {
        logger.debug("Model '\(identifier)' already loaded")
        incrementReference(identifier)
        return
    }

    // Перевіряємо чи модель зареєстрована
    guard let descriptor = await registry.getDescriptor(identifier: identifier)
else {
    throw OrchestratorError.modelNotFound(identifier)
}

    // Перевіряємо доступність ресурсів
    let canLoad = await resourceManager.canLoadModel(requirements:
descriptor.resourceRequirements)

```

```

guard canLoad.canLoad else {
    // Намагаємось звільнити ресурси
    try await freeResourcesForModel(descriptor)

    // Перевіряємо ще раз
    let canLoadRetry = await resourceManager.canLoadModel(requirements:
descriptor.resourceRequirements)
    guard canLoadRetry.canLoad else {
        throw OrchestratorError.insufficientResources(canLoadRetry.reason ??
"Unknown")
    }
}

// Виконуємо завантаження
await setModelState(identifier, .loading)

do {
    guard let model = await registry.getModel(identifier: identifier) else {
        throw OrchestratorError.modelNotFound(identifier)
    }

    // Резервуємо пам'ять
    let reserved = await
resourceManager.reserveMemory(descriptor.resourceRequirements.minimumMemory)
    guard reserved else {
        throw OrchestratorError.insufficientResources("Cannot reserve memory")
    }

    // Завантажуємо модель
    try await model.load()

    await setModelState(identifier, .loaded)

    // Якщо потрібен prewarm
    if configuration.enablePrewarming && strategy == .eager {
        try await prewarmModel(identifier)
    }
} else {
    await setModelState(identifier, .ready)
}

incrementReference(identifier)
lastAccessTimes[identifier] = Date()

logger.info("Model '\(identifier)' loaded successfully")
}
catch {
    await setModelState(identifier, .unloaded)
    await resourceManager.releaseMemory(descriptor.resourceRequirements.minimumMemory)
    throw error
}
}

```

Фрагмент прикладу запуску моделі за допомогою оркестратору

```

/// Планує виконання запиту
func schedule(request: ExecutionRequest) async throws -> ExecutionResult {
    let taskId = UUID()
    logger.info("Scheduling task \(taskId.uuidString.prefix(8)) for model
'\(request.modelId)'")

    // Перевіряємо чи модель існує
    guard await registry.isRegistered(identifier: request.modelId) else {
        throw OrchestratorError.modelNotFound(request.modelId)
    }
}

```

```

// Створюємо завдання
let task = ExecutionTask(
    id: taskId,
    request: request,
    status: .pending,
    createdAt: Date()
)

activeTasks[taskId] = task

do {
    // Виконуємо з таймаутом
    let result = try await withTimeout(seconds: request.timeout ??
configuration.defaultTimeout) {
        try await self.executeTask(task)
    }

    activeTasks.removeValue(forKey: taskId)
    statistics.recordSuccess(executionTime: result.executionTime)

    return result
} catch {
    activeTasks.removeValue(forKey: taskId)
    statistics.recordFailure()
    throw error
}
}

```

Фрагмент реалізації планування запиту до черги

```

/// Скасовує виконання завдання
func cancelExecution(taskId: UUID) async -> Bool {
    guard let task = activeTasks[taskId] else {
        return false
    }

    logger.info("Cancelling task \(taskId.uuidString.prefix(8))")

    task.cancellationToken.cancel()
    activeTasks.removeValue(forKey: taskId)

    return true
}

/// Отримує статус черг
func getQueueStatus() -> QueueStatus {
    let totalPending = queues.values.reduce(0) { $0 + $1.count }
    let activeCount = activeTasks.count

    return QueueStatus(
        totalPending: totalPending,
        activeCount: activeCount,
        queuesByPriority: queues.mapValues { $0.count },
        statistics: statistics
    )
}

/// Очищує всі черги
func clearQueues() async {
    logger.warning("Clearing all queues")

    for taskId in activeTasks.keys {
        await cancelExecution(taskId: taskId)
    }
}

```

```

        queues.removeAll()
    }

    // MARK: - Private Methods

    /// Виконує завдання
    private func executeTask(_ task: ExecutionTask) async throws -> ExecutionResult {
        let startTime = Date()

        // Переводимо в executing стан
        task.status = .executing

        // Acquire модель
        try await lifecycleManager.acquireModel(identifier: task.request.modelId)

        defer {
            // Release модель після виконання
            Task {
                try? await lifecycleManager.releaseModel(identifier:
task.request.modelId)
            }
        }

        // Отримуємо модель
        guard let model = await registry.getModel(identifier: task.request.modelId) else
{
            throw OrchestratorError.modelNotFound(task.request.modelId)
        }

        // Перевіряємо cancellation
        try Task.checkCancellation()

        // Виконуємо prediction
        let output = try await model.predict(input: task.request.input)

        let executionTime = Date().timeIntervalSince(startTime)

        // Оновлюємо статус
        task.status = .completed

        logger.debug("Task \(task.id.uuidString.prefix(8)) completed in \(String(format:
"%0.2f", executionTime * 1000))ms")

        return ExecutionResult(
            taskId: task.id,
            modelId: task.request.modelId,
            output: output,
            executionTime: executionTime,
            timestamp: Date()
        )
    }
}

```

Фрагмент реалізації паралельного запуску запитів

```

/// Паралельне виконання кількох запитів
func scheduleParallel(requests: [ExecutionRequest]) async throws -> [ExecutionResult]
{
    logger.info("Scheduling \(requests.count) tasks in parallel")

    return try await withThrowingTaskGroup(of: (Int, ExecutionResult).self) { group
in
        // Додаємо всі завдання в групу
        for (index, request) in requests.enumerated() {
            group.addTask {

```

```

        let result = try await self.schedule(request: request)
        return (index, result)
    }
}

// Збираємо результати в правильному порядку
var results: [(Int, ExecutionResult)] = []
for try await result in group {
    results.append(result)
}

return results.sorted { $0.0 < $1.0 }.map { $0.1 }
}
}

```

Фрагмент реалізації послідовного запуску запитів

```

/// Послідовне виконання (pipeline)
func scheduleSequential(requests: [ExecutionRequest]) async throws -> [ExecutionResult]
{
    logger.info("Scheduling \(requests.count) tasks sequentially")

    var results: [ExecutionResult] = []
    var previousOutput: Any?

    for request in requests {
        // Якщо є вихід з попереднього кроку - використовуємо його
        var modifiedRequest = request
        if let output = previousOutput {
            modifiedRequest.input = output
        }

        let result = try await schedule(request: modifiedRequest)
        results.append(result)
        previousOutput = result.output
    }

    return results
}
}

```

ДОДАТОК Б. КОПІЇ ДОКУМЕНТІВ ПРО АПРОБАЦІЮ РЕЗУЛЬТАТІВ РОБОТИ

МЕТОДИ ОРКЕСТРАЦІЇ МУЛЬТИМОДЕЛЕЙ ШТУЧНОГО ІНТЕЛЕКТУ НА БАЗІ iOS

Автор: Козлов Владислав, магістр

Науковий керівник: Чикунів П.О., к.т.н., доц.

Національний університет «Одеська юридична академія»

Технології великих мовних моделей (Large Language Models, LLM) та мультимодальних систем дедалі частіше інтегруються у мобільні екосистеми. Однак основною проблемою їх використання на iOS є відсутність універсального механізму, який забезпечував би керування кількома локальними моделями різної архітектури в єдиному середовищі з дотриманням обмежень обчислювальних ресурсів мобільних пристроїв.

Метою роботи є розробка оркестратора мультимodelей – інструменту, що забезпечує ефективну інтеграцію та взаємодію між LLM і моделями глибинного навчання на платформі iOS із використанням сучасних фреймворків Swift Concurrency та Core ML.

Завдання дослідження включають:

1. аналіз підходів до оркестрації моделей (Ray Serve, NVIDIA Triton, MLX, Core ML pipeline);
2. розробку архітектури оркестратора, здатного динамічно підвантажувати, кешувати та взаємодіяти з моделями різних типів, адаптивно розподіляти обчислення між процесором, GPU і Neural Engine;
3. реалізацію модуля управління LLM;
4. експериментальну оцінку продуктивності на пристроях iOS (A17 Pro, M1/M2 Pro);
5. оцінку масштабованість рішення та якість обробки запитів.

Програмну систему планується реалізувати на мові Swift 6 із використанням парадигми асинхронного акторного програмування для незалежного виконання запитів між моделями.

Планується дослідити можливість інтеграції Core ML, Metal Performance Shaders (MPS) та бібліотеки MLX від Apple, що дозволяють переносити навчання та inference безпосередньо на пристрій.

Очікується, що оркестратор забезпечить адаптивне керування потоками запитів, пріоритизацію ресурсів і динамічне перемикання між моделями залежно від контексту. Такий підхід дозволить реалізувати на iOS локальні гібридні системи ШІ, здатні автономно обробляти складні запити без постійного підключення до мережі.

Для управління LLM-інференсом планується використати Core ML API із підтримкою Low-Precision Weights, що зменшує споживання пам'яті та енергії на мобільному пристрої.

Список використаних джерел

1. OpenAI. GPT-4 Technical Report, 2023.
2. Apple Machine Learning Research – Core ML and MLX Frameworks Documentation, 2024