

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»
Міністерство освіти і науки України

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»
Міністерство освіти і науки України

Кваліфікаційна наукова
праця на правах рукопису

ХМЕЛЬНИЦЬКИЙ АРСЕНІЙ АНДРІЙОВИЧ

УДК 004.8

ДИСЕРТАЦІЯ

СПОСІБ ТРАНСФОРМАЦІЇ НЕЙРОННИХ МЕРЕЖ ДЛЯ ВИКОРИСТАННЯ В
КОНТЕКСТІ НЕКЛАСИЧНИХ ОБЧИСЛЕНЬ

121 Інженерія програмного забезпечення

12 Інформаційні технології

Подається на здобуття наукового ступеня доктора філософії

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

_____ Хмельницький А.А.

Науковий керівник: Юрій Григорович Гордієнко, проф. каф. ОТ, д.ф.-м.н., с.н.с.

АНОТАЦІЯ

Хмельницький А.А. Спосіб трансформації нейронних мереж для використання в контексті неklasичних обчислень. – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня доктора філософії за спеціальністю 121 – Інженерія програмного забезпечення з галузі знань 12 – Інформаційні технології. – Національний Технічний Університет України «Київський Політехнічний Інститут імені Ігоря Сікорського», Київ, 2025.

У дисертаційній роботі розглянуто проблему адаптації нейронних мереж до умов неklasичних обчислювальних середовищ, зокрема квантових, нейроморфних та інших альтернативних парадигм. В умовах стрімкого зростання обчислювальної складності сучасних моделей штучного інтелекту та зростаючого інтересу до нових апаратних платформ постає задача розробки методів трансформації архітектур нейронних мереж, які б дозволяли ефективно переносити класичні моделі в нові обчислювальні контексти.

Актуальність роботи зумовлена відсутністю формалізованих принципів інтеграції квантових перетворень у структури класичних нейронних мереж. Наявні підходи здебільшого ґрунтуються на емпіричних налаштуваннях без чіткого опису того, як параметризовані квантові операції впливають на стабільність, відтворюваність і продуктивність моделей на даних різної складності. Ситуація ускладнюється тим, що медичні набори даних є високоваріативними, містять значний дисбаланс класів і чутливі до перенавчання, що потребує пошуку стійкіших архітектур.

Метою роботи є підвищення ефективності та стабільності систем класифікації зображень шляхом розробки методу трансформації нейронних мереж у гібридні квантово-класичні архітектури, придатні для використання в контексті неklasичних обчислень. У роботі проаналізовано властивості типових неklasичних обчислювальних систем, визначено обмеження, які вони

накладають на структуру та функціональні елементи моделей машинного навчання.

Для досягнення поставленої мети проаналізовано сучасні методи квантового та гібридного глибинного навчання, досліджено можливості використання квантових симуляторів у задачах опрацювання зображень, розроблено метод трансформації нейронних мереж на архітектурному, функціональному та реалізаційному рівнях, запропоновано конфігурації гібридних квантово-класичних моделей із квантовою згорткою як препроцесингом, а також експериментально оцінено ефективність гібридних моделей порівняно з класичними та проаналізовано вплив кількості квантових каналів і масштабу класичної основи на якість і стабільність класифікації.

Розроблено та досліджено метод використання квантових перетворень як квантово-згорткового препроцесингу (qunvolution) для формування багатоканального представлення вхідного зображення. Масштабована архітектура HNN-QCn передбачає поєднання кількох паралельних класичних основ нейронної мережі (бекбонів), де кожен отримує окремий квантово-перетворений канал; для генерації квантових варіацій використовуються однокубітні обертання навколо осей Y , X та їх комбінації (RY , RX , RXY).

Для узагальнення прогнозів, отриманих для різних квантових варіацій зображення, обґрунтовано застосування мажоритарного голосування (Majority Voting - MV) як завершального кроку формування фінального передбачення гібридної моделі.

Наукова новизна одержаних результатів полягає в тому, що вперше запропоновано комплексний спосіб побудови гібридних квантово-класичних нейронних мереж, який, на відміну від наявних підходів з інтеграцією квантової компоненти в одну фіксовану архітектуру, забезпечує системну трансформацію мереж на трьох взаємопов'язаних рівнях — архітектурному, функціональному та реалізаційному. Набув подальшого розвитку метод квантового препроцесингу на основі квантової згортки, який передбачає паралельне застосування кількох однокубітних обертань для формування множини додаткових каналів, завдяки чому квантово-індуковані ознаки виконують роль регуляризатора. Вперше

сформульовано критерій доцільності застосування квантового препроцесингу залежно від масштабу класичної компоненти та вперше розроблено стандартизований протокол експериментального оцінювання, що поєднує стратифіковану перехресну перевірку, прогнозування на позатренувальних блоках (Out-of-Fold) і статистичний аналіз стабільності метрик.

Експериментальні дослідження виконано на еталонному наборі даних загального призначення CIFAR-10 та прикладних спеціалізованих медичних наборах даних MedMNIST (BloodMNIST, PathMNIST, DermaMNIST).

Показано зростання якості зі збільшенням кількості квантових каналів: для набору даних CIFAR-10 комбінована конфігурація HNN-5QC (YW4+O1) досягла значень точності (accuracy) 0.769 ± 0.002 при значеннях $AUC_micro = 0.964 \pm 0.022$ та $AUC_macro = 0.969 \pm 0.001$, що перевищує аналогічні показники базової моделі. Також встановлено перевагу вибору класичного бекбону: на наборі даних DermaMNIST модель з основою LCNet050 стабільно переважає модель з основою MobileNetV3Small050 за показниками AUC ($\Delta AUC \approx 0.02$; AUC_macro 0.9540 проти 0.9340; AUC_micro 0.9585 проти 0.9381).

Встановлено, що ефект гібридизації найбільший для компактних і середніх класичних архітектур, тоді як для великих компонент він суттєво зменшується; зі збільшенням кількості квантових каналів якість зростає до діапазону QC5–QC9, після чого спостерігається ефект насичення. Одночасно зменшується міжфолдова варіативність метрик, що підтверджує інтерпретацію квантово-індукованої ознакової надбудови як регуляризатора, який підвищує стабільність і відтворюваність прогнозів.

Практичне значення одержаних результатів полягає у формалізації підходу побудови гібридних квантово-класичних моделей та створенні відтворюваного експериментального потоку робочих операцій (workflow) для систематичного добору квантових трансформацій, кількості квантових каналів і класичних архітектур під конкретні задачі класифікації зображень із підвищеними вимогами до надійності.

Результати дисертації отримано здобувачем самостійно: розроблено концепцію та принципи системної трансформації нейронних мереж, архітектуру

HNN-QCn і схему багатоканального кванволюційного входу, реалізовано програмні засоби та проведено експерименти. Основні положення оприлюднено на міжнародних наукових конференціях (ICAIS 2024; ICTSM, Сінгапур, 2024) та опубліковано в наукових працях, зокрема у виданнях, що індексуються в Scopus (журнали AI та Computation), і у фаховому виданні України.

Дисертація складається зі вступу, чотирьох розділів, висновків, списку використаних джерел і додатка. У ній послідовно розглянуто квантові обчислення та інструменти штучного інтелекту, особливості класичних і некласичних обчислень для гібридизації, комплексний спосіб побудови квантово-класичних гібридних мереж, а також аналіз результатів експериментів з багатоканальною кванволюцією, масштабуванням архітектури HNN-QCn і впливом вибору класичної основи.

Ключові слова: машинне навчання, глибокі нейронні мережі, гібридні нейронні мережі, класифікація зображень, квантові обчислення.

ABSTRACT

Khmelnyskyi A.A. Method for Transforming Neural Networks for Use in the Context of Non-Classical Computing. – Qualified scientific work on the rights of the manuscript.

Dissertation for the degree of Doctor of Philosophy in specialty 121 – Software Engineering, field of knowledge 12 – Information Technologies. – National Technical University of Ukraine “Igor Sikorsky Kyiv Polytechnic Institute,” Kyiv, 2025.

The dissertation addresses the problem of adapting neural networks to non-classical computational environments, in particular quantum, neuromorphic, and other alternative paradigms. In the context of the rapid growth of computational complexity in modern artificial intelligence models and the increasing interest in emerging hardware platforms, there arises a need to develop methods for transforming neural network architectures that enable efficient transfer of classical models to new computational contexts.

The relevance of the work stems from the lack of formalized principles for integrating quantum transformations into the structures of classical neural networks. Existing approaches rely mostly on empirical tuning, without a clear description of how parameterized quantum operations affect the stability, reproducibility, and performance of models on data of varying complexity. The situation is further complicated by the fact that medical datasets are highly variable, contain significant class imbalance, and are prone to overfitting, which calls for more robust architectures.

The aim of the research is to improve the efficiency and stability of image classification systems by developing a method for transforming neural networks into hybrid quantum–classical architectures suitable for use in non-classical computing settings. The study analyzes the properties of typical non-classical computational systems and identifies the constraints they impose on the structure and functional components of machine learning models.

To achieve this aim, modern methods of quantum and hybrid deep learning were analyzed, the possibilities of using quantum simulators in image-processing tasks were

studied, a method for transforming neural networks at the architectural, functional, and implementation levels was developed, configurations of hybrid quantum–classical models with quantum convolution as preprocessing were proposed, and the effectiveness of the hybrid models was experimentally evaluated against classical ones, together with an analysis of the influence of the number of quantum channels and the scale of the classical backbone on classification quality and stability.

A method for employing quantum transformations as quantum-convolutional preprocessing (quanvolution) to form a multi-channel representation of input images has been developed and investigated. The scalable HNN-QCn architecture combines multiple parallel classical backbones, each receiving a separate quantum-transformed channel; single-qubit rotations around the Y and X axes and their combinations (RY, RX, RXY) are used to generate quantum variations.

To aggregate predictions obtained from different quantum variations of the image, the use of the Majority Voting (MV) approach is justified as the final step in forming the hybrid model’s prediction.

The scientific novelty of the obtained results is that, for the first time, a comprehensive method for constructing hybrid quantum–classical neural networks is proposed which, unlike existing approaches that integrate the quantum component into a single fixed architecture, provides a systemic transformation of networks at three interrelated levels — architectural, functional, and implementation. The method of quantum preprocessing based on quantum convolution has been further developed through the parallel application of several single-qubit rotations to form a set of additional channels, owing to which the quantum-induced features act as a regularizer. For the first time, a criterion for the expediency of applying quantum preprocessing depending on the scale of the classical component has been formulated, and a standardized protocol for experimental evaluation has been developed that combines stratified cross-validation, Out-of-Fold prediction, and statistical analysis of metric stability.

Experimental studies were conducted on the general-purpose benchmark dataset CIFAR-10 and on the applied specialized medical datasets MedMNIST (BloodMNIST, PathMNIST, DermaMNIST).

An improvement in performance with an increasing number of quantum channels is demonstrated: for the CIFAR-10 dataset, the combined HNN-5QC (YW4+O1) configuration achieved an accuracy of 0.769 ± 0.002 with $\text{AUC_micro} = 0.964 \pm 0.022$ and $\text{AUC_macro} = 0.969 \pm 0.001$, outperforming the baseline model. In addition, the advantage of backbone selection is established: on the DermaMNIST dataset, the model with the LCNet050 backbone consistently outperforms the model with the MobileNetV3Small050 backbone in terms of AUC ($\Delta\text{AUC} \approx 0.02$; AUC_macro 0.9540 vs. 0.9340; AUC_micro 0.9585 vs. 0.9381).

It has been established that the effect of hybridization is greatest for compact and medium-sized classical architectures, whereas for large components it decreases substantially; as the number of quantum channels grows, quality increases up to the QC5–QC9 range, after which a saturation effect is observed. At the same time, the inter-fold variability of the metrics decreases, which confirms the interpretation of the quantum-induced feature superstructure as a regularizer that improves the stability and reproducibility of predictions.

The practical significance of the obtained results lies in the formalization of an approach to constructing hybrid quantum–classical models and in the creation of a reproducible experimental workflow for the systematic selection of quantum transformations, the number of quantum channels, and classical architectures for specific image classification tasks with increased reliability requirements.

The results of the dissertation were obtained by the author independently: the concept and principles of the systemic transformation of neural networks were developed, as well as the HNN-QCn architecture and the multi-channel quanvolutional input scheme; the software was implemented and the experiments were carried out. The main results were presented at international scientific conferences (ICAIS 2024; ICTSM, Singapore, 2024) and published in scientific works, in particular in journals indexed in Scopus (AI and Computation) and in a professional journal of Ukraine.

The dissertation consists of an introduction, four chapters, conclusions, a list of references, and an appendix. It successively examines quantum computing and artificial-intelligence tools, the features of classical and non-classical computing for hybridization, a comprehensive method for constructing quantum–classical hybrid

networks, and an analysis of experimental results involving multi-channel quanvolution, scaling of the HNN-QCn architecture, and the influence of classical-backbone selection.

Keywords: machine learning, deep neural networks, hybrid neural networks, , image classification, quantum computing.

СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА

Наукові праці, в яких опубліковано основні наукові результати дисертації:

1. **Khmelnyskyi, A.**, Stirenko, S., Gordienko, Y. (2024). Hybrid Neural Networks for Medical Image Classification. In: Manoharan, S., Tugui, A., Baig, Z. (eds) Proceedings of 4th International Conference on Artificial Intelligence and Smart Energy. ICAIS 2024. Information Systems Engineering and Management, vol 3. Springer, Cham. https://doi.org/10.1007/978-3-031-61471-2_35 ISSN 3004-958X

Здобувач представив результати дослідження гібридних нейронних мереж для класифікації медичних зображень та провів порівняльний аналіз з класичними підходами; Стіренко С. брав участь у постановці задачі та обговоренні результатів дослідження; Гордієнко Ю. здійснив наукове керівництво та визначив напрям порівняльного аналізу гібридних і класичних підходів.

2. **Khmelnyskyi, A.**, Gordienko, Y., Trochun, Y., Taran, V., Stirenko, S. HNN-QCn: Hybrid Neural Network with Multiple Backbones and Quantum Transformation as Data Augmentation Technique. *AI* 2025, 6, 36. <https://doi.org/10.3390/ai6020036> ISSN 2673-2688.

Здобувач розробив концепцію та архітектуру HNN-QCn, спроектував сімейство гібридних моделей з масштабуванням квантово-трансформованих каналів, провів порівняльні експерименти та сформулював основні висновки; Гордієнко Ю. здійснив загальне наукове керівництво дослідженням, визначив пріоритетні напрями розвитку гібридних квантово-класичних архітектур та верифікував коректність отриманих результатів і висновків; Стіренко С. брав участь у постановці наукової задачі та обговоренні методології експериментальних досліджень; Таран В. надав консультації щодо організації обчислювальних експериментів

та обробки результатів; Трочун Я. брав участь в обговоренні архітектурних рішень та аналізі продуктивності моделей.

3. **Khmelnyskyi, A.**, Gordienko, Y., Stirenko, S. Impact of Scaling Classic Component on Performance of Hybrid Multi-Backbone Quantum–Classic Neural Networks for Medical Applications. *Computation* 2025, 13, 278. <https://doi.org/10.3390/computation13120278> ISSN 2079-3197.

Здобувач дослідив вплив масштабування класичної компоненти на якість гібридних моделей, реалізував конвеєрний потік оцінювання на медичних наборах MedMNIST та сформулював практичні рекомендації; Гордієнко Ю. здійснив наукове керівництво, сформулював напрям дослідження впливу масштабування класичної компоненти та верифікував практичні рекомендації; Стіренко С. брав участь в обговоренні методики оцінювання на наборах MedMNIST та критичному аналізі отриманих результатів.

4. Gordienko, Y., **Khmelnyskyi, A.**, Taran, V., Stirenko, S. (2025). Hybrid Neural Networks with Multi-channel Quantvolutional Input for Medical Image Classification. In: Lanka, S., Cabezuelo, A.S., Vuppalapati, C. (eds) Trends in Sustainable Computing and Machine Intelligence. ICTSM 2024. Algorithms for Intelligent Systems. Springer, Singapore. https://doi.org/10.1007/978-981-96-1452-3_15 ISSN 2524-7565.

Внесок здобувача: здобувач розробив та верифікував метод мультиканального квантового препроцесингу для класифікації медичних зображень та представив результати на міжнародній конференції; Гордієнко Ю. здійснив наукове керівництво та сформулював напрям розроблення методу мультиканального квантового препроцесингу; Таран В. надав консультації щодо реалізації та верифікації методу; Стіренко С. брав участь в обговоренні й критичному аналізі результатів.

5. **Khmelnyskyi, A** and Gordienko, Y., “Comparative analysis of LCNet050 and MobileNetV3 architectures in hybrid quantum–classical neural networks for image classification”, *Inf. Comput. and Intell. syst. j.*, no. 7,

pp. 49–60, Dec. 2025. <https://doi.org/10.20535/2786-8729.7.2025.333887> ISSN 2786-8729

Внесок здобувача: здобувач провів порівняльний аналіз архітектур класичних основ у гібридних квантово-класичних мережах та обґрунтував критерії вибору оптимальної архітектури; Гордієнко Ю. здійснив наукове керівництво, визначив критерії порівняння архітектур класичних основ та верифікував обґрунтування вибору оптимальної архітектури.

ЗМІСТ

АНОТАЦІЯ	2
ABSTRACT	6
СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА	10
Перелік умовних позначень.....	15
Вступ.....	17
Розділ 1 квантові обчислення та інструменти штучного інтелекту	24
1.1. Квантові обчислення	24
1.1.1. Стан квантового апаратного забезпечення на сьогодні.....	25
1.1.2. Застосування квантових обчислень на практиці	27
1.2. Гібриди квантових та класичних нейронних мереж	30
1.3. Використання квантових комп'ютерів на сьогодні	32
Висновки до розділу 1.....	36
Розділ 2 Особливості класичних та некласичних обчислень для гібридизації 38	
2.1. Вибір задачі.....	38
2.2. Вибір набору даних для експериментів.....	39
2.2.1. Набір даних CIFAR-10	41
2.2.2. Набір даних MedMNIST.....	43
2.3. Вибір показників ефективності та метрик оцінювання для експериментальних досліджень	49
2.4. Аналіз доступних архітектур квантових пристроїв	52
2.5. Вибір програмних засобів та середовища розроблення	62
Висновки до розділу 2.....	65
Розділ 3 КОМПЛЕКСНИЙ СПОСІБ побудови квантово-класичних нейронних гібридних мереж.....	66
3.1. Вибір алгоритмів для побудови архітектур квантово-класичних гібридних нейронних мереж.....	66
3.2. Квантовий шар як прихований елемент нейронної мережі.....	67
3.3. Попереднє квантове опрацювання зображень	70

3.4. Використання квантового пристрою як першого згорткового шару гібридної нейронної мережі.....	75
3.5. Багатоструктурна класична складов квантово-згорткової гібридної нейронної мережі.....	79
3.6. Комплексний спосіб поєднання квантових та класичних обчислень у задачах штучного інтелекту	82
Висновки до розділу 3.....	85
Розділ 4 Аналіз результатів способів використання класичних та квантових обчислень у побудові гібридних нейронних мереж	87
4.1. Аналіз експериментів із базовими гібридними нейронними мережами	87
4.2. Аналіз експериментів із багатоканальною кванволюцією	92
4.3. Аналіз експериментів із масштабуванням архітектури HNN-QCN.	99
4.4. Аналіз експериментів із впливу вибору класичної частини мережі	106
4.5. Аналіз експериментів із багатоканальною класичною гібридною архітектурою HNN	109
Висновки до розділу 4.....	118
Висновки	121
Список використаних джерел	124
Додаток А.....	133

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ

AUC – Area Under the Curve

AWS – Amazon Web Services

CIFAR-10 – Canadian Institute For Advanced Research dataset, 10 classes

CNN – Convolutional Neural Network

CNOT – Controlled NOT gate

CV – Cross-Validation

DA – Data Augmentation

BloodMNIST – Blood cell microscopy subset of MedMNIST

DermaMNIST – Dermatoscopy subset of MedMNIST

PathMNIST – Pathology subset of MedMNIST

FCNN – Fully Connected Neural Network

GPU – Graphics Processing Unit

GPT – Generative Pre-trained Transformer

HNN – Hybrid Neural Network

HNN-QCn – Hybrid Neural Network with n Quantum Channels

LLM – Large Language Model

MedMNIST – Medical MNIST benchmark dataset

MNIST – Modified National Institute of Standards and Technology database

MV – Majority Voting

NN – Neural Network

OoCV – Out-of-Cross-Validation

OoF – Out-of-Fold

QAOA – Quantum Approximate Optimization Algorithm

QC – Quantum Circuit

QFT – Quantum Fourier Transform

QNN – Quantum Neural Network

RGB – Red Green Blue

ROC – Receiver Operating Characteristic

SOTA – State of the Art

SWAP – SWAP gate

TPU – Tensor Processing Unit

VGG – Visual Geometry Group

VQC – Variational Quantum Circuit

WSI – Whole Slide Image

ІІІ – Штучний Інтелект

ВСТУП

Актуальність теми. Стрімкий розвиток квантових обчислень у поєднанні з методами глибинного навчання формує нову наукову галузь — квантове машинне навчання, що відкриває перспективи для створення моделей із підвищеною виразністю та здатністю до узагальнення. Варіаційні квантові схеми (Variational Quantum Circuit - VQC), які можуть параметризовано опрацьовувати інформацію у гільбертовому просторі експоненційної розмірності, становлять особливий інтерес як потенційні компоненти гібридних квантово-класичних нейронних мереж. Хоча сучасні квантові процесори обмежені шумами та кількістю кубітів, саме їхні унікальні властивості дають можливість розробляти нові архітектури, здатні долати недоліки класичних моделей, зокрема нестабільність, чутливість до дисбалансу та труднощі масштабування.

Проблема полягає у відсутності формалізованих принципів інтеграції квантових перетворень у структури класичних нейронних мереж. Наявні підходи базуються переважно на емпіричних налаштуваннях, без чіткого опису того, як параметризовані квантові операції впливають на стабільність, відтворюваність, продуктивність та поведінку моделей на даних різної складності. Ситуація ускладнюється тим, що медичні набори даних — такі як DermaMNIST — є високоваріативними, містять значний дисбаланс класів та демонструють чутливість до перенавчання, що вимагає пошуку більш стійких архітектур.

У цьому контексті актуальним є завдання розробити формальний комплексний спосіб трансформації класичних нейронних мереж у гібридні квантово-класичні, забезпечити узгодженість квантових і класичних компонент та виявити закономірності, що визначають ефективність і стійкість таких систем. Потреба в такому комплексному способі визначається як сучасним станом розвитку квантових технологій, так і прикладними вимогами до моделей високої надійності.

Мета і завдання дослідження. Мета дослідження полягає у підвищенні ефективності та стабільності програмних систем класифікації зображень шляхом

розробки технології трансформації нейронних мереж у гібридні квантово-класичні архітектури, придатні для використання в контексті некласичних обчислень.

Для досягнення поставленої мети сформульовано такі завдання:

- Проаналізувати сучасні методи квантового та гібридного глибинного навчання.
- Дослідити можливості використання квантових симуляторів у задачах обробки зображень.
- Розробити метод трансформації нейронних мереж на архітектурному, функціональному та реалізаційному рівнях.
- Запропонувати конфігурації гібридних квантово-класичних моделей із використанням квантової згортки (кван-волюції - *quanvolution*) як квантового препроцесингу.
- Експериментально оцінити ефективність гібридних моделей у порівнянні з класичними на CIFAR-10 та медичних наборах даних MedMNIST.
- Проаналізувати вплив кількості квантових каналів і масштабу класичної основи на якість класифікації та стабільність результатів.

Об'єкт дослідження – процеси розроблення програмного забезпечення інтелектуальних систем класифікації зображень на основі гібридних квантово-класичних нейронних мереж.

Предмет дослідження – технології та методи трансформації класичних нейронних мереж як компонент програмного забезпечення для їх адаптації та ефективного використання в некласичних (квантових) обчислювальних середовищах.

Методи дослідження. Методичну основу дисертаційного дослідження складають аналіз і узагальнення сучасних підходів квантового та гібридного машинного навчання, на яких ґрунтується побудова гібридних квантово-класичних моделей. Для розроблення та навчання моделей застосовано методи машинного навчання й передавального навчання (*transfer learning*), а також

техніки попередньої обробки даних і формування багатоканальних представлень вхідних зображень. Оцінювання якості та стабільності моделей здійснено за допомогою стратифікованої перехресної перевірки, позафолдового прогнозування (Out-of-Fold) і метрик якості класифікації (точність, AUC). Для підвищення відтворюваності та узагальнювальної здатності прогнозів використано ансамблювання моделей методом м'якого мажоритарного голосування (Soft Majority Voting), а реалізацію кванволюційних (quanvolution) перетворень виконано засобами квантових симуляторів.

Наукова новизна отриманих результатів:

- Вперше запропоновано комплексний спосіб побудови гібридних квантово-класичних нейронних мереж як компонентів програмного забезпечення інтелектуальних систем класифікації зображень, який, на відміну від наявних підходів, де квантова компонента інтегрується лише в одну фіксовану класичну архітектуру, забезпечує системну трансформацію нейронних мереж на трьох взаємопов'язаних рівнях — *архітектурному* (паралельна структура з кількох класичних згорткових мереж-бекбонів), *функціональному* (формування множини квантово-індукованих вхідних каналів засобами квантової згортки — quanvolution) та *реалізаційному* (стандартизований протокол навчання й оцінювання, що забезпечує відтворюване порівняння гібридних і класичних архітектур), що дозволяє підвищити якість, надійність та узагальнювальну здатність моделей у завданнях класифікації.
- Набув подальшого розвитку метод квантового препроцесингу зображень на основі квантової згортки (quanvolution), який, на відміну від відомих реалізацій з одним типом квантового перетворення, передбачає паралельне застосування кількох однокубітних обертань (RY, RX, RXY) для формування множини додаткових вхідних каналів, завдяки чому квантово-індуковані ознаки виконують роль регуляризатора та підвищують стабільність і відтворюваність прогнозів гібридної моделі.

- Вперше сформульовано критерій доцільності застосування квантового препроцесингу у програмному забезпеченні гібридних інтелектуальних систем залежно від масштабу класичної компоненти, який, на відміну від поширеної практики емпіричного добору архітектури, встановлює умови ефективної гібридизації: для компактних і середніх класичних компонент (на прикладі LCNet050–LCNet075) гібридизація забезпечує підвищення показників якості програмного забезпечення, тоді як для великих компонент цей ефект суттєво зменшується; критерій обґрунтовано експериментально на наборах даних CIFAR-10 та MedMNIST.
- Вперше розроблено та апробовано стандартизований протокол експериментального оцінювання гібридних квантово-класичних нейронних мереж, що поєднує стратифіковану k-блокову перехресну перевірку, прогнозування на позатренувальних блоках (Out-of-Fold) і статистичний аналіз стабільності метрик (точності та макро-усередненої площі під ROC-кривою — AUC_macro), і, на відміну від поширених практик, забезпечує коректне та відтворюване порівняння гібридних і класичних архітектур незалежно від типу класичної згорткової нейронної мережі.

Практичне значення отриманих результатів. Практичне значення отриманих результатів полягає у створенні формалізованого методу трансформації класичних нейронних мереж у гібридні квантово-класичні архітектури, що забезпечує стабільнішу та точнішу роботу моделей на даних зі складною структурою та високою варіативністю. Запропоновані квантові препроцесори QC4 та QC5 можуть бути безпосередньо інтегровані у класичні CNN-архітектури, підвищуючи їхню стійкість до перенавчання та покращуючи результати класифікації у медичних задачах, біометричних системах та індустріальному контролі якості.

Отримані у дисертації закономірності поведінки гібридних моделей дають змогу обґрунтовано вибирати архітектурні параметри для практичних

застосувань, визначати доцільність використання квантового препроцесора залежно від масштабу класичної мережі та прогнозувати ефективність гібридизації для різних типів даних. Рекомендації щодо побудови квантово-класичних моделей, структур VQC та способів комбінування квантових і класичних компонент можуть використовуватися при розробленні прикладних інтелектуальних систем, зменшуючи потребу в експериментальному переборі та прискорюючи проектування моделей.

Крім того, запропонована експериментальна методика оцінювання — включно з аналізом стабільності, міжфолдної варіативності та статистично значущих покращень — може бути використана як стандартизований інструментарій для валідації гібридних моделей у наукових і промислових проектах. Результати дослідження створюють підґрунтя для подальшого впровадження некласичних обчислювальних компонентів у практичні системи штучного інтелекту та для адаптації таких методів до майбутніх квантових процесорів.

Особистий внесок здобувача. Дисертація є результатом самостійних наукових досліджень здобувача, у межах яких розроблено та експериментально обґрунтовано спосіб системної трансформації класичних нейронних мереж у гібридні квантово-класичні архітектури шляхом інтеграції параметризованого квантового препроцесингу (quanvolution) і формування багатоканальних подань вхідних даних. Основні результати, наукові положення та висновки дисертаційної роботи отримані здобувачем самостійно в процесі виконання науково-дослідної роботи, зокрема: сформульовано концепцію та принципи системної трансформації нейронних мереж на архітектурному, методичному та функціональному рівнях; спроектовано сімейство гібридних моделей типу HNN-QCn із масштабуванням кількості квантово-трансформованих каналів і варіантів квантових перетворень; реалізовано програмні компоненти для генерації квантово-індукованих ознак і інтеграції їх у класичні бекбони; розроблено та верифіковано стандартизований конвеєрний потік робочих операцій оцінювання гібридних моделей із застосуванням стратифікованої перехресної валідації та позафолдового прогнозування, що забезпечує відтворюване порівняння

гібридних і класичних архітектур на еталонному наборі даних загального призначення CIFAR-10 та прикладних спеціалізованих медичних наборах даних MedMNIST (BloodMNIST, PathMNIST, DermaMNIST) із використанням метрик точності та площі під кривою.

У роботах, опублікованих у співавторстві, здобувачеві належить: **[1,6]** постановка задачі та обґрунтування підходу системної трансформації класичних нейронних мереж через квантовий препроцесинг, визначення факторів експериментального аналізу (тип квантових перетворень, кількість квантових каналів, рецептивне поле, тип/масштаб класичної основи); **[2]** розроблення, програмна реалізація та валідація квантово-згорткового препроцесингу (quanvolution) як механізму формування додаткових квантово-індукованих ознак і багатоканальних вхідних подань; **[3]** проєктування та реалізація архітектур сімейства HNN-QCn, включно з масштабуванням кількості квантових каналів і варіантів квантових перетворень, а також інтеграцією з різними класичними бекбонами (зокрема LCNet і MobileNet); **[4]** побудова та впровадження стандартизованого потоку робочих операцій, експериментальної оцінки гібридних квантово-класичних моделей (стратифікована k-fold перевірка, Out-of-Fold прогнозування, аналіз середніх значень і стандартних відхилень метрик), підготовка експериментів та аналіз статистичної стабільності; **[5]** проведення порівняльного аналізу ефективності гібридизації залежно від типу й масштабу класичної основи та формування практичних рекомендацій щодо вибору компактних і середніх архітектур як найбільш чутливих до покращення від квантового препроцесингу; узагальнення результатів, підготовка висновків і формування наукових положень щодо доцільності застосування квантово-індукованих ознак як регуляризатора, що підвищує стабільність і відтворюваність оцінок у медичних задачах класифікації; підготовка і проведення експериментів на еталонному наборі даних загального призначення CIFAR-10 та прикладних спеціалізованих медичних наборах даних MedMNIST (BloodMNIST, PathMNIST, DermaMNIST), інтерпретація отриманих результатів і їх представлення у публікаціях.

Апробація результатів дисертації. Основні результати дисертаційного дослідження були представлені, обговорені та опубліковані в матеріалах міжнародних наукових конференцій, а саме на: Proceedings of 4th International Conference on Artificial Intelligence and Smart Energy (2024 p); Trends in Sustainable Computing and Machine Intelligence (Сінгапур, 2024р).

Дисертаційна робота пов'язана з науковими розробками, що здійснюються на кафедрі обчислювальної техніки Національного технічного університету України «Київський політехнічний інститут ім. Ігоря Сікорського». Запропоновані у дисертації методи були використані у науково-дослідних роботах:

- Національного фонду досліджень України (НДФУ), грант 2022.01/0199,
- Національного фонду досліджень України (НДФУ), грант 2025.06/0100,
- Міністерства освіти і науки України (МОНУ), грант 2715r,
- в рамках ініціативи IMPRESS-U, грант № STCU-7125, за підтримки Національної академії наук США (US National Academy of Sciences - US NAS) та Управлінням військово-морських досліджень (Office of Naval Research Global - ONRG).

Публікації. За результатами дослідження опубліковано 5 наукових статей, що індексовані до наукометричних баз даних з міжнародним індексом цитування: Scopus – 2, Фахове наукове видання України категорії Б – 1, з яких дві статті у виданнях, що відносяться до першого та другого квартилю(Q1, Q2): одна у *AI* (ISSN 26732688, Q1), а друга — у *Computation* (ISSN 20793197, Q2).

Структура та обсяг роботи. Дисертаційна робота складається зі вступу, чотирьох розділів, загальних висновків, списку використаних джерел із 87 найменувань та додатків. Загальний обсяг дисертації становить 133 сторінки, з яких 107 сторінок основного тексту, 2 додатки на 18 сторінках. Дисертація містить 30 рисунків, 10 формул та 14 таблиць.

РОЗДІЛ 1

КВАНТОВІ ОБЧИСЛЕННЯ ТА ІНСТРУМЕНТИ ШТУЧНОГО ІНТЕЛЕКТУ

1.1. Квантові обчислення

Квантові обчислення становлять один із найперспективніших напрямів розвитку сучасної інформатики, оскільки базуються на принципах квантової механіки, що суттєво розширює можливості обчислювальних систем. Завдяки залученню квантових ефектів, зокрема суперпозиції та квантової інтерференції, квантові обчислювальні пристрої здатні розв'язувати деякі задачі значно швидше, ніж це можливо на класичних комп'ютерах. Ба більше, існують категорії задач, які вважаються принципово нерозв'язуваними в рамках традиційної обчислювальної парадигми, але можуть бути оброблені квантовими алгоритмами [1, 2].

Фундаментальним елементом квантових обчислень є квантовий біт, або кубіт. На відміну від класичного біта, який у будь-який момент часу може перебувати лише в одному з двох дискретних станів — логічному нулі або одиниці, кубіт одночасно перебуває в комбінації обох станів завдяки явищу суперпозиції [3]. Цей стан описується комплексними коефіцієнтами, які визначають ймовірність отримання кожного з можливих результатів під час вимірювання. Зокрема, результат вимірювання кубіта не є фіксованим значенням 0 або 1, а задається ймовірнісним розподілом, у якому отримане значення визначається як випадкова величина в межах $[0; 1]$.

Квантові операції, які застосовуються до кубітів, не лише змінюють їхній стан, але й дозволяють за допомогою конструктивної або деструктивної інтерференції контролювати ймовірності результатів. Такий підхід уможливорює цілеспрямовану модифікацію ймовірнісного простору з метою досягнення більшої точності або ефективності в обчисленнях.

На сьогодні розроблено низку квантових алгоритмів, які демонструють значні переваги над класичними, зокрема алгоритм Шора для факторизації цілих

чисел, алгоритм Гровера для пошуку в неструктурованих базах даних та інші. Всі ці алгоритми використовують специфічні властивості квантових систем, що відкриває нові горизонти для обробки інформації, моделювання складних фізичних процесів та вирішення задач, які раніше вважалися практично недосяжними.

1.1.1. Стан квантового апаратного забезпечення на сьогодні

Сучасний етап розвитку квантових технологій характеризується значними труднощами у створенні стабільних та якісних кубітів. Визначальним чинником у цьому процесі є їх ефективна ізоляція від зовнішніх впливів, оскільки взаємодія із середовищем спричиняє шумові спотворення та погіршує точність результатів обчислень.

На сучасному етапі розвитку квантових технологій одним із ключових викликів залишається виготовлення надійних та довготривало стабільних кубітів. Цей процес супроводжується численними технологічними труднощами, зокрема пов'язаними з необхідністю забезпечення максимально можливої ізоляції кубіта від впливів навколишнього середовища. У разі недостатньої ізоляції квантовий стан кубіта може бути легко порушений зовнішніми шумами або взаємодіями, що призводить до деградації когерентності та, відповідно, спотворення результатів обчислень.

Наукова спільнота приділяє значну увагу розробці нових підходів до конструювання кубітів, які були б менш чутливими до декогеренції та характеризувалися б нижчим рівнем помилок. Серед основних цілей досліджень — досягнення тривалого перебування кубіта у когерентному стані, що дозволить реалізовувати обчислення, які потребують великої кількості квантових операцій, і, як наслідок, відкриє шлях до створення універсальних квантових комп'ютерів загального призначення [7,10].

Одним з найбільш перспективних напрямів у сфері апаратної реалізації кубітів є використання так званих іонних пасток. У цьому підході квантові біти

реалізуються на основі окремих іонів, які фіксуються в просторі за допомогою спеціально сформованого електромагнітного поля [11]. Така архітектура забезпечує високу точність контролю над станами кубітів і є відносно стійкою до деяких видів шуму. Експериментальні досягнення у цій галузі підтверджують, що із застосуванням сучасних технологій можливо сконструювати квантову систему на 32 кубіти, побудовану саме за допомогою іонних пасток [12].

Ще одним надзвичайно потужним і активно досліджуваним методом створення кубітів є технологія, що базується на використанні надпровідних матеріалів [13]. Надпровідники вирізняються тим, що за дуже низьких температур опір у них зникає майже повністю, що дозволяє досягти мінімізації втрат енергії та підвищити точність керування квантовими станами. Найчастіше для створення надпровідних кубітів використовуються такі метали, як тантал і ніобій [14]. Цю технологію активно впроваджують провідні компанії індустрії високих технологій, серед яких Google, IBM, Intel, Rigetti та інші. У більшості сучасних квантових процесорів — QPU (Quantum Processing Units) — застосовуються саме надпровідні кубіти. Наразі наймасштабніший надпровідний квантовий процесор складається з 53 кубітів, що стало значним досягненням у розвитку цієї технології [15].

Водночас головним бар'єром на шляху до створення повноцінних квантових комп'ютерів залишається проблема відсутності ефективної та швидкодіючої системи квантової корекції помилок [16, 17]. Подібна система є надзвичайно важливою, оскільки дозволяє компенсувати вплив декогеренції та інших джерел шуму, які неминуче виникають у процесі виконання обчислень, що перевищують за тривалістю когерентний час кубітів [8,9,18].

Механізм квантової корекції помилок має не лише виявляти й виправляти помилки, але й робити це з такою швидкістю, щоб залишатися ефективним у порівнянні з темпом деградації квантового стану. Важливо зауважити, що сама реалізація цього алгоритму вимагає додаткового квантового апаратного забезпечення, що, у свою чергу, суттєво збільшує загальні ресурси системи. Наприклад, для ефективної роботи такого механізму може знадобитися використання сотень фізичних кубітів для захисту одного логічного кубіта, що

суттєво ускладнює масштабування системи. Таким чином, розробка високопродуктивних і водночас практично реалізованих механізмів квантової корекції помилок залишається однією з ключових перешкод на шляху до повноцінної реалізації багатоцільових квантових обчислювальних систем [19].

1.1.2. Застосування квантових обчислень на практиці

На сьогодні квантові комп'ютери залишаються переважно об'єктом наукових досліджень і демонструють себе більше як теоретичний концепт, ніж як повноцінний інструмент для повсякденного практичного використання. Апаратне забезпечення для квантових обчислень усе ще має численні технологічні обмеження та нерозв'язані інженерні задачі. Тому ця сфера вважається такою, що перебуває на ранніх етапах становлення. Проте, попри існуючі труднощі, уже зараз квантові технології знаходять прикладне застосування для розв'язання окремих, вузькоспеціалізованих задач, де класичні методи або виявляються неефективними, або взагалі непридатними.

Станом на сьогодні квантові обчислювальні системи розглядаються не як універсальні пристрої загального призначення, а радше як високоспеціалізовані прискорювачі, що реалізують обчислення для задач, тісно пов'язаних із квантовою природою самих явищ. Найпоширенішою сферою практичного використання квантових обчислень є симуляція квантових процесів, яка має як фундаментальне, так і прикладне значення у фізиці, хімії, матеріалознавстві та біомедичних дослідженнях [20].

Зокрема, квантові симуляції широко використовуються у фармакології та біохімії. Яскравим прикладом такого застосування є дослідження Джошуа Гоінгса, яке було опубліковане у 2022 році, де було продемонстровано потенційні можливості квантових обчислень у вивченні ферменту cytochrome P450 [21]. Цей ензим бере участь у метаболізмі близько 70% усіх фармацевтичних препаратів. Оскільки функціонування даного ферменту підпорядковується квантовим законам, його точна симуляція на класичних

комп'ютерах є надзвичайно складною або навіть недосяжною. У свою чергу, квантові комп'ютери надають інструментарій для детального аналізу подібних процесів.

Ще одним напрямом активних досліджень на перетині квантових обчислень і медицини є використання квантових моделей для аналізу медичних зображень та побудови діагностичних систем нового покоління. Зокрема, у галузі медичної візуалізації досліджуються можливості застосування гібридних квантово-класичних нейронних мереж для класифікації зображень, отриманих за допомогою методів оптичної когерентної томографії, магнітно-резонансної томографії та інших неінвазивних способів діагностики. Такі моделі дають змогу виконувати швидке виявлення патологічних змін навіть за умов обмеженого обсягу навчальних даних, що особливо важливо в медичних задачах, де доступ до розмічених зображень є обмеженим.

Крім того, квантові алгоритми розглядаються як потенційний інструмент для вирішення обернених задач біофізики — зокрема, реконструкції внутрішніх структур тканин за непрямыми вимірюваннями. Завдяки своїй здатності працювати у багатовимірних просторах станів та ефективно знаходити оптимальні конфігурації, варіаційні квантові алгоритми (Variational Quantum Algorithm - VQA) можуть застосовуватись для моделювання фізіологічних процесів та взаємодій біомолекул на рівні, недосяжному для класичних методів. Це відкриває нові можливості у сфері персоналізованої медицини, зокрема в плануванні індивідуального лікування на основі квантово змодельованої реакції організму на певні лікарські препарати.

Також зростає інтерес до застосування квантових методів у геноміці, де обчислювальні задачі, пов'язані з аналізом великомасштабних біологічних послідовностей, часто є NP-складними. Наприклад, пошук оптимальних шляхів вирівнювання ДНК-послідовностей або класифікація мутацій за клінічним значенням — це задачі, що потенційно можуть бути прискорені завдяки квантовим підходам. У майбутньому це може сприяти значному підвищенню ефективності біоінформатичних систем для ранньої діагностики спадкових захворювань.

Ще одним перспективним напрямом застосування є моделювання хімічних реакцій, зокрема тих, що мають екологічне або промислове значення. Прикладом може слугувати технологія секвестрації вуглецю — процес, що дозволяє вловлювати вуглекислий газ з атмосфери та перетворювати його в стабільні тверді форми [22]. Для підвищення ефективності цього процесу ведуться активні дослідження з пошуку оптимальних каталізаторів. Проте моделювання відповідних реакцій потребує значної обчислювальної потужності, і саме тут квантові системи можуть запропонувати принципову перевагу, дозволяючи ефективно симулювати взаємодію атомів та молекул з високою точністю.

У сфері агропромисловості також існує великий запит на симуляцію складних молекулярних систем. Однією з найважливіших задач є пошук альтернативи для синтезу аміаку, яка не потребувала б екстремальних умов високих температур і тисків, як це відбувається у випадку процесу Габера-Боша. Ефективне моделювання цього процесу вимагає врахування квантових ефектів, що робить класичні обчислення обмежено корисними. У таких випадках перспективним є підхід, який передбачає використання гібридних квантово-класичних обчислень, де класичний комп'ютер відповідає за загальну структуру задачі, а квантовий — за симуляцію локальних квантових процесів [23].

Квантові симуляції також мають критичне значення для розробки нових матеріалів в енергетиці. Зокрема, у контексті екологічної безпеки дедалі більшої актуальності набуває питання заміни кобальтових катодів у літій-іонних батареях. Добування кобальту має серйозний негативний екологічний і соціальний вплив, зокрема у країнах Африки. Як одна з альтернатив розглядається оксид літію та нікелю, проте він виявляє високу хімічну нестабільність у звичних умовах. За допомогою квантових симуляцій можливо змодельовати атомарну структуру цієї речовини та дослідити її властивості з метою створення стабільнішого аналогічного матеріалу [24]. Це дозволить не лише підвищити ефективність батарей, а й значно зменшити екологічні ризики.

Окрім того, однією з найбільш практичних сфер використання квантових технологій уже сьогодні є квантові сенсори [25]. Вони реалізують один з найперспективніших напрямів застосування квантових явищ у техніці,

забезпечуючи надзвичайно високу точність вимірювань. Сучасні квантові сенсори вже використовуються в таких проєктах, як LIGO — для виявлення гравітаційних хвиль [26, 27]. Також тривають дослідження з розробки квантових сенсорів для інших застосувань — від високоточних методів нейровізуалізації (наприклад, сканування мозкової активності) [28] до створення навігаційних систем нового покоління на основі квантових радарів [29].

Ключовою перевагою квантових сенсорів є здатність безпосередньо оперувати квантовими станами без необхідності повного перетворення інформації в класичну форму. Це означає, що за наявності квантового комп'ютера, який інтегрується з сенсором, можливо реалізувати обробку даних «на льоту» з мінімальними втратами точності та швидкості. Таким чином, квантовий комп'ютер може не лише пришвидшити аналіз результатів вимірювань, а й підвищити точність самої процедури [30].

1.2. Гібриди квантових та класичних нейронних мереж

У сучасному науковому дискурсі квантове машинне навчання та гібридні квантово-класичні нейронні мережі посідають чільне місце серед пріоритетних дослідницьких напрямів у галузі штучного інтелекту. Через те, що технологія квантових обчислень перебуває у зародковому стані, практичне застосування таких моделей поки що обмежене. Більшість досліджень у цій галузі наразі мають переважно теоретичний характер, хоча спостерігається стійке зростання інтересу до створення реальних прикладних рішень, зокрема у високоспеціалізованих галузях.

Однією з таких ключових галузей є медицина — сфера, у якій технології штучного інтелекту потенційно здатні не лише автоматизувати процеси, а й сприяти покращенню діагностики та лікування. У цій сфері вже зафіксовано низку успішних кейсів використання гібридних нейронних мереж. Зокрема, у дослідженні Месута Тоґакара запропоновано метод виявлення патологій сітківки за зображеннями, отриманими методом оптичної когерентної томографії, із

використанням гібридної квантово-класичної архітектури [31]. Це дослідження стало однією з перших практичних демонстрацій ефективності подібних моделей у клінічно важливих задачах.

Схожі результати були отримані й у роботі Р.К. Агал'ї, у якому розглядалося виявлення ревматоїдного артрити на основі термографічних зображень рук пацієнтів [32]. У цьому дослідженні було показано, що гібридні нейронні квантово-класичні мережі здатні забезпечити високу точність класифікації, що робить їх практично придатними для застосування у системах медичної діагностики. Подальші дослідження Уллаха [33] про діагностику ішемічної кардіопатії, а також дослідження Юмін Дона [34], для задачі класифікації новоутворень головного мозку за даними МРТ-сканів, додатково підтверджують ефективність гібридного підходу: у ряді випадків ці моделі перевершували традиційні нейронні мережі за точністю.

Крім медичної галузі, гібридні квантово-класичні підходи виявили свою ефективність і в галузях хімії та біології. У дослідженні, проведеному Грегорі В. Кіро [35], було продемонстровано можливість використання таких моделей для передбачення спорідненості зв'язування білків і лігандів, що є ключовим завданням при розробці нових лікарських препаратів.

У сфері обробки зображень квантові підходи також демонструють значний прогрес. За останні кілька років розроблено низку методів квантового виділення ознак [37], квантової обробки зображень [36], а також квантово-натхненних згорткових нейронних мереж [38]. Останні, хоча й не використовують безпосередньо квантове апаратне забезпечення, інтегрують ідеї з квантової теорії в архітектуру нейронних мереж, зокрема шляхом перенесення обчислень у комплексний простір. Це дозволяє не лише покращити подання вхідних даних, а й досягти більшої ефективності у процесі навчання.

Одним із найбільш перспективних напрямів є розробка гібридних квантово-класичних архітектур [39, 40], де квантова підсистема виконує роль модуля виділення ознак, а класична підсистема займається класифікацією. У деяких реалізаціях таких мереж використовується кодування амплітуди, яке дозволяє зменшити кількість необхідних кубітів у порівнянні з іншими методами

кодування вхідних даних [39]. Також активно вивчаються неглибокі архітектури, що поєднують класичний згортковий вхідний шар із варіаційною квантовою схемою в прихованому шарі. Такий підхід зменшує складність моделі та водночас дозволяє досягти прийняттого рівня точності [40].

Протягом останніх років квантові згорткові нейронні мережі стали об'єктом значної кількості наукових досліджень. Більшість із них стосуються задач класифікації зображень, зокрема рукописних цифр (наприклад, набір даних MNIST) [41, 42] або зображень квітів [43]. Утім, існують і дослідження, які виходять за межі простих задач. Наприклад, у роботі Дебанджана Конара [44] розглядалася задача класифікації зашумлених зображень з набору ImageNet, де було продемонстровано, що гібридна квантово-класична модель може перевершити навіть такі класичні архітектури, як ResNet-18 [45], у завданнях високої складності.

Таким чином, хоча застосування квантового машинного навчання наразі залишається в основному в межах лабораторних досліджень, уже наявні результати засвідчують його потужний потенціал. Гібридні квантово-класичні архітектури демонструють конкурентну точність у ряді складних задач, особливо в медичних, хімічних і біологічних застосуваннях. З огляду на швидкий розвиток квантових технологій, можна очікувати, що подальші дослідження у цьому напрямі сприятимуть трансформації сучасних методів штучного інтелекту, розширюючи їх можливості завдяки включенню квантових принципів.

1.3. Використання квантових комп'ютерів на сьогодні

Незважаючи на динамічний розвиток квантового апаратного забезпечення, практична доступність квантових обчислень на момент виконання цього дослідження все ще залишається обмеженою. Використання квантових ресурсів переважно обмежується доступом через спеціалізовані хмарні платформи, які надають обчислювальні потужності у форматі обмежених або платних сервісів.

У цьому розділі розглядаються найбільш поширені та технологічно розвинуті платформи, що забезпечують доступ до квантових обчислень через хмарну інфраструктуру.

Однією з найвідоміших таких платформ є IBM Quantum [46], яка надає відкритий доступ до обчислень на основі квантового процесора IBM Eagle, що включає 127 кубітів [47]. Користувачі мають можливість безкоштовного використання квантового комп'ютера в межах 10 хвилин на місяць, після чого діє тарифна модель з оплатою \$96 за кожну додаткову хвилину. Програмування квантових задач на цій платформі здійснюється за допомогою відкритої бібліотеки Qiskit [48], яка надає інструменти для створення, симуляції та візуалізації квантових схем (детальніше описано в розділі 2). Проте, на момент проведення цього дослідження, доступ до платформи IBM Quantum для користувачів з території України був обмежений, що суттєво ускладнило проведення експериментів.

Іншим значним гравцем вважається Microsoft Azure Quantum — агрегатор квантових рішень, який об'єднує апаратні ресурси таких компаній, як IonIQ, Pasqal, Quantinuum і Rigetti [49-53]. В якому платформа надає користувачам вибір між різними технологічними підходами до реалізації кубітів (впіймані іони, нейтральні атоми, надпровідники) та кількістю доступних кубітів — від 9 до 100. Наприклад, квантові комп'ютери від IonIQ (25 і 32 кубіти) доступні з оплатою за кількість квантових операцій, із мінімальною ціною \$12. Апаратне забезпечення від Pasqal (100 кубітів) оцінюється в \$3000 за годину обчислень. Рішення від Quantinuum (20 та 56 кубітів) пропонуються за підпискою з ціною в межах \$135,000–185,000 на місяць. У випадку з Rigetti (9 і 84 кубіти) — вартість обчислень становить \$78 за хвилину.

Третя велика платформа — Amazon Braket від Amazon Web Services (AWS) [54]. Подібно до Azure Quantum, AWS Braket є агрегатором, який інтегрує квантове апаратне забезпечення від IonQ, Rigetti, IQM [55] і QuEra [56]. Проте вартісна політика тут орієнтована на оплату за кількість виконаних шотів (shots) — тобто запусків квантової задачі. Так, запуск задачі з 1000 шотів на процесорах IonQ коштує від \$30.3 до \$80.3, на Rigetti — \$1.2, на IQM (20 кубітів,

надпровідники) — \$1.75, а на QuEra (256 кубітів, нейтральні атоми) — \$10.3. За потреби інтенсивного використання можливе погодинне резервування квантових комп'ютерів за ціною \$2500–7000/год.

З огляду на наведені дані можна зробити висновок, що сучасні квантові обчислення є досить дорогими та технологічно обмеженими. Крім того, через квантову природу обчислень, кожна задача потребує багаторазового запуску з метою усереднення результатів — ці запуски називаються шотами (shots). Більша кількість шотів підвищує стабільність результату, але також збільшує і вартість, і загальний час виконання задачі.

Втім, ситуація поступово змінюється. Спостерігається активний розвиток квантового апаратного забезпечення. Наприклад, у 2024 році компанія Google представила процесор Willow, що демонструє здатність до експоненційного зменшення кількості помилок при збільшенні кількості кубітів [57]. У 2022 році IBM створила процесор Osprey із 433 кубітами [58], а вже в 2023 — Condor, який містить 1121 кубіт [59]. Ці досягнення свідчать про стійке зростання обчислювальної потужності квантових процесорів. Окрім цього, компанії Google та IBM представили стратегічні плани щодо розвитку квантових технологій на період до 2030-х років [60, 61].

Зважаючи на високу вартість квантового обладнання, для попереднього тестування гіпотез або проведення досліджень у межах обмеженого бюджету часто використовуються квантові симулятори — програмні рішення, які імітують роботу квантових комп'ютерів на класичному апаратному забезпеченні. Бібліотеки Qiskit [48] та PennyLane [62], що поширюються з відкритим програмним кодом, надають можливість створювати й тестувати квантові схеми без необхідності фізичного доступу до квантового комп'ютера. Однак головним обмеженням симуляторів є висока обчислювальна складність, що обумовлює їхню повільність і ресурсомісткість при моделюванні складних квантових систем.

Варто зазначити, що на відміну від апаратного прогресу, програмна частина квантових обчислень — зокрема алгоритмічні рішення та методи інтеграції з класичними моделями — розвивається значно повільніше. Це

створює нагальну потребу у дослідженні нових методів гібридизації квантових та класичних обчислень, зокрема для задач штучного інтелекту, де потенціал квантових підходів може стати ключовим чинником підвищення ефективності та точності.

ВИСНОВКИ ДО РОЗДІЛУ 1

У першому розділі було здійснено комплексний огляд сучасного стану предметної області дослідження, що охоплює два ключові напрями: розвиток квантових обчислень і систем штучного інтелекту (ШІ). Особливу увагу було приділено аналізу сучасного стану квантового апаратного забезпечення, зокрема проблемам, які виникають у процесі виготовлення та експлуатації кубітів, таким як нестабільність когерентного стану, висока чутливість до зовнішніх впливів та складність масштабування квантових процесорів. Окреслено також переваги квантових обчислень, які відкривають нові можливості у вирішенні задач, що є або принципово недосяжними, або надмірно ресурсоємними для класичних обчислювальних систем.

Другим важливим вектором аналізу став огляд сучасного стану систем штучного інтелекту. У межах цього огляду було розглянуто ключові тенденції розвитку квантових обчислень і систем ШІ та його інтеграцію в різноманітні сфери сучасного суспільства. Разом із тим було виокремлено низку викликів, притаманних сучасним моделям глибокого навчання, таких як зростання обчислювальної складності, енергозатратність, а також поступове ускладнення архітектур, що зумовлює дедалі більші вимоги до апаратного забезпечення.

В умовах цих викликів гібридизація класичних та квантових обчислень постає як перспективний підхід, що дозволяє поєднати обчислювальну потужність класичних нейронних мереж з перевагами квантової обробки інформації. Завдяки здатності квантових комп'ютерів до реалізації окремих обчислювальних задач експоненційно швидше та з меншою енерговитратністю, інтеграція таких пристроїв у структуру систем ШІ дозволяє зменшити навантаження на класичне апаратне забезпечення, знизити загальне енергоспоживання та прискорити виконання окремих обчислювальних компонентів.

Крім того, гібридний підхід дозволяє уникнути одного з основних недоліків квантового обчислювального середовища — його обмеженої надійності та низької масштабованості. Використання квантових елементів лише

для частини задач, що є найбільш обчислювально складними, дає змогу ефективно компенсувати короткий когерентний час (20–100 мікросекунд) та обмежену кількість кубітів у сучасних квантових комп'ютерах (наразі — до 1121 кубіта). Такий підхід дозволяє не лише збільшити обчислювальну ефективність систем ШІ, а й забезпечити гнучке масштабування відповідно до доступного апаратного ресурсу.

Отже, розробка та дослідження методів гібридизації класичних і квантових обчислень є доцільною і своєчасною. Такий підхід дозволяє поєднати найкращі сторони обох технологій, мінімізуючи їх недоліки та відкриваючи шлях до побудови більш ефективних, масштабованих і стійких до збоїв систем штучного інтелекту. Результати огляду підтверджують актуальність і перспективність обраного наукового напрямку.

РОЗДІЛ 2

ОСОБЛИВОСТІ КЛАСИЧНИХ ТА НЕКЛАСИЧНИХ ОБЧИСЛЕНЬ ДЛЯ ГІБРИДИЗАЦІЇ

2.1. Вибір задачі

Сфера штучного інтелекту є надзвичайно багатогранною, охоплюючи широкий спектр задач, які вирішуються за допомогою інтелектуальних обчислювальних систем. Серед великої кількості можливих напрямів застосування ШІ, у межах даного дисертаційного дослідження основну увагу зосереджено на одному з найбільш поширених і добре сформульованих класів задач — класифікації зображень. Цей тип задач традиційно є одним з основоположних у сфері комп'ютерного зору і відіграє ключову роль у багатьох практичних застосуваннях, де використовується штучний інтелект.

Вибір саме задачі класифікації зображень як об'єкта дослідження обумовлений низкою вагомих чинників. Насамперед, це її універсальність: задачі такого типу зустрічаються в найрізноманітніших галузях — від медицини до екологічного моніторингу, від промисловості до безпеки. Багато високорівневих прикладних задач можуть бути формально зведені до класифікації певних типів зображень. Наприклад, у медичній сфері діагностика захворювань на основі візуальних даних може бути реалізована як задача бінарної або багатокласової класифікації медичних зображень. Зокрема, вже згадувана у попередньому розділі задача виявлення ревматоїдного артрити може бути ефективно сформульована як задача класифікації теплових зображень рук пацієнтів [32].

Також прикладом застосування класифікації зображень є оцінка наслідків природних або техногенних катастроф, яка здійснюється шляхом автоматизованого аналізу супутникових знімків постраждалих регіонів. У цьому випадку класифікація зображень може включати як бінарну класифікацію (наявність/відсутність пошкоджень), так і більш складні варіанти сегментації для виявлення зон з різним рівнем руйнувань [63]. Такі приклади підкреслюють високий прикладний потенціал задач класифікації в різних контекстах.

Ще одним важливим аспектом, що обумовив вибір саме цього типу задач, є їх поширеність у системах критичної важливості, які функціонують з великими об'ємами даних. Наприклад, у випадку супутникової аналітики або медичних систем, що обробляють великі масиви зображень, навіть незначне підвищення продуктивності або зменшення затримки може мати суттєве значення для своєчасності прийняття рішень. У цьому контексті залучення квантових обчислень як інструменту прискорення обробки даних є надзвичайно перспективним. Враховуючи обмеженість ресурсів та потребу в оптимізації, гібридні квантово-класичні підходи можуть значно підвищити ефективність таких систем.

Таким чином, покращення продуктивності систем штучного інтелекту для задач класифікації зображень шляхом впровадження методів квантових обчислень є не лише доцільним з технічної точки зору, а й потенційно здатним позитивно вплинути на критично важливі сфери життєдіяльності. Враховуючи стратегічне значення таких застосувань, обраний напрям дослідження має високу прикладну значущість і є актуальним з точки зору як наукового прогресу, так і суспільних потреб.

2.2. Вибір набору даних для експериментів

У межах дисертаційного дослідження, присвяченого гібридизації класичних і квантових обчислень для задач штучного інтелекту, як експериментальну основу було обрано задачу багатокласової класифікації зображень. Для її розв'язання використано кілька наборів даних, які охоплюють як типові дослідницькі сценарії класифікації кольорових зображень, так і більш прикладні випадки практичного використання, у межах яких застосування квантових обчислень може забезпечити додаткові переваги.

Для проведення досліджень і експериментальної перевірки ефективності способів гібридизації квантових та класичних обчислень у задачах штучного інтелекту в межах даної дисертаційної роботи було обрано мультикласову

класифікацію зображень. Такий вибір дозволяє охопити широкий спектр прикладних сценаріїв використання систем глибокого навчання, а також забезпечити можливість комплексної оцінки ефективності гібридних квантово-класичних нейронних мереж на задачах різного рівня складності.

Для цілей дослідження було сформовано експериментальну вибірку з кількох відкритих наборів даних, що включають як класичні, добре вивчені датасети, які широко застосовуються у науковій спільноті для тестування архітектур глибокого навчання, так і прикладний медичний набір, який репрезентує реальну задачу високої практичної важливості. У таких задачах застосування квантових обчислень є особливо доцільним через потребу у високій точності, швидкодії та можливості обробки великого обсягу візуальних медичних даних.

До класичних експериментальних наборів, обраних для аналізу, належать::

- MNIST [64,65] — один із найвідоміших наборів для класифікації зображень рукописних цифр, що слугує стандартом де-факто для тестування ефективності базових моделей.
- CIFAR10 [67,68] — популярний набір кольорових зображень, розділених на 10 класів, які дозволяють протестувати здатність моделі працювати з різнокольоровими зображеннями високої варіативності.

У якості прикладного набору, що відображає практичне медичне завдання, було обрано датасет MedMNIST — великий набір анонімізованих медичних зображень, орієнтований на задачі навчання з обмеженим обсягом даних і стандартизований для використання в задачах класифікації та сегментації. Цей набір є складовою частиною однойменної колекції [66,70], яка включає декілька піднаборів (наприклад, PathMNIST, OrganMNIST, BloodMNIST тощо), що відображають реальні медичні сценарії — від класифікації зразків тканин до виявлення патологій у зображеннях органів. Набір є цінним ресурсом для апробації квантових методів, оскільки містить складні багатокласові задачі з високою щільністю інформації на зображеннях і водночас має уніфіковану структуру та зручну для експериментів розмітку.

У подальших підрозділах кожен із зазначених наборів буде розглянуто детальніше з поясненням особливостей структури даних та мотивацією їх вибору для проведення дослідження. Такий підхід дозволяє охопити як теоретичні, так і прикладні аспекти задачі класифікації зображень у контексті дослідження потенціалу гібридних квантово-класичних нейронних архітектур.

2.2.1. Набір даних CIFAR-10

Набір даних MNIST є одним із найбільш поширених у галузі комп'ютерного зору. Його часто використовують як базовий етап для оцінювання ефективності різних алгоритмів класифікації зображень.

Набір даних CIFAR-10 є еталонним у галузі машинного навчання, зокрема в задачах класифікації зображень і комп'ютерного зору. Він був створений і опублікований дослідниками Канадського інституту передових досліджень (CIFAR), також зокрема Кріжевським Алексом, Наїром Вінодом та Хінтоном Джеффрі [69], і з того часу широко використовується в наукових дослідженнях для порівняльної оцінки ефективності алгоритмів класифікації, особливо моделей на основі згорткових нейронних мереж.

Набір CIFAR-10 містить 60 000 кольорових зображень у форматі RGB розміром 32×32 пікселі. Зображення поділені на 10 класів, кожен з яких представлений 6 000 прикладами. Датасет структуровано на навчальну вибірку обсягом 50 000 зображень і тестову вибірку з 10 000 зображень, при цьому кожен клас рівномірно представлений у кожній підмножині — 5 000 навчальних та 1 000 тестових зображень відповідно.

Кожен клас відповідає певному реальному об'єкту, зокрема: літак, автомобіль, птах, кішка, олень, собака, жаба, кінь, корабель або вантажівка. Усі зображення мають одну мітку класу, що відповідає задачі однокласової багатокласової класифікації, при цьому класи є взаємовиключними.

Зображення представлені у триканальному 8-бітовому кольоровому просторі RGB, де кожен піксель описується трьома цілими значеннями в

діапазоні 0–255, що відповідають червоному, зеленому та синьому каналам. Використання повнокольорових зображень істотно підвищує складність задачі порівняно з наборами даних у градаціях сірого, зокрема через більшу варіативність візуального контенту та підвищений рівень шуму.

Додатковою складністю набору CIFAR-10 є низька просторова роздільна здатність зображень, що ускладнює виявлення дрібних візуальних деталей і локальних ознак, особливо у випадках, коли міжкласові відмінності є мінімальними (наприклад, між класами «кінь» та «олень»). У межах даного дослідження набір CIFAR-10 використовується як репрезентативний приклад помірно складної задачі багатокласової класифікації реальних об'єктів у повнокольоровому представленні. Приклад зображень із набору CIFAR-10 наведено на рисунку 2.1.




Рисунок 2.1. Приклад зображень набору даних CIFAR-10

2.2.2. Набір даних MedMNIST

Набір даних Fashion-MNIST є складнішою, але за основними характеристиками подібною до оригінального MNIST альтернативою. Його було розроблено як більш реалістичний тестовий набір, що дає змогу оцінювати ефективність алгоритмів класифікації зображень у складніших умовах порівняно з використанням MNIST.

MedMNIST — це стандартизована колекція медичних зображень, спеціально створена для навчання, тестування та оцінювання алгоритмів

машинного навчання в умовах обмежених ресурсів. Колекцію було представлено як відкриту ініціативу, спрямовану на спрощення доступу до медичних даних для дослідників і водночас на забезпечення уніфікованої платформи для порівняння ефективності алгоритмів обробки візуальної медичної інформації. Розробку ініціювала команда дослідників під керівництвом Гуансінга Янга, і вона була представлена у вигляді однойменної статті з відкритим кодом, що отримала визнання в спільноті штучного інтелекту [70].

Колекція MedMNIST містить понад 700 000 зображень із 12 незалежних піднаборів, кожен з яких представляє окрему клінічну задачу: від гістопатології до дерматології, офтальмології та гематології. Всі піднабори зображень мають однаковий формат (28×28 пікселів), що робить їх зручними для використання в системах глибокого навчання та — що особливо важливо для цього дослідження — у квантових або гібридних квантово-класичних нейронних мережах, які мають обмеження на розмір вхідних даних через апаратні обмеження квантових пристроїв.

На відміну від багатьох медичних датасетів, які мають складну структуру, великі розміри зображень та обмежений доступ через регуляторні або етичні бар'єри, MedMNIST забезпечує відкритий, структурований та анонімізований доступ до різних типів візуальних медичних даних, що робить його цінним ресурсом для дослідницьких експериментів. Крім того, він ідеально підходить для апробації нових підходів, зокрема квантових, у безпечному та відтворюваному середовищі.

У межах дисертаційного дослідження особливу увагу було приділено трьом піднаборам колекції MedMNIST: BloodMNIST, PathMNIST та DermaMNIST, які є найбільш репрезентативними з точки зору клінічної цінності, складності задачі та різноманітності візуального контенту.

BloodMNIST — набір зображень мазків крові, отриманих за допомогою мікроскопії. Він містить 17 092 зображення клітин крові, що поділені на 8 класів, які відповідають різним типам клітин, таким як нейтрофіли, еозинофіли, базофіли, моноцити тощо. Дані було зібрано з реальних медичних випадків та професійно розмічено експертами-гематологами. Зображення представлені у

форматі RGB, що дозволяє враховувати колірну диференціацію між типами клітин. Набір даних BloodMNIST є важливим з точки зору практичного застосування, оскільки автоматизація розпізнавання клітин крові є критично важливою для діагностики гематологічних захворювань. Приклад зображень із набору BloodMNIST подано на рисунку 2.2.




Рисунок 2.2. Приклад зображень набору даних BloodMNIST

PathMNIST містить 107 180 зображень гістопатологічних зрізів, отриманих із великого Whole Slide Image (WSI), що охоплює дев'ять типів тканин печінки (нормальні, запалені, фіброзні, пухлинні тощо). Завдання моделі —

класифікувати фрагмент тканини до одного з 9 класів, що робить набір даних багатокласовим і практично орієнтованим. Зображення мають високу варіативність і складну текстуру, що робить цей набір викликом навіть для потужних згорткових мереж. PathMNIST є особливо цінним для досліджень у сфері цифрової патології, оскільки автоматизація обробки гістопатологічних зображень дозволяє підвищити точність і швидкість діагностики онкологічних захворювань. Приклад зображень із набору PathMNIST подано на рисунку 2.3.




Рисунок 2.3. Приклад зображень набору даних PathMNIST

Набір даних PathMNIST містить 107 180 зображень гістопатологічних зрізів, отриманих із великого Whole Slide Image (WSI), що охоплює дев'ять типів тканин печінки (нормальні, запалені, фіброзні, пухлинні тощо). Завдання моделі — класифікувати фрагмент тканини до одного з 9 класів, що робить набір даних багатокласовим і практично орієнтованим. Зображення мають високу варіативність і складну текстуру, що робить цей набір викликом навіть для потужних згорткових мереж. Набір даних PathMNIST є особливо цінним для досліджень у сфері цифрової патології, оскільки автоматизація обробки гістопатологічних зображень дозволяє підвищити точність і швидкість діагностики онкологічних захворювань. Приклад зображень із набору PathMNIST подано на рисунку 2.3

Набір даних DermaMNIST містить 10 015 дерматологічних зображень шкірних уражень, які класифіковані за 7 категоріями, включаючи доброякісні й злоякісні новоутворення. Дані походять із реєстру HAM10000, який широко використовується у клінічних дослідженнях для побудови діагностичних моделей. Зображення мають формат RGB, оскільки колірна структура шкіри є критично важливою для визначення типу ураження. Набір даних DermaMNIST відображає складну та важливу задачу комп'ютеризованої дерматоскопії, де моделі машинного навчання можуть істотно допомогти лікарям у ранньому виявленні меланоми та інших захворювань шкіри. Приклад зображень із набору DermaMNIST подано на рисунку 2.4.




Рисунок 2.4. Приклад зображень набору даних DermaMNIST

Колекція MedMNIST була обрана для цього дослідження не лише завдяки своїй структурованості та відкритості, але й через її особливу відповідність задачам гібридного квантово-класичного навчання. Завдяки компактному розміру вхідних зображень (28×28), ці дані придатні для обробки квантовими схемами без необхідності складних процедур попереднього зменшення розмірності, що дозволяє максимально зберегти інформаційний вміст. Це робить MedMNIST унікальною тестовою платформою для перевірки працездатності квантових компонентів у гібридних моделях.

Також важливо зазначити, що використання медичних даних дозволяє оцінити не лише загальну ефективність моделі, а й її практичну придатність у високоставкових клінічних сценаріях, де точність є критично важливою. В межах даного дослідження ці піднабори було використано для побудови, тренування та тестування гібридних моделей, які містили квантові варіаційні схеми як шар виділення ознак, у поєднанні з класичними шарами для класифікації.

Таким чином, набір даних MedMNIST не лише забезпечив різноманітність задач і даних для моделювання, але й слугував важливим містком між теоретичним апаратом квантових обчислень і практичними вимогами сучасної медичної діагностики, демонструючи потенціал гібридних підходів у реальних умовах.

2.3. Вибір показників ефективності та метрик оцінювання для експериментальних досліджень

Визначення ефективності гібридних нейронних квантово-класичних мереж є одним із ключових етапів експериментального дослідження, оскільки саме на підставі обраних метрик приймається рішення щодо доцільності використання певного підходу у прикладних сценаріях. Зважаючи на специфіку гібридних архітектур, до оцінювання повинні бути залучені як традиційні метрики якості моделей машинного навчання, так і специфічні характеристики, що стосуються обчислювального навантаження на квантову підсистему.

У загальному випадку до основних показників ефективності класифікаційних моделей належать:

- Точність класифікації зображень на тестовому наборі.
- Значення функції втрат для процесу навчання.
- Відсоток помилок під час тестування .
- Швидкість роботи моделі.

- Об'єм обчислень та складність.

Всі обрані метрики є важливими з практичної точки зору, оскільки дозволяють не лише порівнювати моделі між собою, але й визначати можливість їх використання в конкретних умовах — наприклад, у системах реального часу або в середовищах з обмеженими апаратними ресурсами (edge computing). В окремих випадках компроміс між точністю та швидкістю або споживанням ресурсів може виявитися більш прийнятним, ніж абсолютне досягнення state-of-the-art результатів за точністю.

Зважаючи на те, що експерименти в межах дисертаційної роботи проводилися з використанням класичних симуляторів квантових обчислень, точна оцінка реальної швидкодії гібридних моделей була неможливою. Симулятори, зокрема Qiskit та PennyLane, дозволяють відтворити поведінку квантових схем, проте вони не можуть надати достовірної інформації щодо часу виконання на фізичному квантовому апаратному забезпеченні через фундаментальні обмеження класичних комп'ютерів. У зв'язку з цим метрика швидкодії моделі залишилася поза межами дослідження та є об'єктом для подальших робіт.

Водночас, через акцент на залученні квантових обчислень, до набору метрик було включено два специфічні показники, що відображають квантову складову моделі:

- Необхідний об'єм квантових обчислень для підготовки моделі.
- Необхідний об'єм обчислень при використанні моделі.

Ці показники мають критичне значення в умовах актуального квантового апаратного забезпечення, оскільки дозволяють оцінити ресурсну вартість квантової частини моделі та її практичну придатність для реалізації на наявних пристроях.

У межах дослідження було використано наступні метрики ефективності гібридних моделей:

- Необхідний об'єм квантових обчислень для підготовки моделі.

- Необхідний об'єм обчислень при використанні моделі.
- Значення функції втрат для процесу навчання.
- Відсоток правильних класифікацій під час тестування
- Кількість хибних класифікацій.

Оцінювання точності класифікації моделей здійснювалося із застосуванням двох підходів. Перший підхід є більш простим і безпосереднім та передбачає поділ вихідного набору даних на тренувальну і тестову вибірки, при цьому показником точності вважається частка правильно класифікованих зображень із тестового набору даних. Як другий, більш ґрунтовний підхід до оцінювання якості функціонування моделі було застосовано метод перехресної перевірки (CV) [71]. Сутність цього методу полягає в попередньому об'єднанні тренувального та тестового наборів даних, після чого випадковим чином 20% елементів сформованої сукупності відбираються як тестова вибірка, тоді як решта 80% використовується для навчання моделі. Далі виконується процес навчання моделі та обчислення метрик її роботи. Після цього виконується послідовна зміна тренувальних і тестових підмножин, а вся процедура повторюється до того моменту, поки кожен елемент набору даних не буде використаний і для навчання, і для тестування моделі. Підсумковий результат визначається як середнє значення точності, обчислене за всіма такими ітераціями. Використання перехресної перевірки дає змогу не лише більш об'єктивно оцінити ефективність моделі, а й проаналізувати статистичні характеристики її функціонування, рівень стійкості до змін у даних, а також знизити вплив можливих викривлень результатів, що можуть виникати у випадках, коли тестова вибірка містить відносно простіші або більш придатні для класифікації зображення.

У роботі застосовано ансамблювання моделей методом голосування більшістю (majority voting). Ідея методу полягає в тому, що фінальне рішення формується на основі сукупності прогнозів кількох моделей, що дозволяє зменшити вплив випадкових факторів навчання, локальних мінімумів та

варіативності вибірок при перехресній валідації, а також підвищити відтворюваність результатів.

У даній роботі реалізовано саме soft voting, оскільки він є більш інформативним: агрегуються не лише “жорсткі” рішення моделей, а й ступінь упевненості (ймовірності) для кожного класу. Нехай M — кількість моделей в ансамблі, а $p(m)(x)=[p_1(m), \dots, p_K(m)(x)]$ — вектор імовірностей для K класів, який повертає m -та модель для зображення x . Тоді агрегований прогноз ансамблю обчислюється як:

$$\bar{p}(x) = \frac{1}{M} \sum_{m=1}^M p^m(x) \quad (2.1)$$

а фінальний клас визначається як:

$$\hat{y}(x) = \arg \max_{k \in \{1, \dots, K\}} \bar{p}(x) \quad (2.2)$$

У рамках запропонованого workflow majority voting використовується як один із інструментів підвищення ефективності та стабільності системи класифікації зображень і узгоджується з загальною метою роботи — отримання більш відтворюваних і статистично надійних результатів при порівнянні гібридних квантово-класичних архітектур із відповідними класичними моделями.

2.4. Аналіз доступних архітектур квантових пристроїв

Квантовий пристрій є одним із визначальних структурних елементів гібридної квантово-класичної нейронної мережі та виконує функцію реалізації некласичних обчислювальних перетворень у межах єдиної архітектури моделі. Під квантовим пристроєм, або квантовою схемою, у даній роботі розуміється впорядкований набір кубітів, що перебувають у когерентному квантовому стані,

разом із визначеною послідовністю квантових операцій, які застосовуються до цих кубітів з метою реалізації заданих обчислювальних трансформацій.

Квантова схема у складі гібридної моделі виступає функціональним аналогом шару виділення ознак у класичних нейронних мережах, оскільки забезпечує перетворення вхідної інформації, закодованої у квантових станах, у новий простір ознак. У цьому просторі подальші етапи класифікації або регресійного аналізу можуть здійснюватися більш ефективно за рахунок підвищеної виразності представлення даних, що формується внаслідок квантових перетворень.

Існує широкий спектр елементарних квантових операцій, які можуть бути використані для побудови квантових схем, зокрема однокубітні та двокубітні гейти, параметризовані варіаційні операції, а також специфічні апаратно-залежні гейти, характерні для окремих фізичних реалізацій квантових обчислювальних систем, таких як надпровідникові платформи або іонні пастки. Однак у межах даного дисертаційного дослідження доцільним було зосередитися на обмеженому підмножині найбільш поширених і добре теоретично обґрунтованих квантових операцій, які забезпечують достатню експресивність квантових схем за умови відносної простоти реалізації в симуляційному середовищі та стабільності чисельних експериментів.

У процесі дослідження використано набір базових квантових операцій, що входять до стандартного інструментарію побудови квантових схем і широко застосовуються у квантовому машинному навчанні. Зазначені операції слугували фундаментальними елементами для конструювання параметризованих варіаційних квантових схем, які в межах гібридних нейронних мереж виконували роль квантових шарів попередньої обробки та трансформації даних:

- Операція R_y . Виконує ротацію стану кубіта навколо осі Y на заданий кут θ . Широко використовується у параметризованих схемах, оскільки дозволяє вводити гнучкість у стан кубіта[72]. Можна описати цю операцію наступною формулою:

$$RY(\theta) = \exp\left(-i\frac{\theta}{2}Y\right) = \begin{pmatrix} \cos\left(\frac{\theta}{2}\right) & -\sin\left(\frac{\theta}{2}\right) \\ \sin\left(\frac{\theta}{2}\right) & \cos\left(\frac{\theta}{2}\right) \end{pmatrix} \quad (2.3)$$

- Операція R_x . Здійснює ротацію кубіта на заданий кут « θ » навколо осі X . Застосовується в аналогічних сценаріях до R_y , забезпечуючи іншу вісь обертання та варіативність у конфігурації квантової схеми [73]. Можна описати цю операцію наступною формулою:

$$RX(\theta) = \exp\left(-i\frac{\theta}{2}X\right) = \begin{pmatrix} \cos\left(\frac{\theta}{2}\right) & -i\sin\left(\frac{\theta}{2}\right) \\ -i\sin\left(\frac{\theta}{2}\right) & \cos\left(\frac{\theta}{2}\right) \end{pmatrix} \quad (2.4)$$

- Операція R_z . Ротація стану кубіта навколо осі Z . Є однією з найбільш ефективних з точки зору реалізації на апаратному рівні, оскільки часто виконується з мінімальними похибками [74]. Можна описати цю операцію наступною формулою:

$$RZ(\theta) = \exp\left(-i\frac{\theta}{2}Z\right) = \begin{pmatrix} e^{-i\frac{\theta}{2}} & 0 \\ 0 & e^{i\frac{\theta}{2}} \end{pmatrix} \quad (2.5)$$

- Операція Хадамарда (Hadamard Gate). В цій операції відбувається обертання на кут π навколо осей « X » та « Z » [75]. Перетворює базисні стани $|0\rangle$ та $|1\rangle$ у суперпозицію. Часто використовується для ініціалізації квантової системи в суперпозиційному стані. Можна описати цю операцію наступною формулою:

$$H = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} \quad (2.6)$$

- Операція Паулі [76] X (σ_x), є ротацією кубіта на π радіан навколо осі « X » [77]. Еквівалент класичної операції NOT. Перетворює $|0\rangle$ в $|1\rangle$, а $|1\rangle$ в $|0\rangle$. Операція σ_x описується такою формулою:

$$\sigma_x = RX(\pi) = \begin{pmatrix} 0 & -i \\ -i & 0 \end{pmatrix} = -iX \quad (2.7)$$

- Операція Паулі Y (σ_y), є ротацією кубіта » на π радіан навколо осі «Y» [78]. Виконує інверсію біту та фази. Перетворює $|0\rangle$ в $i|1\rangle$, а $|1\rangle$ в $-i|0\rangle$. Операцію σ_y описується такою формулою:

$$\sigma_y = RY(R) = \begin{pmatrix} 0 & -i \\ i & 0 \end{pmatrix} = -iY \quad (2.8)$$

- Операція Паулі Z (σ_z), є ротацією кубіта на π радіан навколо осі «Z» [79]. Змінює фазу квантового стану. $|0\rangle$ залишається незмінним, а $|1\rangle$ набуває фази -1 . Операцію описується такою формулою:

$$\sigma_z = RZ(R) = \begin{pmatrix} -i & 0 \\ 0 & i \end{pmatrix} = -iZ \quad (2.9)$$

- Операція зміни станів кубітів (SWAP Gate), двокубітна операція, що діє на кубіти «a» та «b» і здійснює взаємний обмін їхніх квантових станів [80, 81]. Формально таке перетворення можна подати у вигляді переходу $|a, b\rangle$ в $|b, a\rangle$.

Квантові схеми, використані в межах цього дослідження, побудовані виключно на основі базових квантових операцій над кубітами. Попри свою простоту, ці елементарні операції дозволяють формувати функціональні та ефективні квантові схеми, які є здатними до виконання складних обчислювальних задач у складі гібридних квантово-класичних моделей.

З огляду на сучасний стан розвитку квантового апаратного забезпечення, особливу увагу було приділено мінімізації кількості залучених кубітів. Усі схеми, реалізовані в рамках експериментів, містили від 2 до 9 кубітів, що дозволило забезпечити прийнятний баланс між виразною здатністю моделі та її практичною реалізовуваністю на сучасних симуляторах квантових обчислень або фізичних пристроях. Частина алгоритмів спроектована спеціально з урахуванням обмежень апаратного рівня, таких як тривалість когерентного стану та обмежена точність фізичних гейтів.

У межах дисертаційного дослідження було застосовано кілька типів квантових схем для реалізації гібридних нейронних мереж, кожна з яких вирізняється своєю структурною специфікою та функціональною роллю.

Одним із найпростіших і базових варіантів квантових пристроїв, що використовувалися в дослідженні, були RY-схеми. Цей тип квантових схем передбачає послідовне застосування двох квантових операцій до кожного з кубітів незалежно:

- Першим елементом є операція Хадамарда, яка переводить кожен кубіт у стан суперпозиції, забезпечуючи повну виразність квантової системи на початку виконання схеми.
- Наступним кроком є параметризована операція обертання навколо осі Y , де параметр є індивідуальним для кожного кубіта. Значення цих параметрів оптимізуються в процесі навчання моделі, подібно до ваг у класичних нейронних мережах.

Після застосування операцій до всіх кубітів відбувається вимірювання кожного з них, що дозволяє отримати класичні значення, які передаються до подальших шарів моделі для класифікації або регресії.

RY-схеми мають низьку обчислювальну складність, добре масштабується та ідеально підходить для задач, де важливо зберігати простоту квантової частини моделі. Приклад квантової схеми типу RY, побудованої для двох кубітів, наведено на Рисунку 2.5.




Рисунок 2.5. Діаграма квантової схеми з 2 RY кубітами

Ще одним типом квантових схем, використаних у межах дисертаційного дослідження, є схеми, що базуються на алгоритмі квантової апроксимації оптимізації (Quantum Approximate Optimization Algorithm, QAOA). Цей підхід є більш складним за структурою, порівняно з базовими RY-схемами, і передбачає багаторівневу побудову із залученням більшої кількості квантових операцій.

Квантові схеми QAOA включають комбінації таких базових операцій:

- RX-гейти — ротації кубітів навколо осі X, параметризовані кутом.
- RZ-гейти — ротації навколо осі Z, що відповідають фазовим зсувам.
- CNOT або CZ (ентанглінгові гейти) — операції, що створюють квантову запутаність між кубітами, які реалізують логічну взаємодію між змінними, тобто накладають обмеження або кореляції.

Кількість застосувань кожного типу гейтів залежить від розмірності схеми (тобто кількості кубітів), а також від глибини квантового циклу (кількості шарів, або «рівнів QAOA»), що визначається як гіперпараметр.

Мотивація використання QAOA-схем полягає у природній відповідності задачі оптимізації, яку вони реалізують. Навчання нейронної мережі — це, по суті, задача пошуку оптимального набору параметрів, які мінімізують функцію втрат або максимізують точність класифікації. Саме таку мету має і алгоритм QAOA: наближене розв'язання задач оптимізації дискретного простору за допомогою квантової еволюції.

Таким чином, QAOA-схеми виступають природною архітектурною основою для варіаційного квантового шару, адаптованого до задач машинного навчання. Їх використання в гібридних нейронних мережах дозволяє ефективно поєднати квантову силу пошуку оптимумів з класичними методами градієнтного оновлення параметрів.

На Рисунку 2.6 зображено приклад квантової схеми QAOA, побудованої для випадку з двома кубітами.




Рисунок 2.6. Діаграма квантової схеми з 2 QAOA кубітами

Ще одним типом квантових схем, що були використані в межах дисертаційного дослідження, є схеми квантового перетворення Фур'є (Quantum Fourier Transform, QFT). На відміну від раніше описаних схем, цей тип не є параметризованим: його структура не містить жодних змінних параметрів, що підлягають оптимізації в процесі навчання. Результат роботи QFT-схеми цілком визначається вхідними квантовими станами.

Квантове перетворення Фур'є є фундаментальною квантовою операцією, що відіграє центральну роль у багатьох квантових алгоритмах, зокрема в алгоритмі Шора. Його суть полягає у перетворенні амплітуд вхідного стану в їх спектральне представлення. На практиці це дозволяє виділяти періодичні структури в даних, які класичними методами визначити значно складніше.

Особливістю квантового перетворення Фур'є є його висока обчислювальна ефективність: реалізація QFT на n кубітах потребує лише елементарних операцій, що значно менше, ніж класичне дискретне перетворення Фур'є. Однак ця схема також дуже чутлива до похибок та шумів, які притаманні сучасним квантовим пристроям. Тому її практичне використання наразі обмежене переважно симуляційним середовищем або лабораторними експериментами.

У межах дисертації QFT-схеми використовувалися як еталонна квантова трансформація, яка могла б виявити приховані закономірності у вхідних векторах ознак до того, як вони надходять до класичних або гібридних частин

моделі. Це дозволяє апіорно покращити представлення даних на основі трансформаційного квантового шару без залучення механізмів оптимізації.

На Рисунку 2.7 подано приклад квантової схеми реалізації перетворення Фур'є для двох кубітів.




Рисунок 2.7. Діаграма з 2 кубітами квантового перетворення Фур'є

Не менш важливим типом перетворенням, що були використані у межах дисертаційного дослідження, є схеми, які реалізують формування квантового стану Белла (Bell State). Стан Белла є одним із найпростіших і водночас найбільш інформативних прикладів квантової запутаності (quantum entanglement) — фундаментального явища квантової механіки, що не має класичних аналогів.

У своїй базовій формі схема створення стану Белла включає застосування Hadamard-гейта до одного кубіта з подальшим застосуванням CNOT-гейта до пари кубітів, що забезпечує створення запутаного стану. Такі стани є невіддільними з точки зору інформаційного представлення: зміна стану одного кубіта автоматично впливає на стан іншого, незалежно від фізичної відстані між ними.

У межах дисертаційного дослідження використано модифіковану версію класичної схеми стану Белла, що доповнена параметризованими RY-гейтами, які застосовуються до кожного кубіта перед або після створення запутаності. Таке розширення дозволяє не лише ініціалізувати запутані стани, а й залучити параметри квантового шару до процесу навчання гібридної нейронної мережі.

Змінювані кути в R_Y -гейтах піддаються оптимізації разом із вагами класичних шарів, що забезпечує взаємопов'язане оновлення параметрів у гібридній архітектурі.

Ці схеми демонструють потенціал використання квантової запутаності для представлення складних залежностей між вхідними ознаками. Вони були використані як частина дослідження здатності квантової частини моделі відображати нелокальні кореляції в даних.

На Рисунку 2.8 наведено приклад квантової схеми, що реалізовує формування стану Белла з параметризованими елементами.




Рисунок 2.8. Діаграма реалізації квантового стану Белла

Окрім вищезазначених структурованих типів квантових схем, у межах дисертаційного дослідження було застосовано також альтернативний, ортогональний підхід, що базується на генерації довільних квантових схем. У цьому випадку проєктування не ґрунтувалося на відомих алгоритмах або на схемах, теоретично обґрунтованих для конкретного типу задач. Натомість квантові схеми формувалися випадковим чином відповідно до кількох заздалегідь визначених параметрів, зокрема кількості кубітів та бажаного рівня квантової запутаності.

Такий підхід було обрано з міркувань введення додаткового стохастичного елементу в архітектуру гібридної нейронної мережі. У результаті випадково згенеровані квантові схеми виконували роль своєрідного джерела квантового

«шуму», що модифікував вхідні вектори ознак у непередбачуваний, але керований спосіб. Це сприяло тому, що модель у процесі навчання менше схилялася до запам'ятовування тренувальних прикладів і натомість фокусувалася на пошуку інваріантних ознак, спільних для представників одного класу. Таким чином, випадкові квантові схеми слугували елементом регуляризації, який підвищував здатність моделі до узагальнення.

Усі випадково згенеровані схеми створювалися динамічно під час проведення експериментів. В окремих серіях експериментів могло бути згенеровано десятки варіантів квантових схем із різною конфігурацією, тож їх повний перелік є надмірно об'ємним для репрезентації у межах дисертаційної роботи. Для ілюстрації загального вигляду таких схем на Рисунку 2.9 наведено приклад однієї з випадково згенерованих квантових схем, що містить 9 кубітів та характеризується середнім рівнем квантової заплутаності.




Рисунок 2.9. Діаграма з 9 кубітами випадково згенерованої квантової схеми.

2.5. Вибір програмних засобів та середовища розробки

Попри надзвичайну динамічність і наукову новизну в галузі штучного інтелекту, набір інструментів, що використовується для розробки сучасних моделей, є досить стабільним і стандартизованим. У розробці систем на основі нейронних мереж домінують кілька мов програмування, зокрема Python, а також низка спеціалізованих фреймворків та бібліотек для побудови, навчання й оцінювання моделей.

Основною мовою програмування, що була використана в межах дисертаційного дослідження, є Python [82] — динамічно типізована, інтерпретована мова з лаконічним синтаксисом. Python де-факто є стандартом у сфері науки про дані, машинного навчання та глибокого навчання завдяки наявності великої кількості готових бібліотек, широкій підтримці з боку наукової спільноти та інтеграції з інструментами для візуалізації, обробки даних і моделювання.

Для побудови та тренування нейронних мереж у дослідженні було використано два основні фреймворки:

- PyTorch [83] — основний фреймворк, що застосовувався у більшості експериментів. Його популярність у науковій спільноті зумовлена гнучкою архітектурою, зручністю реалізації нових моделей та можливістю інтегрування зовнішніх модулів, зокрема квантових схем, як складових нейронної мережі. PyTorch забезпечує просту інтеграцію з іншими інструментами (NumPy, matplotlib, scikit-learn тощо) та підтримує апаратне прискорення через CUDA.
- TensorFlow [84] використовувався в окремих експериментах, зокрема там, де було необхідно автоматично генерувати візуалізації архітектур моделей. TensorFlow також забезпечує високий рівень оптимізації та масштабованість, що є важливим для повторного використання моделей у хмарних середовищах.

Усі експерименти проводилися у середовищі Jupyter Notebooks [85] — інтерактивному середовищі для Python, що дозволяє виконувати код фрагментами (комірками) та одночасно зберігати результати виконання. Це особливо зручно при тривалих експериментах або за необхідності гнучкої верифікації проміжних результатів. Jupyter також слугує інструментом документування, дозволяючи об'єднувати код, пояснення та візуалізації в одному середовищі.

З огляду на обмежену доступність фізичних квантових комп'ютерів, експерименти проводилися з використанням симуляторів квантових обчислень. Було використано два основні інструменти:

- Qiskit [48] — фреймворк від IBM, який надає низькорівневий інтерфейс для побудови квантових схем, їх оптимізації та симуляції на класичному апаратному забезпеченні. Qiskit підтримує моделювання гібридних архітектур та дозволяє створювати квантові компоненти, які потім вбудовуються в класичні моделі. Однак слід зазначити, що симуляція квантових схем є дуже ресурсоемною, що значно уповільнює експерименти, особливо в умовах багатьох запусків (шотів) або великої кількості параметрів.
- PennyLane [62] — вища за рівнем абстракції бібліотека, орієнтована на поєднання квантових обчислень із машинним навчанням. PennyLane має зручний синтаксис та вбудовану підтримку PyTorch і TensorFlow, що полегшує створення гібридних моделей. Бібліотека активно підтримує використання параметризованих квантових схем (variational quantum circuits) у поєднанні з класичним градієнтним навчанням.

Частину обчислювальних експериментів, зокрема ті, що вимагали значного часу на тренування моделей або потребували додаткових ресурсів у вигляді графічного прискорення, було виконано із використанням хмарних обчислювальних платформ Kaggle [86] та Google Colaboratory [88]. Обидва середовища надають безкоштовний доступ до апаратного прискорення у вигляді графічних процесорів (GPU), а у випадку Google Colaboratory — також

тензорних процесорів (TPU), що є спеціалізованими пристроями, оптимізованими для виконання операцій над тензорами в рамках задач глибокого навчання.

Використання цих платформ дало змогу значно скоротити час тренування моделей, паралелізувати обчислення та запускати кілька експериментів одночасно, не обмежуючись ресурсами локальної машини. Крім того, хмарні середовища дозволили уникнути перевантаження локального середовища та забезпечили відтворюваність експериментів, оскільки всі обчислення проводилися у стандартизованих інфраструктурах із попередньо налаштованим середовищем Python та підтримкою основних бібліотек (PyTorch, TensorFlow, Qiskit, PennyLane). Завдяки можливості зберігати ноутбуки та результати обчислень безпосередньо в хмарі, ці платформи також виступили як інструмент управління та документування експериментальних сесій.

Такий підхід до побудови експериментального середовища дозволив забезпечити гнучкість, відтворюваність та масштабованість дослідження. Усі компоненти середовища підібрано таким чином, щоби вони відповідали сучасним стандартам дослідницької практики в галузі машинного навчання та квантових обчислень.

ВИСНОВКИ ДО РОЗДІЛУ 2

У другому розділі дисертаційного дослідження було здійснено ґрунтовний аналіз особливостей гібридизації класичних та некласичних обчислень для побудови глибоких нейронних мереж. Проведено обґрунтований вибір задачі багато-класової класифікації зображень як базового сценарію для експериментів, що дозволяє комплексно оцінити переваги та обмеження гібридних моделей.

Для забезпечення коректності та відтворюваності експериментів обрано кілька різних наборів даних (MedMNIST, CIFAR-10), які відрізняються складністю, структурою та обсягом вибірок. Такий підхід дав змогу протестувати гібридні нейронні мережі в умовах різної складності задач.

У роботі визначено ключові показники ефективності — точність класифікації, AUC, стабільність навчання та узагальнювальна здатність моделей. Це створює єдиний критерій для подальшого порівняння класичних і гібридних архітектур.

Здійснено огляд і відбір архітектур квантових пристроїв, що можуть бути інтегровані у гібридні моделі. Особливу увагу приділено базовим квантовим операціям (R_x , R_y , R_z , σ_x , σ_y , σ_z , Hadamard, swap), які забезпечують можливість Реалізації як елементарних квантових перетворень, так і складних квантових схем. На основі цих операцій сформовано кілька архітектур, які надалі були використані для побудови та тестування гібридних нейронних мереж.

Окремо описано вибір інструментів програмної реалізації та середовища експериментів. Використання хмарних платформ та спеціалізованих бібліотек (PyTorch, TensorFlow, Qiskit, PennyLane) дозволило забезпечити масштабованість, гнучкість та відтворюваність дослідження, а також паралельне виконання серії експериментів.

Таким чином, у другому розділі було створено необхідне методологічне та технічне підґрунтя для подальших експериментальних досліджень. Він забезпечив системне підґрунтя для розробки та аналізу гібридних квантово-класичних моделей, заклавши основу для порівняння їхніх характеристик з класичними нейронними мережами.

РОЗДІЛ 3

КОМПЛЕКСНИЙ СПОСІБ ПОБУДОВИ КВАНТОВО-КЛАСИЧНИХ НЕЙРОННИХ ГІБРИДНИХ МЕРЕЖ

3.1. Вибір алгоритмів для побудови архітектур квантово-класичних гібридних нейронних мереж

Сучасні дослідження у сфері квантових технологій свідчать про активний розвиток гібридних підходів, які поєднують класичні та некласичні (квантові) методи обчислень. Значна кількість наукових груп і промислових компаній спрямовують свої зусилля на створення гнучких інструментів, здатних ефективно поєднувати ці два обчислювальні парадигми. Такі підходи є особливо перспективними для задач, що характеризуються високою обчислювальною складністю та великими обсягами даних.

Важливою сферою застосування є системи штучного інтелекту, зокрема — глибинне навчання для обробки медичних зображень. У таких задачах класичні апаратні потужності забезпечують масштабованість та швидке прототипування моделей, тоді як квантові пристрої здатні виконувати специфічні високонавантажені підзадачі або здійснювати трансформацію вхідних даних у простір із вищою виразністю. Завдяки цьому великі проблеми можна розбивати на менші підзадачі, делегуючи їхнє розв’язання квантовим блокам, а згодом об’єднувати результати у єдину систему. Це відкриває можливість створення більш ефективних і стійких моделей, здатних краще узагальнювати інформацію, зокрема у сфері медичної діагностики.

У межах дисертаційного дослідження було розглянуто комплексний спосіб на основі трьох принципових підходів до інтеграції квантових пристроїв у глибокі згорткові нейронні мережі для задачі багато-класової класифікації медичних зображень (зокрема, із наборів MedMNIST та його підмножин):

1. Квантовий шар як прихований елемент нейронної мережі. У цьому випадку квантова схема вбудовується як один із прихованих шарів між класичними шарами згорткової мережі. Такий підхід дозволяє безпосередньо інтегрувати квантові перетворення у процес формування внутрішніх ознак, забезпечуючи додаткову виразність моделі.
2. Квантовий пристрій використовується для попереднього квантового опрацювання зображень перед їх поданням до класичної частини гібридної нейронної мережі.
3. Квантовий пристрій використовується як перший згортковий шар глибокої згорткової нейронної мережі.

Далі кожен із вищезазначених підходів буде детально розглянуто разом з аналізом ідей, покладених в основу їх побудови.

3.2. Квантовий шар як прихований елемент нейронної мережі

Першим підходом до гібридизації класичних і квантових обчислень, розглянутим у межах дисертаційного дослідження, є інтеграція квантового пристрою безпосередньо як одного з прихованих шарів глибокої згорткової нейронної мережі. Основна ідея цього підходу полягає у частковому перенесенні обчислювально складних операцій із класичної частини моделі до квантової схеми, що теоретично може дозволити зменшити глибину класичної мережі та одночасно підвищити ефективність виконання окремих операцій за рахунок властивого квантовим системам паралелізму.

Зазначений підхід розглядається як відправна точка дослідження методів гібридизації, оскільки в теоретичному аспекті він відкриває можливість не лише зменшення складності класичної частини нейронної мережі, але й потенційного винесення найбільш обчислювально затратних етапів обробки даних у квантову схему. Така декомпозиція обчислень може суттєво скоротити обсяг операцій, які виконуються на класичному апаратному забезпеченні. Водночас на сучасному

етапі розвитку квантових технологій критично важливим є досягнення збалансованого співвідношення між складністю класичної та квантової частин гібридної нейронної мережі, оскільки надмірне ускладнення квантової схеми або використання великої кількості кубітів є нераціональним з огляду на наявні апаратні обмеження

Зокрема, сучасні квантові обчислювальні пристрої здатні оперувати лише обмеженою кількістю кубітів протягом відносно короткого часу когерентності. Крім того, відсутність повноцінних практичних алгоритмів корекції квантових помилок зумовлює наявність підвищеного рівня шуму та неточностей під час виконання квантових операцій. У зв'язку з цим збільшення розміру та складності квантової схеми може призводити до деградації якості її роботи на реальному квантовому апаратному забезпеченні, що обмежує практичну доцільність такого підходу на поточному етапі розвитку квантових обчислень [16, 17].

Оскільки квантовий пристрій у даному підході виступає складовою частиною нейронної мережі, він повинен бути інтегрований не лише в процес використання моделі, але й у процес її навчання. Це накладає низку принципових вимог до квантової схеми. Зокрема, квантова схема має містити конфігуровані параметри, які дозволяють змінювати стан кубітів залежно від вхідних даних та значень параметрів попередніх шарів. Крім того, необхідною умовою є наявність формалізованого механізму прямого проходу через квантову схему та зворотного проходу для обчислення градієнтів і реалізації алгоритму зворотного поширення помилки.

Прямий прохід у такій гібридній архітектурі реалізується шляхом встановлення значень конфігурованих параметрів квантової схеми відповідно до вихідних значень попереднього класичного шару, подальшого виконання квантової схеми, вимірювання результуючих станів кубітів і передачі отриманих значень до наступного шару нейронної мережі. Результати виконання квантової схеми зберігаються для подальшого використання на етапі зворотного проходу.

Зворотний прохід є більш складним, оскільки потребує обчислення градієнтів для коригування вагових коефіцієнтів нейронної мережі відповідно до різниці між прогнозованими та фактичними значеннями. У межах даного

дослідження квантову схему розглянуто як диференційований «чорний ящик», для якого градієнт обчислюється чисельним методом скінченних різниць. Градієнт квантового шару визначається як різниця результатів виконання квантової схеми при зміщенні параметра у позитивному та негативному напрямках і може бути поданий у вигляді:

$$qc_{gradient} = qc(\theta + \varepsilon) - qc(\theta - \varepsilon) \quad (3.1)$$

Де θ — параметр квантової схеми, що відповідає вхідним значенням попереднього прямого проходу, ε — мале зміщення, яке задається як гіперпараметр гібридної нейронної мережі, а $qc(\bullet)$ — результат виконання квантової схеми з відповідними параметрами. Отримані градієнти використовуються для формування повного градієнта шару шляхом поєднання з градієнтами наступних шарів та подальшого оновлення вагових коефіцієнтів, після чого градієнти передаються до попередніх шарів мережі.

Запропонований алгоритм дає змогу інтегрувати квантову схему в межах стандартного механізму зворотного поширення помилки та застосовувати квантовий пристрій як повноцінний прихований шар глибокої гібридної нейронної мережі. На рисунку 3.1 представлено високорівневу діаграму гібридної квантово-класичної нейронної мережі, у структурі якої квантовий пристрій виконує роль одного з прихованих рівнів.




Рисунок 3.1. Діаграма нейронної мережі
з прихованим квантовим пристроєм.

Таким чином, у межах цього підходу квантовий рівень безпосередньо залучається як до процесу використання сформованої моделі, так і до повного циклу її навчання. Це, своєю чергою, зумовлює потребу в істотному використанні квантового апаратного забезпечення на етапі підготовки моделі, що на сучасному етапі розвитку квантових обчислень становить суттєве обмеження для практичного застосування такого підходу з огляду на обмежену доступність квантових комп'ютерів і високу вартість їх використання.

3.3. Попереднє квантове опрацювання зображень

Другим підходом до гібридизації класичних та некласичних обчислень для задач штучного інтелекту, розглянутим у межах дисертаційного дослідження, є використання квантового пристрою на етапі попередньої квантової обробки даних. У межах цього підходу квантовий пристрій не інтегрується безпосередньо у процес навчання нейронної мережі, а використовується для трансформації

вхідних даних до початку навчання класичної частини моделі. Концептуально такий підхід ґрунтується на припущенні, що квантові обчислення можуть бути використані для внесення контрольованого рівня квантового шуму у тренувальні дані, що за своїм функціональним призначенням є аналогом класичного етапу штучного розширення різноманітності даних (data augmentation).

Квантове розширення різноманітності даних у даному випадку не відповідає класичному трактуванню цього підходу, оскільки результат квантової обробки не є детерміністичним, не допускає обернення та призводить до формування модифікованих зображень, які можуть суттєво відрізнятися від оригінальних. Водночас з методологічної точки зору зазначений підхід може бути віднесений до різновидів розширення різноманітності даних, оскільки він переслідує ідентичну мету — підвищення ефективності навчання моделі за рахунок збагачення простору вхідних представлень. Аналогічно до класичних методів data augmentation, квантове «зашумлення» даних сприяє покращенню узагальнювальної здатності нейронної мережі, зменшуючи ризик перенавчання та знижуючи ймовірність запам'ятовування тренувальних зразків.

Попередня квантова обробка вхідних даних у межах дослідження реалізована у вигляді квантово-згорткової операції над зображеннями з оригінального набору даних. Така операція відома в літературі як кванволюційна (quanvolutional) та вперше була запропонована М. Хендерсоном[37]. Алгоритмічно квантово-згорткова обробка полягає у послідовному переміщенні квантово-згорткового ядра по площині зображення відповідно до заданих гіперпараметрів. Для кожної позиції ядра значення пікселів відповідних каналів використовуються як вхідні параметри квантової схеми, після чого виконується квантова обробка, а результати вимірювання станів кубітів формують значення вихідних каналів результуючого зображення.

Процес обробки зображення за допомогою квантово-згорткової операції можна формалізувати наступним алгоритмом:

1. Вибір гіперпараметрів обробки, зокрема розміру квантово-згорткового ядра, кроку його переміщення та параметра доповнення (padding) оригінального зображення. Детальний аналіз впливу цих гіперпараметрів наведено нижче.
2. Послідовне переміщення квантово-згорткового ядра по всій площині зображення відповідно до заданих значень гіперпараметрів.
3. Використання значень каналів пікселів (RGB) для кожної позиції ядра як вхідних параметрів квантової схеми.
4. Виконання квантової схеми окремо для кожного каналу.
5. Виконання вимірювання результуючих станів кубітів з подальшим використанням отриманих значень як відповідних каналів результуючого зображення.




Рисунок 3.2. Схема квантово-згорткового процесу [37].

Список гіперпараметрів, які використовувались в алгоритмі квантово-згорткової обробки :

- Розмір квантового згорткового ядра (kernel size) — відповідає за кількість пікселів, які використовуються на кожному кроці обробки. Розмір ядра повинен відповідати кількості кубітів квантової схеми та мати квадратну форму. З огляду на обмеження сучасного квантового апаратного забезпечення, у роботі розглядаються ядра розміром 2×2 та 3×3 , що відповідає використанню квантових схем із 4 та 9 кубітами відповідно.
- Розмір кроку квантово-згорткової операції (stride) — визначає величину зміщення ядра між сусідніми позиціями та впливає на просторову роздільну здатність результуючого зображення. Практично цей параметр визначає розмір результуючого зображення: зі збільшенням величини кроку зменшуються як геометричні розміри вихідного зображення, так і його роздільна здатність.
- Параметр доповнення (padding) — регулює додавання рамки пікселів навколо оригінального зображення та використовується для контролю розміру результуючих даних. За замовчуванням значення цього параметра дорівнює нулю. Це важливо, якщо результуюче зображення повинно зберегти оригінальний розмір.
- Тип квантових операцій, що застосовуються у квантовій схемі. Даний гіперпараметр визначає типи квантових операцій, що реалізуються у квантовому пристрої на відповідному апаратному забезпеченні. Склад та конфігурація квантових операцій, які формують квантову схему, безпосередньо впливають на її структурну складність і, як наслідок, визначають характер та результати квантової обробки кожного пікселя. У межах дослідження використовувалися параметризовані квантові обертання RX , RY та RZ у різних комбінаціях.

Суттєвою відмінністю квантово-згорткової операції від класичної згортки є характер її вихідних даних. Якщо результатом класичної згорткової операції є одне значення для кожної позиції ядра, то результатом квантово-згорткової операції є множина значень, кількість яких відповідає числу кубітів квантової

схеми. Кожен виміряний стан кубіта використовується як окремий канал результуючих даних. Таким чином, для квантово-згорткового ядра розміром 2×2 формується чотири вихідні шари, кожен з яких містить три канали, що відповідають RGB-представленню зображення. У загальному випадку розмірність даних після квантово-згорткової обробки зростає пропорційно кількості кубітів, що використовуються у квантовій схемі.

Важливим аспектом цього підходу є архітектура квантового пристрою, що використовується для виконання квантово-згорткової операції, а також рівень квантової заплутаності між його кубітами. У межах експериментів застосовувалися випадково згенеровані квантові схеми із фіксованими типами квантових операцій, що дозволило дослідити вплив різних конфігурацій схем на результати обробки даних. Наявність квантової заплутаності забезпечує залежність кожного вихідного каналу від усієї сукупності пікселів, що входять до області квантово-згорткового ядра, що є функціонально подібним до принципу роботи класичних згорткових операцій.

У межах дослідження було проведено експерименти, спрямовані на оцінювання доцільності використання додаткових каналів, отриманих у результаті квантово-згорткової операції, а також на аналіз ефективності різних архітектур класичної частини гібридної нейронної мережі, здатних опрацьовувати багатоканальні квантово-трансформовані дані.

Загальна архітектура гібридної квантово-класичної моделі, що використовує метод попередньої квантової обробки даних, включає:

- Квантовий пристрій, який виконує одноразову попередню квантову обробку вхідних даних.
- Класичну нейронну мережу, що навчається на багатоканальному наборі квантово-трансформованих даних.

На відміну від підходу, за якого квантовий пристрій інтегрується як прихований шар нейронної мережі, у цьому випадку кожний зразок вхідних даних піддається квантовій обробці лише один раз. Така організація не впливає на подальший процес використання навченої моделі, проте дає змогу суттєво

скоротити кількість квантових операцій на етапі навчання, оскільки квантове опрацювання може бути виконане ще до початку оптимізації параметрів класичної складової моделі. У результаті процес навчання не має прямої залежності від квантового апаратного забезпечення, що є суттєвою перевагою з огляду на обмежену доступність квантових обчислювальних ресурсів та їх високу вартість. Додатково можливим є паралельне виконання квантової обробки даних за умови наявності відповідної інфраструктури.

Отже, описаний метод гібридизації класичних і некласичних обчислень характеризується такими перевагами:

- Можливість бути розділеним у часі процесів квантової обробки даних та навчання класичної моделі.
- Можливість паралельної обробки даних.
- Відсутність потреби у квантових обчисленнях на етапі навчання класичної частини моделі.
- Внесення шумової компоненти у вхідні дані засобами квантових обчислень, що може позитивно позначатися на узагальнювальній здатності моделі.
- Збільшення розмірності вихідного представлення даних унаслідок застосування квантово-згорткової операції.

3.4. Використання квантового пристрою як першого згорткового шару гібридної нейронної мережі

Третім підходом до гібридизації класичних і некласичних обчислень у задачах штучного інтелекту, розглянутим у межах дисертаційного дослідження, є застосування квантового пристрою як згорткового шару квантово-класичної гібридної глибокої згорткової нейронної мережі. У межах цього підходу квантовий пристрій безпосередньо бере участь у формуванні початкового

простору ознак, частково або повністю замінюючи класичну згорткову операцію на першому етапі оброблення вхідних даних.

Запропонований підхід ґрунтується на ідеях та принципах, викладених у розділі 2.4.2 «Попередня квантова обробка даних», і є логічним розвитком зазначеної концепції. Основна відмінність даного методу полягає у способі використання результатів квантово-згорткової операції: на відміну від підходу, в якому результат квантової обробки розглядається як єдиний багатоканальний елемент даних, у цьому випадку кожен канал квантово-згорткової операції інтерпретується як окрема варіація одного й того самого зображення.

Процес підготовки моделі в межах даного підходу може бути описаний наступним алгоритмом:

1. Виконується квантове опрацювання вихідного набору даних із застосуванням квантово-згорткових операцій.
2. Результати квантової обробки використовуються для формування нового тренувального набору даних, обсяг якого у n разів перевищує обсяг початкового набору, де n відповідає кількості каналів, отриманих унаслідок виконання квантово-згорткової операції.
3. Сформований таким чином тренувальний набір даних застосовується для навчання класичної складової гібридної моделі.

У результаті виконання попередньої квантової обробки формується новий тренувальний набір даних, що містить n варіацій кожного вхідного зображення.

Як зазначалося раніше, значення n визначається кількістю каналів, сформованих у результаті квантово-згорткової операції, і безпосередньо залежить від гіперпараметрів квантової обробки, зокрема від розміру квантово-згорткового ядра та пов'язаної з ним кількості кубітів у квантовій схемі. Застосування такого підходу дає змогу ввести додаткову варіативність до тренувального набору даних, що є особливо важливим у випадках, коли обсяг вихідного набору є недостатнім або субоптимальним для ефективного навчання моделі. Завдяки розширенню тренувального набору даних цей підхід може сприяти підвищенню точності функціонування моделі в зазначених умовах.

Алгоритм навчання класичної частини гібридної моделі не має принципових відмінностей від процесу навчання класичних моделей штучного інтелекту. Водночас етап використання підготовленої моделі має суттєву специфіку. На відміну від класичної згорткової операції, квантово-згортковий шар формує не одне зображення, а множину з n варіацій, унаслідок чого класична складова гібридної моделі повинна окремо опрацювати та класифікувати кожен з отриманих варіацій. Таким чином, для отримання фінального передбачення гібридної квантово-класичної нейронної мережі необхідно виконати узагальнення результатів передбачень, отриманих для кожної з квантово-згортково трансформованих версій вхідного зображення.

Для реалізації етапу узагальнення можуть застосовуватися різні підходи та алгоритми, вибір яких залежить від специфіки конкретної задачі. Одним із таких підходів є алгоритм голосування більшістю (Majority Voting, MV) [92]. Застосування подібних методів дозволяє ввести додатковий рівень гнучкості у процес формування фінального передбачення гібридної моделі, що може бути корисним у широкому спектрі прикладних задач.

Отже, алгоритм застосування гібридної квантово-класичної моделі штучного інтелекту, побудованої із використанням квантово-згорткової операції як першого шару нейронної мережі, може бути поданий у такому вигляді:

1. Здійснюється квантова обробка зображення на вході.
2. Для кожної з варіацій зображення, отриманих у результаті квантової обробки, виконується:
 - а. Зображення опрацьовується класичною частиною моделі.
 - б. Збереження передбачення зроблене класичною частиною моделі.
3. Виконується аналіз отриманих передбачень з метою формування фінального результату.

Додатково важливою перевагою цього методу є можливість використання сучасних і високоефективних архітектур згорткових нейронних мереж як класичної складової гібридної моделі. Крім залучення архітектур рівня state-of-the-art, запропонований підхід також створює умови для результативного

застосування сучасних засобів підвищення якості навчання, зокрема методів трансферного навчання (transfer learning) [93].

Високорівневу архітектуру гібридних моделей, побудованих на основі цього підходу до гібридизації, наведено на Рисунку 3.3.




Рисунок 3.3. Архітектура квантово-класичної нейронної мережі, яка використовує квантово-згортковий шар [94]

Таким чином, гібридну модель штучного інтелекту, побудовану з використанням даного підходу, також доцільно розглядати як таку, що складається з двох функціонально відокремлених частин:

- Квантового опрацювання вхідного зображення з використанням квантового пристрою.
- Подальшого оброблення результатів квантової трансформації за допомогою класичної частини моделі.

Таке розділення забезпечує всі переваги, наведені в розділі 3.3 «Попередня квантова обробка даних», зокрема можливість часової декомпозиції окремих етапів процесів квантової обробки та навчання, виконання квантової обробки лише один раз без її повторення на кожній епосі навчання, а також можливість здійснення квантової обробки з необмеженим рівнем паралелізму. Водночас використання кожного каналу результатів квантової обробки у вигляді окремого RGB-зображення забезпечує низку додаткових переваг, серед яких можливість залучення сучасних SOTA-архітектур як класичної частини гібридної нейронної мережі, ефективне використання просунутих методів підвищення якості, зокрема трансферного навчання, а також гнучкість інтерпретації результатів моделі за рахунок застосування процедур узагальнення, таких як алгоритми голосування.

3.5. Багатоструктурна класична складова квантово-згорткової гібридної нейронної мережі

Цей підхід є подальшим розвитком раніше описаного методу гібридизації, що ґрунтується на використанні квантового пристрою як першого квантово-згорткового шару гібридної глибокої нейронної мережі. У процесі виконання квантово-згорткової операції на основі одного вхідного зображення формується набір додаткових каналів, кожен з яких відповідає окремій квантово-трансформованій варіації оригінального зображення. Зважаючи на те, що кожен із таких каналів характеризується специфічними структурними відмінностями та відображає окремі аспекти квантового перетворення вхідних даних, закономірним розвитком ідеї використання квантово-згорткової операції як першого шару глибокої нейронної мережі є застосування багатоструктурної архітектури класичної складової гібридної моделі. У межах такого підходу замість однієї класичної моделі застосовується N нейронних мереж, де N відповідає кількості каналів, сформованих у результаті квантово-згорткової операції, причому кожна з цих мереж виконує оброблення лише одного каналу зображення [95]. Архітектурну діаграму підходу, заснованого на використанні

багатоструктурної класичної складової гібридної квантово-згорткової нейронної мережі, показано на Рисунку 3.4.




Рисунок 3.4 Архітектурна діаграма гібридної нейронної мережі, яка використовує квантово-згортковий шар та багатоканальну класичну частину моделі.

Запропонований підхід може бути розширений шляхом додавання до класичної складової гібридної моделі ще одного вхідного каналу, через який передається оригінальне зображення, не модифіковане квантовими перетвореннями. У такому разі класична частина моделі включає $N+1$ базових нейронних мереж, де додаткова мережа призначена для оброблення початкового вхідного зображення. Архітектурну діаграму підходу, що передбачає використання $N+1$ базових мереж, наведено на Рисунку 3.5.




Рисунок 3.5. Архітектурна діаграма гібридної нейронної мережі, яка використовує квантово-згортковий шар і багатоканальну класичну частину моделі з окремим каналом із оригінальним зображенням.

Зіставлення архітектурних діаграм, наведених на Рисунках 3.4 та 3.5, із діаграмою базового підходу, представленою на Рисунку 3.3, дає підстави стверджувати про збереження загальної концепції побудови гібридної моделі. Ключовою відмінністю є використання множини класичних моделей замість однієї, причому кожна з них здійснює обробку лише одного каналу вхідних даних. Запропонований підхід зберігає всі переваги попередньо запропонованого методу гібридизації, проте додатково може забезпечувати підвищення точності роботи гібридної моделі завдяки більш вираженій спеціалізації окремих складових багатоканальної класичної частини. Додатковою перевагою є підвищена гнучкість архітектури, що дозволяє розширювати модель шляхом залучення додаткових вхідних каналів, зокрема каналу з оригінальним зображенням. Разом із тим, у порівнянні з попереднім підходом, даний метод має і суттєвий недолік, оскільки кожна додаткова базова модель у складі класичної багатоструктурної частини призводить до зростання вимог до обсягу оперативної пам'яті та обчислювальних ресурсів, що, своєю чергою, зумовлює

потребу у використанні потужнішого апаратного забезпечення та призводить до зростання загальної вартості застосування цього підходу.

Таким чином, гібридну модель штучного інтелекту, засновану на використанні квантового пристрою як першого згорткового шару нейронної мережі та багатоструктурної класичної частини, можна охарактеризувати як таку, що поєднує всі переваги підходу гібридизації, розглянутого в розділі 3.4 «Використання квантового пристрою як першого згорткового шару гібридної нейронної мережі», та водночас має низку відмінних особливостей, а саме:

- Дозволяє потенційно досягти вищої точності роботи моделі за рахунок використання багатоструктурної архітектури класичної частини.
- Характеризується підвищеною гнучкістю, що дає змогу залучати додаткові базові моделі відповідно до вимог конкретної прикладної задачі.
- Характеризується підвищеною гнучкістю, що дає змогу залучати додаткові базові моделі відповідно до вимог конкретної прикладної задачі.

3.6. Комплексний спосіб поєднання квантових та класичних обчислень у задачах штучного інтелекту

На підставі розглянутих у роботі методів гібридизації класичних і некласичних обчислень може бути сформовано комплексний метод побудови гібридних квантово-класичних нейронних мереж. Основним чинником при формуванні такого комплексного способу є вимоги конкретної прикладної задачі, для розв'язання якої доцільним є залучення гібридних обчислювальних підходів. Кожен із розглянутих методів гібридизації характеризується наявністю як суттєвих переваг, так і певних обмежень, у зв'язку з цим комплексний підхід передбачає вибір і застосування конкретного методу гібридизації залежно від

вимог поставленої задачі з метою максимально ефективного використання його переваг за умови прийнятності пов'язаних із ним обмежень.

Основною перевагою методу гібридизації, що полягає у підстановці квантовий пристрій замість частини прихованих шарів класичної глибокої нейронної мережі, є потенційна можливість прискорення обчислень завдяки перенесенню частини обчислювального навантаження на квантове апаратне забезпечення.

Разом із тим, більш глибокий аналіз цього підходу, проведений у межах дисертаційного дослідження, показав, що застосування такого методу може призводити до зниження максимально досяжного рівня точності моделі після завершення процесу навчання. Детальний опис експериментального дослідження та відповідні кількісні результати наведено у розділі 4.

Перевагою методу гібридизації, що ґрунтується на використанні квантово-згорткової операції, є помітне підвищення точності роботи моделі, яке забезпечується завдяки залученню квантових обчислень для штучного розширення тренувального набору даних і формування додаткових каналів вхідної інформації. Водночас результати експериментальних досліджень показали, що застосування даного підходу супроводжується суттєвим зростанням обсягу класичних обчислень, що призводить до збільшення часу роботи моделі та підвищених вимог до обчислювальних ресурсів. Детальні результати відповідних експериментальних досліджень наведено у розділі 4.

Отже, аналіз переваг і обмежень кожного з розглянутих методів гібридизації дає підстави визначити доцільність їх використання залежно від специфіки конкретної прикладної задачі. Для задач, у яких пріоритетом є надвисока швидкодія та допускається певне зниження точності, доцільним є застосування методу гібридизації, заснованого на заміні частини прихованих шарів класичної глибокої нейронної мережі квантовим пристроєм. Водночас для задач, орієнтованих на досягнення підвищеної точності та здатних допускати зменшення швидкодії, більш доцільним є використання методу гібридизації нейронних мереж із залученням квантово-згорткової операції на початковому етапі оброблення даних, із можливістю застосування багатоструктурної

класичної частини гібридної глибокої нейронної мережі за наявності достатнього апаратного забезпечення. Особливо перспективним цей підхід є для задач, що характеризуються субоптимальним обсягом тренувального набору даних, оскільки квантове штучне розширення даних продемонструвало ефективність як засіб часткової компенсації обмежень, зумовлених недостатньою кількістю навчальних зразків.

ВИСНОВКИ ДО РОЗДІЛУ 3

У цьому розділі дисертаційного дослідження розглянуто три різні стратегії гібридизації глибоких згорткових нейронних мереж для розв'язання задачі багатокласової класифікації зображень:

1. Використання квантового пристрою, що виконує заміняє один з прихованих шарів згорткової глибокої нейронної мережі.
2. Використання квантового пристрою для попередньої обробки зображень до їх переходу у класичну частину гібридної моделі.
3. Використання квантового пристрою як першого квантово-згорткового шару глибокої згорткової нейронної мережі

На сьогодні перший підхід є найпоширенішим варіантом гібридизації. Він дозволяє зменшити глибину класичної частини мережі та підвищити швидкодію систем штучного інтелекту завдяки перенесенню частини обчислень на квантовий рівень. Водночас існує ризик зниження точності моделей, що вказує на необхідність уважного вибору архітектури.

Другий підхід — квантова попередня обробка даних — виявився перспективним для підвищення ефективності гібридних моделей. Він може розширювати тренувальні набори даних, що особливо цінно для задач із обмеженим обсягом даних, забезпечуючи вищу стійкість та точність моделі.

Третій підхід, запропонований у межах цього дослідження, передбачає використання квантового пристрою як першого квантово-згорткового шару та застосування механізму колективного голосування (MV) для формування фінального передбачення. Такий підхід створює додаткові канали представлення даних і надає гнучкість у виборі механізму об'єднання результатів, що потенційно підвищує якість класифікації.

Окремо було розроблено розширення цього підходу шляхом застосування багатоструктурної класичної частини гібридної архітектури. Це дозволяє досягати більш високих рівнів точності завдяки додатковим можливостям класичних обчислень.

Загалом результати свідчать, що ефективність гібридних квантово-класичних нейронних мереж визначається не лише вибором квантової компоненти, але й у значній мірі залежить від архітектурних рішень щодо класичної частини. Саме конфігурація класичних блоків може як компенсувати обмеження квантових підсистем, так і значно посилювати їхній потенціал, що робить вибір класичної архітектури критичним чинником у розробці гібридних моделей.

РОЗДІЛ 4

АНАЛІЗ РЕЗУЛЬТАТІВ СПОСОБІВ ВИКОРИСТАННЯ КЛАСИЧНИХ ТА КВАНТОВИХ ОБЧИСЛЕНЬ У ПОБУДОВІ ГІБРИДНИХ НЕЙРОННИХ МЕРЕЖ

4.1. Аналіз експериментів із базовими гібридними нейронними мережами

Перший етап експериментів був присвячений перевірці ефективності використання квантових перетворень у складі класичних згорткових нейронних мереж. Ця серія становила базовий етап перевірки запропонованого підходу до трансформації архітектур, оскільки дозволяла оцінити, чи здатен квантовий препроцесор сам по собі покращувати представлення вхідних ознак і сприяти підвищенню якості класифікації без зміни решти архітектури.

Всі моделі будували за єдиною схемою, яка включала вхідний шар, блок квантового препроцесингу та класичну частину мережі з трьох згорткових шарів, пулінгу та двох повнозв'язних шарів. У контрольних експериментах квантовий блок був замінений на класичну згортку 2×2 з однаковим stride, що дозволяло ізолювати вплив квантової трансформації. У квантовому шарі кожен 2×2 -патч зображення перетворювався у 4-кубітний стан; на нього накладалися параметризовані обертання навколо однієї або кількох осей Блоха. Розглядалися три варіанти параметризації: R_y -, X_Y - та XYZ -перетворення. Для кожного патчу здійснювалось вимірювання очікуваного значення операторів Паулі, після чого результати об'єднувалися у тензор вихідних ознак. Подальша частина мережі залишалася класичною.

Усі моделі навчалися з використанням п'ятиразової стратифікованої перехресної валідації. Оптимізатор — Adam зі швидкістю навчання 0.001; розмір пакета — 128; кількість епох — 50. Для оцінювання ефективності застосовували метрики Accuracy, AUC_macro та AUC_micro, а також стандартне відхилення (std) результатів між фолдами для оцінки стабільності навчання. Дослідження виконувалися у симуляційному середовищі Qiskit Aer Simulator на GPU, що

гарантувало можливість відтворення результатів без обмежень реальних квантових пристроїв.

Як тестові набори даних використовувалися CIFAR-10 та BloodMNIST, які суттєво відрізняються за природою зображень і рівнем структурної складності. CIFAR-10 є типовим набором для оцінювання ефективності моделей на різномірних об'єктах (автомобілі, літаки, тварини тощо), тоді як набір даних BloodMNIST містить медичні мікрозображення з вираженим дисбалансом класів і високою внутрішньокласовою варіативністю. Таким чином, вибір цих двох датасетів дозволив оцінити, чи матиме квантова компонента універсальний ефект або ж її вплив проявиться сильніше у специфічних, більш шумних задачах.

На рисунку 4.1 наведено схеми архітектур нейронних мереж, використаних у дослідженні для порівняльного аналізу ефективності класичних і некласичних підходів до класифікації зображень. Архітектура на Рисунку 4.1(a), відповідає класичній повнозв'язній нейронній мережі (FCNN), у якій вхідне зображення розміром $28 \times 28 \times 3$ після операції розгортання перетворюється на вектор ознак розмірності 2352 і подається безпосередньо на вихідний повнозв'язний шар із 10 нейронами. Архітектура на Рисунку 4.1(b), є класичною згортковою нейронною мережею (CNN), де початкове зображення проходить через згортковий шар, унаслідок чого формується компактніше подання ознак, яке після розгортання подається на класифікаційний шар. Архітектура на Рисунку. 4.1(c), реалізує кванволюційну нейронну мережу (QNN) з квантовим шаром типу Q-W4-RF2-S2, у якій вхідне зображення після квантового перетворення набуває багатоканального подання розмірності $14 * 14 * 3 * 4$, що далі розгортається та обробляється повнозв'язним класифікатором.




Рисунок 4.1. Схеми архітектур досліджуваних нейронних мереж: (а) класична повнозв'язна мережа (FCNN); (б) класична згорткова нейронна мережа (CNN); (с) кванволюційна нейронна мережа (QNN) з квантовим шаром (Q-W4-RF2-S2).

Результати експериментів на наборі даних CIFAR-10 (Рисунок 4.2) показали, що точність гібридної моделі з квантовим препроцесором практично не поступається класичній CNN: середнє значення точності (асигасу) становило 0.821 проти 0.832 у класичній архітектурі. Водночас, гібридна модель мала помітно менше стандартне відхилення результатів між фолдами (0.009 проти 0.016), що свідчить про її стабільніше навчання. Метрика AUC_macro зросла з 0.878 до 0.892 у варіанті з Ru-перетвореннями. Такий результат демонструє, що навіть без підвищення абсолютної точності квантова трансформація допомагає краще ранжувати зображення за належністю до класів і підвищує узагальнювальну здатність мережі.




Рисунок 4. 2. Криві навчання (точність та втрати) на наборі даних CIFAR-10 для гібридних моделей з різними типами квантових перетворень: R_y , R_{xu} та R_{xuz} .

Набагато виразніший ефект спостерігався для набору даних BloodMNIST. У цьому випадку класична CNN досягала $AUC_macro = 0.873 \pm 0.022$, тоді як HNN із квантовим блоком на основі XY-перетворень продемонструвала $AUC_macro = 0.921 \pm 0.014$. Крім того, різниця між втратами на навчальній та валідаційній вибірках істотно зменшилася: крива валідаційної втрати стабілізувалася вже після 15-ї епохи замість 30-ї, характерної для класичної моделі. Це підтверджує припущення про регуляризаційний ефект квантового шару, який сприяє уникненню перенавчання при обмеженій кількості даних.

Детальніший аналіз показав, що серед трьох типів перетворень найстабільнішими виявилися моделі з Ry-операторами. Вони забезпечували найменше коливання результатів між фолдами ($std \approx 0.010$) і демонстрували прогнозовану збіжність навіть при зменшенні розміру пакету (batch size). Натомість конфігурації XY та XYZ показали трохи вищі значення AUC (до 0.925), проте з більшою дисперсією ($std \approx 0.018\text{--}0.020$). Це свідчить, що складніші квантові контури можуть генерувати більш інформативні ознаки, але водночас підвищують чутливість до параметрів навчання.




Рисунок 4.3. Криві навчання (точність та втрати) на наборі даних DermaMNIST для гібридних моделей з різними типами квантових перетворень: Ry, Rxy .

Отримані результати підтвердили, що навіть одиночний квантовий препроцесор може виступати ефективним елементом регуляризації. У класичних моделях регуляризація досягається за рахунок dropout-шарів, шумових або стохастичних методів; у гібридній архітектурі аналогічну роль відіграє квантова стохастичність, обумовлена властивістю суперпозиції станів. Таким чином, квантова компонента сприяє формуванню більш «гладких» латентних представлень, що підвищує робастність до варіацій у вхідних даних.

4.2. Аналіз експериментів із багатоканальною кванволюцією

На другому етапі експериментальних досліджень було проведено серію випробувань, присвячених аналізу впливу багатоканальної квантової обробки на ефективність гібридних нейронних мереж. Метою дослідження стало з'ясування, як збільшення кількості кванволюційних каналів на вхідному рівні впливає на точність класифікації, стабільність навчання та узагальнювальну здатність моделей порівняно з базовими класичними архітектурами.

У межах цієї роботи було реалізовано три основні типи моделей, наведені на рисунку 4.4:

1. Базова класична CNN, побудована на архітектурі LCNet із одним вхідним каналом оригінального зображення.
2. Гібридна нейронна мережа HNN-4QC, у якій застосовано чотири кванволюційні канали, що містять результати квантових перетворень зображення.
3. Модель HNN-5QC, яка поєднує чотири квантові канали з п'ятим — оригінальним каналом, створюючи комбінований багатоканальний вхід.




Рисунок 4.4. Блок-схеми архітектур: (а) класична згорткова мережа (CNN) з одним вхідним каналом; (б) гібридна нейронна мережа HNN-4QC з чотирма кванволюційними вхідними каналами.

Для формування квантових каналів використовувалися обертання навколо осі Y ($qml.RY$) у середовищі PennyLane, що імітує квантовий контур із 4 кубітами. Кожен піксель зображення кодувався за допомогою RY -операції, а результати вимірювань формували чотири незалежні зображення, які слугували вхідними каналами квантової частини моделі. Таким чином створювався узагальнений багатоканальний тензор, який подавався на класичну частину LCNNet.

Для оцінювання ефективності моделей було використано два набори даних різної природи:

- CIFAR-10, що містить 60 000 кольорових зображень у 10 класах розміром 32×32 пікселі; Характеризується підвищеною гнучкістю, що дає змогу залучати додаткові базові моделі відповідно до вимог конкретної прикладної задачі.

- Характеризується підвищеною гнучкістю, що дає змогу залучати додаткові базові моделі відповідно до вимог конкретної прикладної задачі.

Для обох датасетів використовувалася 6-разова перехресна валідація (6-fold CV) та незалежне Out-of-Cross-Validation (OoCV) тестування, що забезпечувало достовірність і стабільність результатів.

Результати експериментів для набору CIFAR-10 показали чітке покращення показників точності у гібридних архітектурах. Згідно з таблицею 4.1, базова модель CNN досягла точності 0.624 ± 0.009 (6-fold CV) і 0.624 на OoCV. Для гібридної HNN-4QC показники зросли до 0.656 ± 0.008 та 0.678, а для HNN-5QC — до 0.666 ± 0.005 і 0.679 відповідно. Такі результати свідчать про системне підвищення точності при збільшенні кількості квантових каналів. Аналіз кривих навчання (рисунки 4.5-4.6) демонструє більш стабільну збіжність і меншу різницю між навчальною та валідаційною втратою, що вказує на покращену узагальнювальну здатність моделі.

Таблиця 4.1. Результати класифікації (Ассурасу) для моделей CNN, HNN-4QC та HNN-5QC на наборі даних CIFAR-10 за 6-кратної крос-валідації (6-fold CV) та поза нею (OoCV).

Model	6-fold CV (mean±std)	OoCV
CNN	0.6240±0.009	0.624
HNN-4QC	0.656±0.008	0.678
HNN-5QC	0.666±0.005	0.679
Model	6-fold CV (mean±std)	OoCV




Рисунок 4.5 Динаміка зміни точності під час навчання на наборі даних CIFAR-10 для моделей: (а) CNN, (b) HNN-4QC, (c) HNN-5QC.




Рисунок 4.6 Динаміка зміни функції втрат під час навчання на наборі даних CIFAR-10 для моделей: (а) CNN, (b) HNN-4QC, (c) HNN-5QC.

Таблиця 4.2. Максимальні значення метрик ROC-AUC (AUC_macro та AUC_micro) після 6-fold крос-валідації (mean±std) та позафолдового прогнозування (OoCV) для базової CNN і гібридних моделей HNN-4QC та HNN-5QC на наборі даних CIFAR-10.

Model	6-fold CV: AUCmacro (mean±std)	6-fold CV: AUCmicro (mean±std)	OoCV: AUCmacro	OoCV: AUCmicro
CNN	0.922±0.034	0.926±0.003	0.931	0.935
HNN-4QC	0.931±0.034	0.936±0.004	0.939	0.944
HNN-5QC	0.933±0.033	0.938±0.001	0.941	0.946

Як видно з AUC-результатів для набору даних CIFAR-10, додавання кванволюційних каналів покращує якість розділення класів за ROC-кривими. Модель HNN-5QC демонструє найкращі значення $AUC_macro = 0.933 \pm 0.033$ та $AUC_micro = 0.938 \pm 0.001$ у 6-fold CV, а також $AUC_macro = 0.941$ і $AUC_micro = 0.946$ у OoCV, перевищуючи базову CNN (0.922 ± 0.034 / 0.926 ± 0.003 у CV та 0.931 / 0.935 в OoCV). Прирости становлять приблизно $+0.011$ (macro) / $+0.012$ (micro) для CV та $+0.010$ (macro) / $+0.011$ (micro) для OoCV, що узгоджується з висновком про кращу узагальнювальну здатність комбінованого багатоканального входу.

На медичному наборі DermaMNIST виявлено подібну закономірність (Таблиця 4.2). Базова CNN досягла середньої точності 0.650 ± 0.018 (6-fold CV) та 0.640 на OoCV, тоді як HNN-4QC і HNN-5QC показали стабільно вищі результати. На графіках (Рисунки 4.7-4.8) видно, що для гібридних моделей характерне швидше вирівнювання на навчальній та валідаційній вибірках, що свідчить про кращу регуляризацию та меншу схильність до перенавчання. Крім того, моделі з квантовими каналами демонстрували плавніше зниження функції втрат і більш рівномірну динаміку приросту точності.

Таблиця 4.3. Результати класифікації (Ассурасу) для моделей CNN, HNN-4QC та HNN-5QC на наборі даних DermaMNIST за 6-кратної крос-валідації (6-fold CV) та поза нею (OoCV)-10.

Model	6-fold CV (mean $\pm$ std)	OoCV
CNN	0.650 $\pm$ 0.018	0.640
HNN-4QC	0.704 $\pm$ 0.025	0.705
HNN-5QC	0.716$\pm$0.014	0.715




Рисунок 4.7 Динаміка зміни точності під час навчання на наборі даних DermaMNIST для моделей: (a) CNN, (b) HNN-4QC, (c) HNN-5QC.




Рисунок 4.8 Динаміка зміни функції втрат під час навчання на наборі даних DermaMNIST для моделей: (a) CNN, (b) HNN-4QC, (c) HNN-5QC

Таблиця 4.4. Максимальні значення метрик ROC-AUC (AUC_macro та AUC_micro) після 6-fold крос-валідації (mean $\pm$ std) та позафолдового прогнозування (OoCV) для базової CNN і гібридних моделей HNN-4QC та HNN-5QC на наборі даних DermaMNIST.

Model	6-fold CV: AUCmacro (mean $\pm$ std)	6-fold CV: AUCmicro (mean $\pm$ std)	OoCV: AUCmacro	OoCV: AUCmicro
CNN	0.799 $\pm$ 0.045	0.912 $\pm$ 0.003	0.806	0.915
HNN-4QC	0.810 $\pm$ 0.047	0.927 $\pm$ 0.001	0.820	0.929
HNN-5QC	0.823$\pm$0.043	0.932$\pm$0.003	0.846	0.935

Для набору даних DermaMNIST спостерігається аналогічна тенденція: гібридні моделі з квантовими каналами забезпечують вищі значення AUC_macro

та AUC_micro порівняно з базовою CNN як у 6-fold CV, так і в OoCV, причому найкращий результат відповідає конфігурації HNN-5QC.

Отримані результати чітко демонструють тенденцію до покращення якості класифікації зі збільшенням кількості квантових каналів. У середньому гібридні моделі забезпечили приріст точності на 3–5 % у порівнянні з класичними, а також більш стабільні значення між фолдами валідації. Додавання оригінального (неперетвореного) каналу разом із квантовими перетвореннями (модель HNN-5QC) забезпечило найвищі показники, що підтверджує доцільність комбінованої подачі вхідних даних.

На основі аналізу експериментів було зроблено висновок, що багатоканальна квантова обробка даних на рівні вхідного шару є ефективним механізмом розширення ознакового простору без істотного збільшення кількості параметрів моделі. Вона підвищує стабільність, узагальнювальну здатність і точність мережі, а також забезпечує більш збалансоване співвідношення між тренувальною та валідаційною похибкою. Таким чином, багатоканальна кванволюція може розглядатися як перспективний напрям подальшої оптимізації гібридних квантово-класичних моделей.

4.3. Аналіз експериментів із масштабуванням архітектури HNN-QCN

Подальший етап експериментальних досліджень був присвячений аналізу масштабованих архітектур гібридних нейронних мереж із кількома паралельними класичними бекбонами, позначеними як HNN-QC_n, де n — кількість квантових каналів і відповідних гілок LCNet-бекбонів. Основна мета цього етапу полягала у визначенні, як збільшення кількості бекбонів і квантових каналів впливає на узагальнювальну здатність, точність і стабільність моделей при класифікації як загальних, так і медичних зображень.

Архітектура HNN-QC_n передбачала поєднання кількох ідентичних LCNet050-бекбонів, кожен з яких отримував на вхід окремий канал — результат квантового перетворення вихідного зображення. Для створення квантових

варіантів використовувалися однокубітні обертання навколо осей Y та X , а також їхні комбінації (RY, RX, RXY). Ці перетворення створювали стохастичні квантові варіації зображення, формуючи набір паралельних вхідних тензорів. Після обробки бекбонами їхні вихідні тензори конкатенувалися та подавалися в повнозв'язну частину для остаточної класифікації.

Основні досліджені архітектури включали:

- Baseline (O1) — LCNet050 з одним каналом оригінального зображення.
- QC4 — чотири квантові канали (YW4).
- QC5 — чотири квантові канали + один оригінальний (YW4 + O1).
- QC9–QC10 — дев'ять каналів (XYW9) з/без оригінального входу.
- QC17–QC18 — сімнадцять каналів, утворених комбінацією YW4, XYW4 та XYW9 з/без оригінального зображення.




Рисунок 4.9. Загальна схема масштабованої багатоканальної архітектури HNN-QCn з використанням декількох паралельних бекбонів LCNet050.

На рисунку 4.9 представлено загальну схему масштабованої багатоканальної архітектури HNN-QCn, побудованої на основі декількох паралельних класичних бекбонів LCNet050. Архітектура демонструє принцип обробки квантово-трансформованих вхідних даних у вигляді множини каналів, кожен з яких подається на окремий екземпляр класичної нейронної мережі.

Таблиця 4.5. Опис архітектур масштабованих моделей HNN-QC_n, що включають різні комбінації квантових каналів (QC) та оригінального зображення (O1).

Model (QC _n)	Model (Transformations and Channels)	QC Inputs	Original Input
baseline	O1	-	1
QC4	YW4	4	—
QC5	YW4 + O1	4	1
QC4	XYW4	4	—
QC5	XYW4 + O1	4	1
QC9	XYW9	9	—
QC10	XYW9 + O1	9	1
QC9	YW4 + XYW4 + O1	9	1
QC17	YW4 + XYW4 + XYW9	17	—
QC18	YW4 + XYW4 + XYW9 + O1	17	1

Для навчання використовувалися два набори даних — CIFAR-10 (загальні об'єкти) та DermaMNIST (медичні зображення). Моделі тренувалися впродовж 200 епох із оптимізатором Adam (learning rate = 1×10^{-4}) і Categorical Cross-Entropy Loss. Застосовувалися метрики Accuracy, AUC_micro, AUC_macro та стандартне відхилення (std) результатів між фолдами.

На наборі даних CIFAR-10 спостерігалось чітке зростання точності та AUC зі збільшенням кількості каналів (таблиця 4.6). Базова модель LCNet050 (O1)

досягла $AUC_micro = 0.961 \pm 0.020$ і $AUC_macro = 0.965 \pm 0.002$ при точності 0.735 ± 0.012 .

Для моделі HNN-4QC (YW4) спостерігався $AUC_micro = 0.955 \pm 0.024$ та $AUC_macro = 0.960 \pm 0.001$ при Accuracy 0.741 ± 0.006 .

Комбінована конфігурація HNN-5QC (YW4 + O1) досягла найвищих показників: $AUC_micro = 0.964 \pm 0.022$, $AUC_macro = 0.969 \pm 0.001$, Accuracy = 0.769 ± 0.002 .

Таблиця 4.6. Найкращі значення AUC та точності (середнє $\pm$ стандартне відхилення) для різних моделей HNN-QCn на наборі даних CIFAR-10.

Inputs	Model	AUCmicro	AUCmacro	Accuracy
1	baseline	0.961 ± 0.020	0.965 ± 0.002	0.735 ± 0.012
4	YW4	0.955 ± 0.024	0.960 ± 0.001	0.741 ± 0.006
5	YW4 + O1	0.964 ± 0.022	0.969 ± 0.001	0.769 ± 0.002




Рисунок 4.10. Залежність точності класифікації від логарифму розміру пакета (batch size) для всіх досліджуваних моделей HNN-QCn на наборі даних CIFAR-10.

Як показують графіки (рисунок 4.10), збільшення кількості каналів призводить до монотонного підвищення обох метрик до рівня QC9, після чого ефект насичення стає вираженим. У варіантах QC17 та QC18 точність зростає ще на $\approx 2\%$, але покращення AUC становить менше 1% . Таким чином, оптимальним балансом між якістю та ресурсами виявилися архітектури QC5–QC9, які забезпечують максимальний приріст при мінімальному збільшенні обчислювальної складності. Збільшення кількості каналів також зменшувало варіативність між фолдами (AUC_std знизилося з 0.020 до ≈ 0.012).

Для медичного набору DermaMNIST масштабування мережі дало ще виразніший позитивний ефект (таблиця 4.4.3). Базова модель (O1) досягла $AUC_micro \approx 0.86$ і $AUC_macro \approx 0.84$, тоді як конфігурації HNN-4QC та HNN-5QC підвищили ці показники до 0.89 та 0.91 відповідно. Моделі HNN-9QC та HNN-1QC0 досягли максимальних значень $AUC_macro > 0.92$ та $Accuracy > 0.78$, що на $\approx 5\text{--}7\%$ вище за базовий результат.

Таблиця 4.7. Найкращі значення AUC та точності (середнє $\pm$ стандартне відхилення) для різних моделей HNN-QCn на наборі даних DermaMNIST.

Inputs	Model	AUCmicro	AUCmacro	Accuracy
1	baseline	0.880 ± 0.045	0.944 ± 0.001	0.701 ± 0.019
4	YW4	0.848 ± 0.048	0.926 ± 0.005	0.727 ± 0.012
5	YW4 + O1	0.952 ± 0.025	0.956 ± 0.003	0.727 ± 0.019




Рисунок 4.11. Залежність точності класифікації від логарифму розміру пакета (batch size) для всіх досліджуваних моделей HNN-QCn на наборі даних DermaMNIST.

У таблиці 4.8 наведено порівняння моделей HNN-QCn на наборі даних DermaMNIST за фіксованого розміру пакету (batch size) = 2048. Спостерігається позитивна кореляція між кількістю входів (QC-каналів/комбінацій та кількістю паралельних гілок) і середніми значеннями площі під кривою та точності: найбільша модель YW4 + XYW4 + XYW9 + O1 (18 входів) досягає $AUC_micro = 0.839 \pm 0.052$, $AUC_macro = 0.941 \pm 0.001$ та точність = 0.734 ± 0.020 . Це підтверджує, що збільшення кількості вхідних представлень загалом підвищує здатність моделі розрізняти класи.

Таблиця 4.8. Опис архітектур масштабованих моделей HNN-QCn, що включають різні комбінації квантових каналів (QC) та оригінального зображення (O1).

Inputs	Model	AUCmicro (mean±std)	AUCmacro (mean±std)	Accuracy (mean±std)
1	baseline	0.814±0.040	0.922±0.002	0.683±0.018
4	YW4	0.801±0.052	0.924±0.001	0.711±0.023
5	YW4 + O1	0.826±0.049	0.932±0.001	0.721±0.017
4	XYW4	0.683±0.054	0.893±0.007	0.705±0.011
5	XYW4 + O1	0.750±0.052	0.914±0.003	0.708±0.015
9	XYW9	0.799±0.054	0.929±0.002	0.724±0.019
10	XYW9 + O1	0.814±0.052	0.933±0.001	0.726±0.019
9	YW4 + XYW4 + O1	0.815±0.045	0.931±0.001	0.729±0.016
17	YW4 + XYW4 + XYW9	0.825±0.055	0.938±0.001	0.733±0.019
18	YW4 + XYW4 + XYW9 + O1	0.839±0.052	0.941±0.001	0.734±0.020

Помітно, що на медичних зображеннях ефект масштабування проявився сильніше через високу структурну подібність між класами та обмежену кількість зразків. Додавання нових бекбонів створювало додаткову варіативність у вхідних представленнях, що покращувало розпізнавання менш поширених класів та зменшувало кількість помилкових класифікацій. Стандартне відхилення результатів зменшилося на $\approx 25\text{--}30\%$, що вказує на вищу стабільність та робастність моделей при збільшенні кількості бекбонів.

Крім того, аналіз залежності показників від розміру пакета (batch size) виявив, що для середніх значень (128–256) досягаються максимальні AUC, а для великих розмірах (512–1024) зростає точність завдяки кращому вирівнюванню

градієнтів. Таким чином, параметри QC5–QC9 і розміру пакета = 256 виявилися найефективнішими з погляду співвідношення якості/ресурси.

Результати масштабування архітектури HNN-QC_n доводять, що збільшення кількості квантових каналів і бекбонів веде до поступового зростання точності та AUC для всіх типів даних, причому ефект є більш вираженим у медичних задачах. Конфігурації QC5–QC10 виявилися оптимальними за показниками якості та ресурсів, а QC9 та QC10 забезпечили найвищі $AUC_{macro} > 0.92$ та точність > 0.78 на наборі даних DermaMNIST. Таким чином, масштабування HNN-QC_n підтвердило ефективність запропонованого методу трансформації нейронних мереж для використання в контексті неklasичних обчислень і дало змогу визначити оптимальну межу збалансованості між якістю та обчислювальними витратами.

4.4. Аналіз експериментів із впливу вибору класичної частини мережі

У цій серії експериментів було досліджено, як вибір класичної частини архітектури впливає на ефективність гібридних квантово-класичних нейронних мереж у задачах класифікації зображень. Метою дослідження було визначити, чи впливають структурні особливості класичної частини моделі на взаємодію з квантовим препроцесором і загальну точність гібридної системи.

Дослідження проводилось на основі двох легких згорткових архітектур:

- MobileNetV3Small050, яка використовує інверсні резидуальні блоки та нелінійність HardSwish.
- LCNet050, побудованої за принципом послідовного зменшення кількості каналів і оптимізованої для CPU-ефективності.

Обидві архітектури інтегрували однаковий квантовий препроцесор (Quanvolutional Layer), що базувався на 4-кубітній схемі з операторами $R_y(\theta)$. Квантова обробка виконувалась перед класичними шарами, забезпечуючи попереднє перетворення вхідного зображення у квантовий простір ознак. Після

цього результат вимірювань формував 5-канальний вихід, який подавався до класичної частини мережі для подальшої класифікації.

Для об'єктивного порівняння обидві моделі навчалися за ідентичних умов:

- Набір даних — CIFAR-10 (60 000 зображень у 10 класах, розміром 32×32 пікселі).
- Кількість епох — 10.
- Batch size — 64.
- Stride квантового шару — 1, receptive field — 2.
- Валідація — 5-fold стратифікована крос-валідація.
- Метрики оцінки — AUC_macro, AUC_micro, матриці змішування, клас-специфічні AUC.

У таблиці 4.9 наведено порівняння середніх результатів після п'ятикратної стратифікованої валідації.

Таблиця 4.9. Найкращі значення AUC та точності (середнє $\pm$ стандартне відхилення) для різних моделей HNN-QCn на наборі даних DermaMNIST.

Backbone	AUC_macro_mean	AUC_macro_std	AUC_micro_mean	AUC_micro_std
MobileNetV3Sm all050	0.933998	0.029202	0.938082	0.001131
LCNet050	0.954004	0.024682	0.958469	0.000409
Δ AUC	0.020006		0.020387	

Отримані дані демонструють, що модель із LCNet050 стабільно переважає MobileNetV3Small050 за всіма ключовими метриками.

Зокрема, макро-усереднене AUC становило 0.9540 проти 0.9340, а мікро-усереднене — 0.9585 проти 0.9381. Приріст Δ AUC ≈ 0.02 перевищує дисперсії показників для обох моделей (AUC_macro_std = 0.0292, AUC_micro_std ≤ 0.0011), що підтверджує статистичну значущість покращення.

У таблиці 4.10 наведено усереднені значення AUC по класах після 5-fold CV. LCNet050 показує покращення в усіх десяти класах набору даних CIFAR-10,

причому приріст ΔAUC варіюється від +0.0073 (class 8, ship) до +0.0286 (class 4, deer). Найбільш виражені покращення спостерігаються для середньо-складних класів — 2, 3, 4 (+0.0201, +0.0203, +0.0286), що свідчить про кращу здатність LCNet узагальнювати при високій внутрішньокласовій варіативності.

Таблиця 4.10. Найкращі значення AUC та точності (середнє $\pm$ стандартне відхилення) для різних моделей HNN-QCn на наборі даних DermaMNIST.

Class	AUC_M_me an	AUC_M_st d	AUC_L_mea n	AUC_L_st d	ΔAUC_mea n
0	0.946172	0.002621	0.964261	0.001295	0.018089
1	0.967665	0.002112	0.980485	0.001488	0.01282
2	0.897933	0.002987	0.923923	0.003442	0.02599
3	0.87987	0.003302	0.905776	0.004025	0.025906
4	0.912916	0.003781	0.943832	0.001716	0.030916
5	0.914256	0.003115	0.931433	0.003443	0.017177
6	0.955699	0.001997	0.9733	0.001343	0.017601
7	0.940685	0.001617	0.966152	0.001009	0.025467
8	0.967525	0.001396	0.97666	0.001053	0.009135
9	0.957264	0.002159	0.974215	0.000966	0.016951

Аналіз матриць змішування (рисунок 4.12) також підтверджує перевагу LCNet050: діагональні елементи є більш чітко вираженими, а міжкласова плутанина — меншою, що означає кращу дискримінаційну здатність гібридної моделі.




Рисунок 4. 12. Нормалізовані матриці змішування для гібридних моделей на наборі даних CIFAR-10 з класичними частинами: (a) MobileNetV3Small050; (b) LCNet050.

LCNet050 демонструє вищу стабільність навчання у межах усіх фолдів, із нижчими значеннями std для обох метрик AUC_macro та AUC_micro.

Зокрема, 9 із 10 класів показали зменшення варіації AUC при використанні LCNet, а середнє зниження стандартного відхилення становило ≈ 0.0020 . Це свідчить, що LCNet забезпечує більш узгоджене навчання і є менш чутливим до зміни розподілу даних між фолдами.

Отже, навіть за однакової квантової обробки, класичний частина архітектури істотно впливає на результат. LCNet050 не лише досягає вищих середніх показників, а й демонструє меншу дисперсію та кращу збалансованість між класами. Це робить її більш придатною для стабільної інтеграції з квантовими препроцесорами.

4.5. Аналіз експериментів із багатоканальною класичною гібридною архітектурою HNN

Заключний етап експериментальних досліджень був спрямований на вивчення впливу масштабування класичної частини гібридних нейронних мереж (HNN) на загальну продуктивність і стабільність моделей. Метою було

визначити, як збільшення глибини та ємності класичних частин у поєднанні з квантовими шарами впливає на якість класифікації та узагальнювальну здатність моделей при різних типах даних.

Цей підрозділ узагальнює результати досліджень щодо впливу масштабування класичної частини на ефективність гібридних квантово-класичних нейронних мереж (HNN), виконаних у межах оновленої архітектури HNN-5QC. Дослідження було побудоване на систематичному порівнянні гібридних і класичних моделей, побудованих на основі п'яти масштабів LCNet: LCNet050, LCNet075, LCNet100, LCNet150 та LCNet200, що дозволило встановити залежність ефективності гібридизації від складності класичної частини.

Усі гібридні моделі інтегрували 4-кубітний параметризований квантовий шар на базі Ry-обертань, ініціалізований операторами Адамара та навчуваними Ry-вузлами, який генерував чотири додаткові квантові канали, що у поєднанні з оригінальними RGB створювало QC5-конфігурацію (3 + 4 каналів). Всі експерименти виконані у симуляторі PennyLane, а результати відображають властивості квантово-надихнених (quantum-inspired) перетворень.

Усі експерименти проводилися в симуляційному середовищі PennyLane, із застосуванням однакових параметрів навчання: оптимізатор Adam із швидкістю 0.001, 50 епох тренування, розмір пакету = 64, стратифікована 5-fold крос валідація та подальше позафолдове оцінювання. Основними метриками були точність, AUC_macro, AUC_micro та їхні стандартні відхилення, які відображають стабільність результатів.

Моделі оцінювалися на двох контрастних датасетах:

- CIFAR-10 — вибірка збалансованих загальних зображень (32×32, 10 класів).
- DermaMNIST — медична, і сильно незбалансована вибірка дерматоскопічних зображень (7 класів).

Оцінювання здійснювалося за допомогою стратифікованої 5-fold крос валідації, з обов'язковою агрегацією позафолдових (OoF) прогнозів для

коректного розрахунку метрик. Реєструвались точність, AUC_macro, AUC_micro та стандартні відхилення як ключові показники стабільності.

Експерименти на наборі CIFAR-10 дозволили визначити залежність ефективності гібридизації від складності класичної архітектури. У таблиці 4.11 наведено середні значення точності для всіх масштабів LCNet.

Таблиця 4.11. Порівняння Out-of-Fold точності (Accuracy) для класичних та гібридних варіантів архітектур LCNet різного масштабу на наборі даних CIFAR-10.

Backbone	Variant	Mean	Std	Δ mean	Δ std
LCNet050	Hybrid	0.7178	0.0074	0.0075	-0.0077
LCNet050	Classic	0.7103	0.0151		
LCNet075	Hybrid	0.7592	0.0063	0.0102	-0.0153
LCNet075	Classic	0.7490	0.0216		
LCNet100	Hybrid	0.7817	0.0082	-0.0098	0.0018
LCNet100	Classic	0.7915	0.0064		




Рисунок 4.13. Криві навчання (точність та втрати) для класичних та гібридних моделей LCNet050, LCNet075 та LCNet100 на наборі даних CIFAR-10.

Цей прогрес підтверджує, що гібридизація у компактних архітектурах діє як квантово-інспірований регуляризатор. Модель навчається стабільніше, менш чутлива до розподілу даних між фолдами, а якість OoF-прогнозів зростає.

Однак для LCNet100 спостерігається протилежна тенденція: класична версія моделі перевершує гібридну. Це означає, що при збільшенні ємності моделі квантовий шар втрачає здатність покращувати навчання, оскільки класична частина самостійно має достатню здатність до узагальнення.

За метриками AUC_macro та AUC_micro класичні моделі загалом мають дещо вищі середні значення. Проте гібридні моделі демонструють істотно менші стандартні відхилення, що підтверджує стабілізаційний ефект квантового шару.

Таблиця 4.12. Порівняння макро- та мікро-усереднених значень AUC для класичних та гібридних варіантів архітектур LCNet різного масштабу на наборі даних CIFAR-10.

Backbone	Variant	AUC macro mean	AUC macro std	AUC micro mean	AUC micro std	Δ AUC macro
LCNet050	Hybrid	0.9531	0.0255	0.9576	0.0027	-0.0047
LCNet050	Classic	0.9578	0.0231	0.9624	0.0030	
LCNet075	Hybrid	0.9634	0.0207	0.9680	0.0017	-0.0005
LCNet075	Classic	0.9639	0.0199	0.9685	0.0060	
LCNet100	Hybrid	0.9681	0.0172	0.9723	0.0015	-0.0058
LCNet100	Classic	0.9739	0.0145	0.9782	0.0010	




Рисунок 4.14. Динаміка макро-усередненої AUC на наборі даних CIFAR-10 для класичних та гібридних моделей LCNet різного масштабу.

Другий набір даних — DermaMNIST — значно складніший внаслідок медичної природи, сильного класового дисбалансу та високої внутрішньокласової варіативності зображень. Саме тут було продемонстровано найбільший прогрес.

Таблиця 4.13. Порівняння Out-of-Fold точності (Accuracy) для класичних та гібридних варіантів архітектур LCNet різного масштабу на наборі даних DermaMNIST.

Backbone	Variant	Mean	Std	Δ mean	Δ std
LCNet050	Hybrid	0.6125	0.0116	0.0668	-0.0115
LCNet050	Classic	0.5457	0.0231		
LCNet075	Hybrid	0.6377	0.0270	0.0657	-0.0025
LCNet075	Classic	0.5720	0.0295		
LCNet100	Hybrid	0.6121	0.0221	0.0357	-0.0089
LCNet100	Classic	0.5764	0.0310		
LCNet150	Hybrid	0.5581	0.0309	-0.0298	0.0053
LCNet150	Classic	0.5879	0.0256		
LCNet200	Hybrid	0.5554	0.0300	-0.0581	0.0095
LCNet200	Classic	0.6135	0.0205		




Рисунок 4.15. Криві навчання (точність та втрати) для класичних та гібридних моделей LCNet050–LCNet200 на наборі даних DermaMNIST.

Результати, отримані на наборі DermaMNIST, дозволили найбільш повно продемонструвати переваги запропонованого методу гібридизації та стали центральним підтвердженням ефективності квантового препроцесора у завданнях медичної класифікації. Цей датасет характеризується високою складністю: сильним дисбалансом класів, значною внутрішньокласовою варіативністю та високою чутливістю моделей до перенавчання. Саме тому набір даних DermaMNIST виступає суворим тестом на узагальнювальну здатність моделей.

У всіх експериментах для набору даних DermaMNIST спостерігалось чітке, статистично значуще та систематичне покращення продуктивності для гібридних моделей порівняно з класичними, причому цей ефект був більш виразним, ніж на у набору CIFAR-10. Це підкреслює: квантова регуляризація приносить максимальну користь саме в умовах медичних задач, де класичні моделі схильні до нестабільності та коливань метрик на різних фолдах.

За даними ОоF-оцінювання гібридні моделі на основі LCNet050, LCNet075 і LCNet100 забезпечили суттєвий приріст точності: LCNet050 Hybrid: +0.0668; LCNet075 Hybrid: +0.0657; LCNet100 Hybrid: +0.0357.

Ці значення вражають у контексті медичної класифікації, оскільки приріст на рівні 6–7 процентних пунктів за точністю зазвичай досягається лише шляхом збільшення обсягу даних або радикальної зміни архітектури. У даному ж випадку покращення досягнуто без зміни класичної моделі, лише за рахунок інтеграції квантового шару.

Таким чином, запропонована архітектура HNN-5QC продемонструвала, що квантова трансформація може компенсувати дефіцит даних, характерний для медичних наборів.

Таблиця 4.14. Порівняння макро- та мікро-усереднених значень AUC для класичних та гібридних варіантів архітектур LCNet різного масштабу на наборі даних DermaMNIST.

Backbone	Variant	AUC macro mean	AUC macro std	AUC micro mean	AUC micro std
LCNet050	Hybrid	0.8647	0.0468	0.9080	0.0048
LCNet050	Classic	0.8310	0.0558	0.8919	0.0090
LCNet075	Hybrid	0.8778	0.0465	0.9207	0.0050
LCNet075	Classic	0.8391	0.0467	0.9028	0.0072
LCNet100	Hybrid	0.8664	0.0476	0.9169	0.0077
LCNet100	Classic	0.8434	0.0533	0.9104	0.0043
LCNet150	Hybrid	0.8293	0.0452	0.8765	0.0114
LCNet150	Classic	0.8362	0.0662	0.9174	0.0040
LCNet200	Hybrid	0.8394	0.0536	0.8768	0.0116
LCNet200	Classic	0.8635	0.0478	0.9181	0.0068




Рисунок 4.16. Динаміка макро-усередненої AUC на наборі даних DermaMNIST для класичних та гібридних моделей LNet різного масштабу.

За метриками AUC_macro та AUC_micro спостерігався систематичний приріст у гібридних моделях:

- AUC_macro: +0.0337 ... +0.0387.
- AUC_micro: +0.0161 ... +0.0179.

Це особливо важливо, оскільки AUC_macro є чутливою до класів з малою кількістю прикладів. Підвищення на 0.03–0.04 означає, що модель не лише покращує загальну якість, а й краще розрізняє рідкісні патології, що має критичне значення для задач медичної діагностики.

Окрім зростання середніх значень, у гібридних моделей спостерігається значне зменшення стандартних відхилень між фолдами. Для LNet050 й LNet075 значення std зменшувалося майже вдвічі порівняно з класичними моделями.

Це свідчить про два ключові аспекти: квантовий шар знижує чутливість до розподілу вибірки, тобто робить модель більш передбачуваною; гібридна модель краще узагальнює, навіть у випадках класового дисбалансу.

Для медичних систем, що використовуються у клінічній практиці, стабільність є не менш важливою, ніж абсолютна точність моделі. Таким чином,

зменшення σ_d можна трактувати як один із найважливіших наукових результатів цієї роботи.

ВИСНОВКИ ДО РОЗДІЛУ 4

У цьому розділі здійснено аналіз комплексного способу побудови, навчання та експериментального оцінювання гібридних квантово-класичних нейронних мереж з урахуванням особливостей різних варіантів класичних архітектур та їх взаємодії з квантовими перетвореннями. Проведене дослідження дозволило встановити фундаментальні закономірності синтезу некласичних обчислень із сучасними згортковими мережами та визначити межі і напрями ефективного застосування квантових компонент для задач класифікації складних даних, зокрема медичних зображень.

Передусім було обґрунтовано методологічний підхід до інтеграції квантового шару, побудованого на параметризованому 4-кубітному Ry-контурі, у структуру легковагових CNN-моделей. Така інтеграція вимагає спеціальної адаптації класичної частини мережі, зокрема коректного масштабування активацій та забезпечення узгодженості між просторами параметрів. Установлено, що застосування обмежувальних активаційних функцій типу $\tanh$ перед квантовим модулем є принципово важливим для стабільного процесу навчання, оскільки воно гарантує відповідність амплітуд вхідних сигналів діапазонам кутових параметрів квантових гейтів. Це підтверджує необхідність спеціального попереднього налаштування класичної архітектури для коректної роботи гібридної моделі.

Важливою складовою дослідження стало формування уніфікованого експериментального робочого процесу, що поєднує класичну комп'ютерну обробку даних з некласичними перетвореннями та включає використання стратифікованої перехресної 5-фолд валідації разом з узагальненням результатів у вигляді Out-of-Fold прогнозів. Такий підхід забезпечує високий рівень статистичної надійності та виключає можливість витоку інформації між тренувальними та тестовими підмножинами. Застосована методика дозволила отримати репрезентативні оцінки розподілу метрик і чітко виявити вплив вибору класичної архітектури на стабільність та узагальнювальну здатність моделі.

Проведений порівняльний аналіз показав, що саме архітектурний вибір класичної частини суттєво визначає ефективність усього гібридного підходу. Мережі LCNet різних масштабів продемонстрували виразно кращу узгодженість із квантовим перетворенням порівняно з MobileNetV3, що проявляється у вищій стабільності міжфолдових метрик, плавнішій збіжності тренування та менших коливаннях AUC і точності. Особливо помітним є ефект для менших та середніх конфігурацій LCNet, де квантова компонента, фактично, працює як регуляризатор, що знижує дисперсію метрик і підвищує стійкість моделі до шуму та невеликих варіацій у даних. Це дозволяє стверджувати, що квантові перетворення здатні компенсувати структурні обмеження менш глибоких CNN-архітектур, підвищуючи їхню дискримінаційну здатність.

Разом із тим результати засвідчили, що збільшення розміру класичної моделі зменшує додаткову користь від квантової компоненти. У випадку більших конфігурацій MobileNetV3 ефект гібридизації послаблюється або стає незначним. Це свідчить про те, що для занадто складних класичних моделей потенціал квантових шарів проявляється слабше, оскільки такі моделі вже здатні формувати достатньо насичене представлення ознак без додаткових перетворень. Таким чином, квантові шари виявляються найбільш корисними у випадку обмежених, ресурсно-економних CNN-архітектур.

Особливу увагу приділено дослідженню моделей у контексті медичних даних, зокрема набору даних DermaMNIST, де наявна значна міжкласова диспропорція та складні візуальні патерни. Показано, що гібридні моделі демонструють суттєві прирости точності та AUC у порівнянні з класичними аналогами. Підвищення метрик у межах 3–7% для малих LCNet-архітектур є важливим індикатором підвищення стійкості та здатності таких моделей виявляти як домінуючі, так і рідкісні класи патологій. Це дозволяє стверджувати, що квантова частина моделі, яка вносить елемент стохастичності та нелінійності, допомагає формувати більш роздільні представлення ознак саме у випадку складних діагностичних наборів.

Сукупний аналіз отриманих результатів дає змогу сформулювати узагальнене твердження про те, що взаємодія між квантовим та класичним компонентами має

складний, нелінійний характер і суттєво залежить від внутрішньої структури класичної частини. Квантові перетворення не є універсальним доповненням для будь-якої мережі; їхня ефективність зростає тоді, коли класична архітектура ще не повністю вичерпала власну здатність до побудови репрезентативних ознак. Тому оптимальна побудова гібридних нейронних мереж повинна передбачати цілеспрямований добір класичної частини з урахуванням масштабності, глибини та характеру обчислювальної взаємодії з квантовою підсистемою.

Загалом проведене дослідження підтверджує, що ефективність гібридних квантово-класичних моделей визначається не лише параметрами квантового контуру, але й структурною відповідністю класичної частини. Отримані результати дають змогу окреслити перспективу подальших робіт — від дослідження альтернативних варіантів квантових шарів до систематичного аналізу архітектурної сумісності різних типів класичних моделей із некласичними обчисленнями. Це створює підґрунтя для комплексного способу розроблення цілеспрямованих методів побудови гібридних мереж нового покоління, оптимізованих для конкретних класів задач, особливо в умовах обмежених обчислювальних ресурсів та підвищених вимог до точності, як у медичній галузі.

ВИСНОВКИ

У дисертаційній роботі розв'язано актуальну науково-технічну задачу створення та обґрунтування комплексного підходу до трансформації нейронних мереж для використання в контексті неklasичних обчислень, що забезпечує системну інтеграцію параметризованих квантових перетворень у класичні архітектури штучного інтелекту. Вперше запропоновано систематичний спосіб побудови гібридних класично-квантових систем ІІІ, який, на відміну від існуючих підходів, реалізує цілісну трансформацію нейронних мереж на архітектурному, методичному та функціональному рівнях і забезпечує підвищення якості, надійності та узагальнювальної здатності у задачах класифікації за рахунок інтеграції параметризованих квантових перетворень даних з урахуванням різних типів і масштабів квантових трансформацій та класичних архітектур.

Запропонований комплексний спосіб принципово відрізняється від відомих реалізацій, у яких квантовий компонент зазвичай поєднувався з однією фіксованою класичною моделлю або застосовувався як демонстрація концепції без систематичного масштабного аналізу. У межах роботи вперше виконано комплексне дослідження поєднання властивостей квантових трансформацій (типів квантових обертань, кількості квантово-трансформованих каналів, розміру рецептивного поля) та властивостей класичних основ-класифікаторів (типу, масштабу і кількості), що дозволило сформувати узгоджений метод архітектурної гібридизації, придатний до відтворення та масштабування. У найкращих конфігураціях, узагальнених за результатами експериментів, продемонстровано покращення точності до +6,7% та зростання AUC_macro до +0,039 порівняно з відповідними класичними моделями (як інтегральний підсумок для найуспішніших комбінацій перетворень і основ).

Набув подальшого розвитку підхід використання квантової згортки (quanvolution) як механізму формування додаткових квантово-індукованих ознак у вигляді багатоканального подання вхідного зображення. Експериментально показано, що збільшення кількості квантових каналів приводить до зростання

метрик якості до певного рівня, після чого проявляється ефект насичення: на наборі даних CIFAR-10 монотонне покращення триває до QC9, тоді як у варіантах QC17–QC18 точність зростає ще приблизно на $\approx 2\%$, але покращення AUC становить менше 1%, що дозволяє виділити діапазон QC5–QC9 як практично оптимальний баланс між якістю та ресурсами. Паралельно зі зростанням якості фіксується підвищення стабільності: варіативність між фолдами зменшується (зокрема, AUC_std знижується з 0.020 до ≈ 0.012), що узгоджується з інтерпретацією квантово-індукованої ознакової надбудови як регуляризатора, здатного зменшувати розкид оцінок у стратифікованій перехресній валідації.

Експериментально встановлено, що ефективність гібридизації суттєво залежить від типу та масштабу класичної основи, причому найбільший практичний ефект досягається для компактних і середніх архітектур. Для набору даних CIFAR-10 показано, що комбінована конфігурація HNN-5QC (YW4+O1) забезпечує підвищення точності з 0.735 ± 0.012 до 0.769 ± 0.002 та AUC_macro з 0.965 ± 0.002 до 0.969 ± 0.001 порівняно з базовою моделлю. У задачі з масштабуванням LCNet також продемонстровано, що гібридні варіанти для компактних/середніх моделей дають одночасно приріст середніх значень і зменшення стандартного відхилення: наприклад, для LCNet050 стандартне відхилення точності зменшується з 0.0151 до 0.0074, а для LCNet075 — з 0.0216 до 0.0063, що відображає суттєве зростання стабільності оцінювання. Для набору DermaMNIST підтверджено важливість вибору класичної частини: модель на основі LCNet050 стабільно переважає MobileNetV3Small050 за ключовими метриками (AUC_macro 0.9540 проти 0.9340, AUC_micro 0.9585 проти 0.9381, $\Delta AUC \approx 0.02$), причому цей приріст перевищує дисперсії показників і розглядається як статистично значущий ефект покращення.

Вперше розроблено, реалізовано та експериментально верифіковано уніфікований конвеєрний процес робочих операцій (workflow) оцінювання гібридних квантово-класичних нейронних мереж для задач класифікації (зокрема медичних), який забезпечує стандартизоване та відтворюване порівняння гібридних і класичних архітектур. Методика поєднує стратифіковану

перехресну 5-fold валідацію та агрегацію Out-of-Fold прогнозів, що підвищує статистичну надійність оцінок і виключає витік інформації між підмножинами; також реєструються точність, AUC_macro, AUC_micro та стандартні відхилення як показники стабільності. Запропонований workflow є придатним для гібридних моделей із довільною класичною основою та дозволяє коректно робити висновки щодо доцільності гібридизації для даних різної природи (зокрема, для контрастних наборів даних CIFAR-10 і DermaMNIST).

Практичне значення отриманих результатів полягає у формалізації комплексного способу побудови гібридних квантово-класичних моделей та створенні відтворюваної методики експериментальної перевірки, яка зменшує потребу в несистемному емпіричному переборі та прискорює проєктування моделей під конкретні умови задачі. Сукупність одержаних закономірностей щодо вибору типів квантових перетворень, кількості каналів і параметрів класичної основи може бути використана для практико-орієнтованих задач класифікації зображень із підвищеними вимогами до надійності та узагальнення, насамперед у доменах з високою варіативністю та дисбалансом даних.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Montanaro A. Quantum algorithms: an overview. *NPJ Quantum Information*. 2016. 2:15023. DOI: 10.1038/npjqi.2016.23.
2. Feynman R. P. Simulating physics with computers. *International Journal of Theoretical Physics*. 1982. 21(6/7). P. 467–488. DOI: 10.1007/BF02650179
3. Nielsen M. A., Chuang I. L. *Quantum Computation and Quantum Information*. Cambridge: Cambridge University Press, 2010. 676 p.
4. Shor P. W. Polynomial-time algorithms for prime factorization and discrete logarithms on a quantum computer. *SIAM Journal on Computing*. 1997. 26(5). P. 1484–1509. DOI: 10.1137/S0097539795293172.
5. Grover L. K. Quantum mechanics helps in searching for a needle in a haystack. *Physical Review Letters*. 1997. 79(2). P. 325–328. DOI: 10.1103/PhysRevLett.79.325.
6. Preskill J. Quantum computing and the entanglement frontier. *Reports on Progress in Physics*. 2012. 75(8). Article 082001. DOI: 10.1088/0034-4885/75/8/082001.
7. Shor P. W. Scheme for reducing decoherence in quantum computer memory. *Physical Review A*. 1995. 52(4). R2493–R2496. DOI: 10.1103/PhysRevA.52.R2493.
8. Steane A. Multiple-particle interference and quantum error correction. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*. 1996. 452(1954). P. 2551–2577. DOI: 10.1098/rspa.1996.0136.
9. Fowler A. G., Mariantoni M., Martinis J. M., Cleland A. N. Surface codes: Towards practical large-scale quantum computation. *Physical Review A*. 2012. 86(3). Article 032324. DOI: 10.1103/PhysRevA.86.032324.
10. Campbell E. T., Terhal B. M., Vuillot C. Roads towards fault-tolerant universal quantum computation. *Nature*. 2017. 549(7671). P. 172–179. DOI: 10.1038/nature23460.
11. Blatt R., Wineland D. Entangled states of trapped ions. *Nature*. 2008. 453(7198). P. 1008–1015. DOI: 10.1038/4531008a.

12. IonQ. IonQ unveils 32-qubit trapped-ion quantum computer [Электронный ресурс] – 2020. URL: <https://ionq.com/news/september-29-2020-ionq-unveils-32-qubit-quantum-computer>.
13. Devoret M. H., Schoelkopf R. J. Superconducting circuits for quantum information: an outlook. *Science*. 2013. 339(6124). P. 1169–1174. DOI: 10.1126/science.1231930.
14. Kjaergaard M., Schwartz M. E., Greene A. D. et al. Superconducting qubits: current state of play. *Annual Review of Condensed Matter Physics*. 2020. 11. P. 369–395. DOI: 10.1146/annurev-conmatphys-031119-050605.
15. Arute F., Arya K., Babbush R. et al. Quantum supremacy using a programmable superconducting processor. *Nature*. 2019. 574(7779). P. 505–510. DOI: 10.1038/s41586-019-1666-5.
16. Chiaverini J., Sage J. M. Insensitivity of the rate of ion-micromotion-induced heating to trap electrode material over a large temperature range. *Physical Review A*. 2014. 89(1). Article 012318. DOI: 10.1103/PhysRevA.89.012318.
17. Egan J. P., Noel C., Risinger A. et al. Fault-tolerant control of an error-corrected qubit in a trapped-ion quantum computer. *Nature*. 2021. 598(7882). P. 281–286. DOI: 10.1038/s41586-021-03928-y.
18. Raussendorf R., Harrington J. Fault-tolerant quantum computation with high threshold in two dimensions. *Physical Review Letters*. 2007. 98(19). Article 190504. DOI: 10.1103/PhysRevLett.98.190504.
19. Gottesman D. An introduction to quantum error correction and fault-tolerant quantum computation. *Proceedings of the 22nd International Conference on Quantum Information (ICQI 2009)*. 2009. P. 13–21.
20. Cao Y., Romero J., Olson J. P. et al. Quantum chemistry in the age of quantum computing. *Chemical Reviews*. 2019. 119(19). P. 10856–10915. DOI: 10.1021/acs.chemrev.8b00803.
21. Goings J. J., White A. F., Lee J. et al. Reliably assessing the electronic structure of cytochrome P450 on today's classical computers and tomorrow's

- quantum computers. Proceedings of the National Academy of Sciences of the USA. 2022. 119(38). e2203533119. DOI: 10.1073/pnas.2203533119.
- 22.Irving M. Liquid metal catalyst quickly converts carbon dioxide into solid carbon [Електронний ресурс] // New Atlas. 18 січня 2022. URL: <https://newatlas.com/environment/liquid-metal-carbon-dioxide-capture-solid/>.
- 23.Di Paola C., Pirandola S., Memarzadeh L. Quantum local algorithms for global optimization. Nature Communications. 2022. 13. Article 4152. DOI: 10.1038/s41467-022-31886-5.
- 24.Lany S., Zunger A. Accurate prediction of defect properties in density-functional supercell calculations. Modeling and Simulation in Materials Science and Engineering. 2009. 17(8). Article 084002. DOI: 10.1088/0965-0393/17/8/084002.
- 25.Dowling J. P., Milburn G. J. Quantum technology: the second quantum revolution. Philosophical Transactions of the Royal Society A. 2003. 361(1809). P. 1655–1674. DOI: 10.1098/rsta.2003.1227.
- 26.Abbott B. P., Abbott R., Abbott T. D. et al. Observation of gravitational waves from a binary black hole merger. Physical Review Letters. 2016. 116(6). Article 061102. DOI: 10.1103/PhysRevLett.116.061102.
- 27.Tse M., Yu H., Kijbunchoo N. et al. Quantum-enhanced advanced LIGO detectors in the era of gravitational-wave astronomy. Physical Review Letters. 2019. 123(23). Article 231107. DOI: 10.1103/PhysRevLett.123.231107.
- 28.Huang Y., Macquarrie E. R., Capelluto L. et al. Quantum-inspired sensor fusion for underwater navigation. IEEE Sensors Journal. 2020. 20(23). P. 14434–14442. DOI: 10.1109/JSEN.2020.3008775.
- 29.Lüders C., Jain R., Bandyopadhyay S. Quantum radar: a status and perspectives review. Applied Physics Reviews. 2023. 10(1). Article 011307. DOI: 10.1063/5.0105231.

30. Taylor M. A., Janousek J., Daria V. et al. Biological measurement beyond the quantum limit. *Nature Photonics*. 2013. 7(3). P. 229–233. DOI: 10.1038/nphoton.2012.346.
31. Togacar M., Ergen B., Comert Z., Subhasis M. Retinal disease detection based on convolutional neural networks using OCT images. *Proceedings of the 23rd International Conference Electronics*. 2019. P. 507–510.
32. Ahalya R. K., Almutairi F. M., Snehalatha U. et al. RANet: a custom CNN model and quantum convolutional neural network for the automated detection of rheumatoid arthritis in hand thermal images. *Scientific Reports*. 2023. 13. Article 15638. DOI: 10.1038/s41598-023-42111-3.
33. Ullah U., García Olea Jurado A., Díez González I. et al. A fully connected quantum convolutional neural network for classifying ischemic cardiopathy. *IEEE Access*. 2022. 10. P. 134592–134605. DOI: 10.1109/ACCESS.2022.3232307.
34. Dong Y., Fu Y., Liu H. et al. An improved hybrid quantum-classical convolutional neural network for multi-class brain tumor MRI classification. *Journal of Applied Physics*. 2023. 133(6). Article 064401. DOI: 10.1063/5.0138021.
35. Kyro G. W., Brent R. I., Batista V. S. HAC-Net: a hybrid attention-based convolutional neural network for highly accurate protein–ligand binding affinity prediction. *Journal of Chemical Information and Modeling*. 2023. 63(7). P. 1947–1960. DOI: 10.1021/acs.jcim.3c0025.
36. Yan F., Dang Y., Lu Y. et al. Quantum image processing: a review of advances in its security technologies. *Cryptography*. 2020. 4(1). Article 2. DOI: 10.3390/cryptography4010002.
37. Henderson M., Shakya S., Pradhan S., Tassiulas L. Quantum convolutional neural networks: powering image recognition with quantum circuits. *Quantum Machine Intelligence*. 2020. 2(2). Article 20. DOI: 10.1007/s42484-020-00012-y.

38. Zhang T., Li A., Lin S. Quantum-inspired fully complex-valued neural network for sentiment analysis. *Electronics*. 2022. 11(14). Article 2144. DOI: 10.3390/electronics11142144.
39. Li S., Song H., Zhang Y. Hybrid quantum-classical convolutional neural networks with amplitude encoding. *Entropy*. 2021. 23(7). Article 874. DOI: 10.3390/e23070874.
40. Chen H., Li X., Liu W., Xu X. Quantum convolutional neural networks in feature fusion for image classification. *IEEE Transactions on Neural Networks and Learning Systems*. 2023. 34(1). P. 391–405. DOI: 10.1109/TNNLS.2021.3077440.
41. Zhu D., Christensen B. T. Quantum optical convolutional neural networks. *Optica*. 2022. 9(5). P. 586–593. DOI: 10.1364/OPTICA.442219.
42. KeQuantum X., Trugger D., Ye L. et al. Quantum convolutional neural networks for image classification. *Proceedings of IEEE Quantum Week (QCE 2021)*. 2021. P. 272–282.
43. Khoshaman A., Siddiqui S., McMahon P. L. et al. Quantum variational autoencoder. *Quantum Science and Technology*. 2018. 4(1). Article 014001. DOI: 10.1088/2058-9565/aad4c4.
44. Schuld M., Petruccione F., Beer K. Quantum autoencoders for efficient compression of quantum data. *Physical Review A*. 2020. 101(3). Article 032314. DOI: 10.1103/PhysRevA.101.032314.
45. Chen S. Y., Yoo S. J. Towards quantum-inspired deep neural networks: a complex-valued perspective. *IEEE Access*. 2020. 8. P. 142034–142048. DOI: 10.1109/ACCESS.2020.3013968.
46. IBM Quantum platform [Электронный ресурс] – 2025. URL: <https://quantum-computing.ibm.com>.
47. IBM. IBM Unveils Breakthrough 127-Qubit Quantum Processor – IBM Newsroom, 16.11.2021. URL: <https://newsroom.ibm.com/2021-11-16-IBM-Unveils-Breakthrough-127-Qubit-Quantum-Processor>
48. Qiskit: An Open-Source Quantum Computing Framework [Электронный ресурс] – IBM, 2023. URL: <https://qiskit.org>.

49. Microsoft Azure Quantum [Електронний ресурс] – Microsoft, 2025. URL: <https://azure.microsoft.com/en-us/products/quantum>.
50. IonQ (компанія) [Електронний ресурс] – 2025. URL: <https://ionq.com>.
51. Pasqal (компанія) [Електронний ресурс] – 2025. URL: <https://pasqal.com>.
52. Quantinuum (Honeywell & Cambridge Quantum) [Електронний ресурс] – 2025. URL: <https://www.quantinuum.com>.
53. Rigetti Computing [Електронний ресурс] – 2025. URL: <https://www.rigetti.com>.
54. AWS Braket – Quantum computing on Amazon Web Services [Електронний ресурс] – Amazon, 2025. URL: <https://aws.amazon.com/braket>.
55. IQM Quantum Computers [Електронний ресурс] – 2025. URL: <https://www.meetiqm.com>.
56. QuEra Computing (neutral-atom quantum systems) [Електронний ресурс] – 2025. URL: <https://www.quera.com>.
57. Neven H. Meet Willow, our state-of-the-art quantum chip [Електронний ресурс] – Google AI Blog, 09.12.2024. URL: <https://blog.google/technology/research/google-willow-quantum-chip>.
58. IBM. IBM Osprey – новий 433-кубітний квантовий процесор [Електронний ресурс] – Прес-реліз IBM, 09.11.2022. URL: <https://newsroom.ibm.com/2022-11-09-IBM-Unveils-400-Qubit-Plus-Quantum-Processor>.
59. Castelvechi D. IBM releases first-ever 1,000-qubit quantum chip [Електронний ресурс] – Nature News, 04.12.2023. URL: <https://www.nature.com/articles/d41586-023-03875-3>.
60. Cherney M. A. Google says commercial quantum computing applications arriving within five years [Електронний ресурс] – Reuters, 05.02.2025. URL: <https://www.reuters.com/technology/google-says-commercial-quantum-computing-applications-arriving-within-five-years-2025-02-05>.
61. Nellis S. IBM aims for quantum computer in 2029, lays out road map for larger systems [Електронний ресурс] – Reuters, 10.06.2025. URL:

- <https://www.reuters.com/business/retail-consumer/ibm-aims-quantum-computer-2029-lays-out-road-map-larger-systems-2025-06-10>.
62. PennyLane: Hybrid Quantum Computing Library [Электронный ресурс] – Xanadu, 2025. URL: <https://pennylane.ai>.
 63. Kaggle – Online platform for data science competitions [Электронный ресурс] – 2025. URL: <https://www.kaggle.com>.
 64. Google Colaboratory – Cloud GPU platform [Электронный ресурс] – Google, 2025. URL: <https://colab.research.google.com>.
 65. Fowler A. G., Whiting E., McKay D. C. et al. Surface code quantum error correction incorporating accurate error propagation. *Quantum Science and Technology*. 2023. 8(4). Article 045010. DOI: 10.1088/2058-9565/acf0cb.
 66. Gheorghiu A., Kapourniotis T., Kashefi E. Verification of quantum computation: an overview of existing approaches. *Theory of Computing Systems*. 2019. 63. P. 715–808. DOI: 10.1007/s00224-018-9872-3.
 67. Bharti K., Cervera-Lierta A., Kyaw T. H. et al. Noisy intermediate-scale quantum algorithms. *Reviews of Modern Physics*. 2022. 94(1). Article 015004. DOI: 10.1103/RevModPhys.94.015004.
 68. Krizhevsky A., Nair V., Hinton G. CIFAR-10 (Canadian Institute for Advanced Research) [Электронный ресурс] – 2009. URL: <https://www.cs.toronto.edu/~kriz/cifar.html>
 69. Sharma K., Khatri S., Cerezo M., Coles P. J. Noise resilience of variational quantum compiling. *New Journal of Physics*. 2020. 22(4). Article 043006. DOI: 10.1088/1367-2630/ab784c.
 70. Yang J., Shi R., Wei H. et al. MedMNIST: A lightweight automatable benchmark for medical image analysis. *Nature Communications*. 2021. 12. Article 5577. DOI: 10.1038/s41467-021-25532-1.
 71. Kohavi R. A study of cross-validation and bootstrap for accuracy estimation and model selection. *Proceedings of the 14th International Joint Conference on Artificial Intelligence (IJCAI '95)*. 1995. P. 1137–1145.
 72. Nielsen M. A. The Bloch sphere. *Am. J. Phys.* 2002. 70(3). P. 558. DOI: 10.1119/1.1466803.

73. Nielsen M. A., Chuang I. L. Programmable quantum gate arrays. *Physical Review Letters*. 1997. 79(2). P. 321–324. DOI: 10.1103/PhysRevLett.79.321.
74. Preskill J. Reliable quantum computers. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*. 1998. 454(1969). P. 385–410. DOI: 10.1098/rspa.1998.0167.
75. Bennet C. H., DiVincenzo D. P., Fuchs C. A. et al. Quantum privacy amplification and the security of quantum cryptography over noisy channels. *Physical Review A*. 1995. 52(5). P. 2564–2575. DOI: 10.1103/PhysRevA.52.2564.
76. Nielsen M. A., Caves C. M., Schumacher B., Barnum H. Information-theoretic approach to quantum error correction and reversible measurement. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*. 1998. 454(1969). P. 277–304. DOI: 10.1098/rspa.1998.0162.
77. Gottesman D., Chuang I. L. Quantum teleportation is a universal computational primitive. *Nature*. 1999. 402(6761). P. 390–393. DOI: 10.1038/46503.
78. Lloyd S. Quantum approximate optimization is computationally universal. *arXiv preprint*, 2018. arXiv:1812.11075 [quant-ph].
79. Schuld M., Killoran N. Quantum machine learning in feature Hilbert spaces. *Physical Review Letters*. 2019. 122(4). Article 040504. DOI: 10.1103/PhysRevLett.122.040504.
80. Havlíček V., Córcoles A. D., Temme K. et al. Supervised learning with quantum-enhanced feature spaces. *Nature*. 2019. 567(7747). P. 209–212. DOI: 10.1038/s41586-019-0980-2.
81. Zhou L., Wang S. J., Choi Y. et al. Quantum Approximate Optimization Algorithm: performance, mechanism, and implementation on near-term devices. *Physical Review X*. 2020. 10(2). Article 021067. DOI: 10.1103/PhysRevX.10.021067.
82. Python Software Foundation. Python Language Reference, version 3.x [Электронный ресурс] – 2024. URL: <https://www.python.org>

83. Paszke A., Gross S., Massa F. et al. PyTorch: An imperative style, high-performance deep learning library. *Advances in Neural Information Processing Systems (NeurIPS)*. 2019. 32. P. 8024–8035.
84. Abadi M., Barham P., Chen J. et al. TensorFlow: A system for large-scale machine learning. *Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI)*. 2016. P. 265–283.
85. Kluyver T., Ragan-Kelley B., Pérez F. et al. Jupyter Notebooks — a publishing format for reproducible computational workflows. *Positioning and Power in Academic Publishing: Players, Agents and Agendas*. 2016. P. 87–90.
86. MedMNIST v2 – A Large-Scale Lightweight Benchmark for 2D and 3D Biomedical Image Classification [Электронный ресурс] – GitHub, 2021. URL: <https://medmnist.github.io>.
87. Keras API Reference [Электронный ресурс] – Python Software Foundation, 2025. URL: <https://keras.io/api>.

ДОДАТОК А

Список публікацій здобувача

1. Khmelnytskyi, A., Stirenko, S., Gordienko, Y. (2024). Hybrid Neural Networks for Medical Image Classification. In: Manoharan, S., Tugui, A., Baig, Z. (eds) Proceedings of 4th International Conference on Artificial Intelligence and Smart Energy. ICAIS 2024. Information Systems Engineering and Management, vol 3. Springer, Cham. https://doi.org/10.1007/978-3-031-61471-2_35 ISSN 3004-958X
2. Khmelnytskyi, A.; Gordienko, Y.; Trochun, Y.; Taran, V.; Stirenko, S. HNN-QCn: Hybrid Neural Network with Multiple Backbones and Quantum Transformation as Data Augmentation Technique. *AI* **2025**, 6, 36. <https://doi.org/10.3390/ai6020036> ISSN 2673-2688 (Scopus).
3. Khmelnytskyi, A.; Gordienko, Y.; Stirenko, S. Impact of Scaling Classic Component on Performance of Hybrid Multi-Backbone Quantum–Classic Neural Networks for Medical Applications. *Computation* **2025**, 13, 278. <https://doi.org/10.3390/computation13120278> ISSN 2079-3197 (Scopus).
4. Khmelnytskyi, A., Gordienko, Y., Taran, V., Stirenko, S. (2025). Hybrid Neural Networks with Multi-channel Quantvolutional Input for Medical Image Classification. In: Lanka, S., Cabezuelo, A.S., Vuppalapati, C. (eds) Trends in Sustainable Computing and Machine Intelligence. ICTSM 2024. Algorithms for Intelligent Systems. Springer, Singapore. https://doi.org/10.1007/978-981-96-1452-3_15 ISSN 2524-7565
5. A. Khmelnytskyi and Y. Gordienko, “Comparative analysis of LCNet050 and MobileNetV3 architectures in hybrid quantum–classical neural networks for image classification”, *Inf. Comput. and Intell. syst. j.*, no. 7, pp. 49–60, Dec. **2025**. <https://doi.org/10.20535/2786-8729.7.2025.333887> ISSN 2786-8729