

О. В. БОЙКО

кандидат технічних наук,
старший викладач кафедри інформаційних технологій
Сумський державний університет
ORCID: 0000-0001-8557-2267

М. Д. ТАТАРЕНКО

аспірант кафедри комп'ютерних наук
Сумський державний університет
ORCID: 0009-0000-9649-4620

АНАЛІЗ ЕФЕКТИВНОСТІ НЕЙРОННИХ МОДЕЛЕЙ У ЗАДАЧАХ ОБРОБКИ УЛЬТРАЗВУКОВИХ ДІАГНОСТИЧНИХ ЗНІМКІВ

У статті здійснено порівняльний аналіз ефективності застосування простих штучних нейронних мереж (ANN) та згорткових нейронних мереж (CNN) у задачах обробки ультразвукових діагностичних знімків. Актуальність дослідження зумовлена широким використанням УЗД у клінічній практиці та обмеженнями, які притаманні цьому методу візуалізації, зокрема – низькою контрастністю, високим рівнем шуму та залежністю якості зображення від типу апаратури й кваліфікації оператора. В умовах зростаючого обсягу медичних даних і потреби в автоматизованих системах підтримки прийняття рішень нейронні моделі виступають перспективним інструментом підвищення діагностичної інформативності знімків.

Для досягнення мети було проведено експериментальне моделювання із використанням відкритого набору ультразвукових зображень молочної залози, доступного на платформі Kaggle. Вихідні знімки були масштабовані з 500×500 до 128×128 пікселів з метою зменшення обчислювального навантаження. Було реалізовано дві архітектури: базову ANN з одним прихованим шаром та CNN з трьома згортковими шарами. Моделі оцінювались за метриками точності класифікації, повноти, специфічності, F1-мірою, швидкістю та інтерпретованістю.

Результати дослідження показали, що CNN суттєво перевершує ANN за всіма ключовими критеріями. Середня точність класифікації CNN склала 86,4 % проти 71,3 % у ANN. Важливо, що CNN забезпечувала кращу стабільність результатів при зміні джерел даних та рівня шуму, а також дозволяла використовувати Grad-CAM для візуалізації ділянок з найбільшим впливом на класифікаційне рішення. ANN, у свою чергу, виявилась менш чутливою до локальних текстурних ознак, проте мала перевагу в обчислювальній простоті.

Зроблено висновок про доцільність використання CNN у клінічних умовах, де пріоритетом є точність та надійність результатів, тоді як ANN може бути корисною в системах попередньої фільтрації або в умовах обмежених обчислювальних ресурсів. Стаття також підкреслює важливість врахування апаратних особливостей джерел зображень та перспективність розвитку гібридних архітектур з високим рівнем інтерпретованості.

Ключові слова: нейронні мережі, нейрон, згорткові нейронні мережі, штучні нейронні мережі, навчання нейронної мережі, обробка зображень, ультразвукова діагностика, глибинне навчання.

O. V. BOYKO

Candidate of Technical Sciences,
Senior Lecturer at the Department of Information Technology
Sumy State University
ORCID: 0000-0001-8557-2267

M. D. TATARENKO

Postgraduate Student at the Computer Science Department
Sumy State University
ORCID: 0009-0000-9649-4620

ANALYSIS OF NEURAL MODEL EFFECTIVENESS IN ULTRASOUND DIAGNOSTIC IMAGE PROCESSING

This article presents a comparative analysis of the effectiveness of using simple artificial neural networks (ANN) and convolutional neural networks (CNN) for processing ultrasound diagnostic images. The relevance of the study stems from the widespread use of ultrasound imaging in clinical practice, along with its inherent limitations such as low contrast, high noise levels, and dependency on both the equipment and operator's experience. In the context of increasing volumes of medical data and the growing need for automated decision support systems, neural models offer a promising tool for enhancing the diagnostic value of ultrasound images.

To achieve the research objective, an experimental simulation was conducted using an open-access dataset of breast ultrasound images available on the Kaggle platform. The original images were downscaled from 500×500 to 128×128 pixels to reduce computational load. Two neural network architectures were implemented: a basic ANN with a single hidden layer and a CNN with three convolutional layers. The models were evaluated based on classification accuracy, recall, precision, F1-score, inference speed, and interpretability.

The results demonstrated that CNN significantly outperformed ANN across all major performance metrics. CNN achieved an average classification accuracy of 86.4 %, compared to 71.3 % for ANN. Furthermore, CNN provided more stable performance under varying image quality and noise conditions and enabled the use of Grad-CAM for highlighting the most influential regions in the decision-making process. While ANN was less sensitive to local textural features, it offered advantages in computational simplicity and inference speed (under 5 ms per image).

The study concludes that CNN is more suitable for clinical settings where accuracy and reliability are critical, whereas ANN may be useful for preliminary filtering or in systems with limited computational resources. The article also emphasizes the importance of considering hardware-specific variations in image sources and highlights the future potential of hybrid, interpretable neural architectures in medical imaging.

Key words: neural networks, neuron, convolutional neural networks (CNN), artificial neural networks (ANN), neural network training, image processing, ultrasound diagnostics, deep learning.

Постановка проблеми

Ультразвукова діагностика (УЗД) є одним із найбільш поширених та доступних методів візуалізації в сучасній медичній практиці. Її безпечність, відносна дешевизна та оперативність забезпечують широке застосування у багатьох галузях клінічної медицини – від акушерства до онкології. Однак, незважаючи на численні переваги, якість отриманих зображень залишається обмеженою через фізичні властивості ультразвукових хвиль та анатомо-фізіологічні характеристики тканин. До основних факторів, що знижують діагностичну інформативність УЗ-зображень, належать дифракційні ефекти, аберації, шумові спотворення, розсіювання хвиль та артефакти, зумовлені неоднорідністю акустичних середовищ.

Особливої актуальності проблема набуває в умовах необхідності детальної візуалізації дрібних структур, таких як малі новоутворення, дрібні судини чи дифузні зміни паренхіми органів. Традиційні методи покращення зображення мають обмежену ефективність та не дозволяють суттєво підвищити роздільну здатність без втрати клінічно значимої інформації.

У цьому контексті зростає роль штучного інтелекту, зокрема нейронних мереж, як інструменту постобробки ультразвукових зображень. Сучасні моделі машинного навчання, зокрема згорткові нейронні мережі, трансформери та генеративні архітектури, демонструють високий потенціал у задачах покращення візуального представлення медичних даних. Проте ефективність різних підходів у контексті саме ультразвукових зображень є неоднозначною та потребує системного аналізу з урахуванням особливостей УЗД – високої варіативності знімків, наявності великої кількості шумів і складності анотування даних.

Проблема вибору та оцінки нейронної архітектури, яка забезпечить найкращий баланс між якістю реконструкції, обчислювальною ефективністю та клінічною інтерпретованістю результатів, залишається відкритою, так само як і питання інтеграції таких рішень у медичні системи з дотриманням нормативних вимог і забезпеченням прозорості.

Аналіз останніх досліджень і публікацій

У сучасній науковій літературі все більшої популярності набувають дослідження, присвячені застосуванню нейронних мереж для покращення якості ультразвукових знімків, які є одним із ключових інструментів у діагностичному процесі в різних галузях медицини. УЗД використовується в акушерстві, кардіології, гастроентерології, ангіології та інших спеціальностях завдяки своїй неінвазивності, доступності й високій швидкості обстеження. Водночас ультразвукові зображення мають низький рівень контрастності, високу залежність від якості апаратури та досвіду оператора, а також зазнають значного впливу шумів та артефактів. У зв'язку з цим значна частина сучасних дослідницьких зусиль зосереджена на підвищенні точності діагностики шляхом використання глибоких моделей машинного навчання для вдосконалення зображень, покращення їх інтерпретованості та автоматизованого аналізу.

Незважаючи на розмаїття нейромережевих архітектур, які пропонуються для обробки зображень, одним із базових підходів залишається використання простих штучних нейронних мереж (ANN) із одним прихованим шаром. Такі моделі мають переваги у вигляді низької обчислювальної складності та швидкого навчання, що робить їх зручними для використання в системах із обмеженими ресурсами або в якості базових референтних моделей для порівняльного аналізу. У роботі Kim & Kim [1] демонструється використання ANN для класифікації ультразвукових зображень. Хоча результати свідчать про здатність таких моделей до розпізнавання основних категорій зображень, їх ефективність є обмеженою в задачах високоточного виявлення патологій через неспроможність обробляти складні просторові залежності, властиві медичним знімкам.

Значну перевагу в подібних завданнях демонструють згорткові нейронні мережі (CNN), які побудовані з урахуванням просторової структури зображень. CNN здатні виділяти локальні ознаки, виявляти контури, текстури та інші ключові деталі, що суттєво підвищує точність класифікації та локалізації об'єктів. Наприклад, у дослідженні Wu та співавт. [2] виконано пряме порівняння CNN і ANN на множині УЗ-зображень, отриманих з різних типів апаратів. Згідно з результатами, CNN забезпечує покращення точності діагностичної класифікації на 15–20 %, що є суттєвим у клінічному контексті. Додатково автори підкреслюють важливість врахування характеристик апаратного забезпечення: враховуючи, що різні ультразвукові сканери продукують зображення зі змінними характеристиками, CNN виявились більш адаптивними до таких відмінностей.

У клінічній практиці важливо не лише отримати точний результат класифікації або сегментації, але й зрозуміти, чому модель прийняла те чи інше рішення. Саме тому інтерпретованість моделей відіграє дедалі важливішу роль. Метод Grad-CAM (Gradient-weighted Class Activation Mapping), описаний у роботі Selvaraju та ін. [3], дозволяє створювати теплові карти, які відображають зони, що були найбільш значущими для прийняття рішення CNN. У контексті УЗ-зображень цей підхід допомагає лікарю зіставити прогноз моделі з реальним анатомічним вмістом, і таким чином забезпечує додатковий рівень довіри до автоматизованої системи. Інтерпретованість також важлива у навчанні молодих спеціалістів, які можуть використовувати такі візуалізації для розуміння діагностичних критеріїв.

Ще одним аспектом, який активно розглядається у наукових роботах, є баланс між точністю та обчислювальною ефективністю. Це особливо актуально для впровадження моделей на портативних пристроях або в умовах обмежених ресурсів, наприклад, у сільських лікарнях чи під час виїзної діагностики. У дослідженні Zhang та ін. [4] було проаналізовано використання легких архітектур, таких як MobileNet, для обробки УЗ-зображень у режимі реального часу. Хоча ANN має перевагу у швидкості, CNN продемонструвала кращу здатність до виявлення патологічних структур при збереженні низької затримки, що робить її практично прийнятною для клінічного використання навіть без графічного процесора.

Ще один важливий виклик – це доступність анотованих медичних даних. Велика кількість моделей вимагає для навчання значної кількості маркованих зображень. У роботі Chen та ін. [5] розглянуто підходи до навчання CNN в умовах обмежених анотованих наборів даних за допомогою методів слабкого навчання та перенавчання (transfer learning). Автори довели, що попереднє тренування моделей на суміжних задачах, навіть не з медичної сфери, дозволяє успішно адаптувати їх до специфіки ультразвукових зображень. Це відкриває нові можливості для малих клінік і дослідницьких центрів, які не мають доступу до великих відкритих датасетів.

Таким чином, на основі аналізу сучасних публікацій можна зробити висновок, що згорткові нейронні мережі мають істотну перевагу над простими ANN у задачах покращення ультразвукових зображень. Вони демонструють вищу точність класифікації, кращу інтерпретованість, адаптивність до апаратного різноманіття та ефективність у реальному часі. Це робить CNN одними з найперспективніших інструментів для впровадження в клінічну практику обробки УЗ-даних, особливо в умовах високої варіативності зображень та потреби у пояснюваності результатів.

Формулювання мети дослідження

Метою даного дослідження є системний аналіз ефективності простих нейронних мереж та згорткових нейронних мереж (CNN) у задачах обробки ультразвукових діагностичних знімків з акцентом на точність діагностики та інтерпретованість моделей.

Завданнями дослідження є:

- порівняти продуктивність простої нейронної мережі з одним прихованим шаром та CNN у контексті класифікації патологій на УЗ-знімках;
- оцінити вплив характеристик апаратного забезпечення на якість обробки та точність моделей;
- проаналізувати можливості підвищення інтерпретованості результатів за допомогою методів візуалізації (наприклад, Grad-CAM);
- визначити компроміс між обчислювальною складністю моделей та їх клінічною ефективністю;
- розробити рекомендації щодо вибору нейронної архітектури для інтеграції у медичні інформаційні системи.

Досягнення поставленої мети сприятиме підвищенню якості ультразвукової діагностики за рахунок впровадження оптимальних нейронних моделей, що забезпечать баланс між точністю, швидкістю і прозорістю результатів, а також адаптацію до особливостей різного апаратного забезпечення.

Викладення основного матеріалу дослідження

Для реалізації поставленої мети було обрано два типи нейронних мереж – проста штучна нейронна мережа (ANN) з одним прихованим шаром та згорткова нейронна мережа (CNN) із базовою трирівневою архітектурою. Обидва підходи були протестовані в умовах обробки різних типів ультразвукових знімків.

У якості джерела даних було використано відкритий набір «Breast Ultrasound Images Dataset», доступний на платформі Kaggle [1]. Цей набір даних є відкритим медичним ресурсом, який використовується для навчання та тестування моделей машинного навчання у завданнях виявлення та класифікації новоутворень молочної залози. У ньому представлено 780 ультразвукових знімків, отриманих від 600 пацієнтів.

Кожне зображення позначене відповідною міткою, яка вказує на тип тканини: нормальна, доброякісна або злоякісна. Завдяки такій класифікації цей набір даних є придатним для задач навчання з вчителем. Окрім самих знімків, у ньому також містяться маски (розмітки), що відображають контури уражених ділянок. Це дозволяє використовувати дані не лише для класифікації, але й для сегментації, що є важливим у випадках, коли необхідно локалізувати новоутворення.




Рис. 1. Класифікація новоутворень за типом тканини: а) нормальне (пухлини відсутні), б) доброякісне, в) злоякісне

Для уніфікації обробки та зниження обчислювального навантаження всі знімки були зменшені з початкової роздільної здатності 500×500 пікселів до 128×128 пікселів.

Дані для дослідження були неанотованими, а тому попередня обробка включала нормалізацію яскравості, зменшення шуму за допомогою медіанного фільтра та стандартизоване масштабування. Таким чином забезпечено однакові умови для обох архітектур.

Проста ANN містила вхідний шар розміром 16 384 (для 128×128 зображень, представлених у векторному вигляді), один прихований шар із 128 нейронів із функцією активації ReLU та вихідний шар для двокласової класифікації (наявність/відсутність патології). Така архітектура дозволяла забезпечити швидке навчання і низьке навантаження на апаратну частину, але мала суттєві обмеження щодо просторового сприйняття зображення.

CNN-архітектура включала три згорткові шари з ядрами 3×3 , за якими слідували шари підвибірки (max-pooling), та два повноз'язні шари на завершення. Для регуляризації використовувалась відсічення (dropout) на рівні 0.4. Загальна кількість параметрів складала близько 110 тис., що вважається середнім показником обчислювальної складності для подібних задач. Усі шари активувались функцією ReLU, крім останнього (Softmax).

Точність діагностики визначалася на підставі візуального розпізнавання патологічних елементів (наприклад, гіпоехогенних зон, зміненої структури тканин) та формальної оцінки за метриками precision, recall і F1-score. ANN показала середню точність на рівні 71,3 %, із помітними похибками при обробці зображень низької якості. Найчастіше мережа помилково інтерпретувала тіньові артефакти як ознаки патології.

Натомість CNN продемонструвала суттєво вищу стабільність результатів із середньою точністю 86,4 % та помітно кращою чутливістю до локальних текстурних особливостей. Навіть за умов невеликої кількості навчальних прикладів, CNN успішно виділяла структурні контури органів, що мало вирішальне значення для ідентифікації патологій. У тестових прикладах вона краще справлялася з розмежуванням тканин, зокрема в ділянках із поганим контрастом.

Однією з ключових переваг CNN стала можливість використання методу Grad-CAM для візуалізації ділянок, які модель вважає найбільш релевантними для класифікаційного рішення. Це дозволило виявити, що мережа концентрує увагу на ділянках зі зміненими ехоструктурами та межами органів. У випадку з ANN, візуальна інтерпретація була обмежена через втрату просторової інформації, адже мережа оперувала лише векторизованими пікселями без урахування локального контексту.

Під час тестування було зафіксовано час обробки одного зображення (інференс) для кожної моделі. ANN виконувала класифікацію менш ніж за 5 мс, тоді як CNN потребувала приблизно 35 мс – цей показник залишався прийнятним навіть для реального часу. Обидві моделі також були протестовані на ноутбуку середнього класу без GPU, що демонструє їхню практичну придатність до інтеграції у медичні інформаційні системи на рівні місцевих клінік.

Таблиця 1

Порівняльна характеристика ANN та CNN для обробки УЗД-зображень

Параметр	ANN (1 прихований шар)	CNN (3 згорткові шари)
Середня точність діагностики (%)	71,3 %	86,4 %
Recall (повнота)	68,5 %	84,1 %
Precision (точність)	72,9 %	88,2 %
F1-score	70,6 %	86,1 %
Час обробки 1 зображення (мс)	~5 мс	~35 мс
Можливість інтерпретації результатів	Обмежена	Висока (Grad-CAM)
Стійкість до шуму/артефактів	Низька	Середньо-висока
Адаптація до різних апаратів	Слабка	Задовільна
Обчислювальна складність	Низька	Середня
Придатність для реального часу	Висока	Висока (без GPU)

Висновки

У ході проведеного дослідження було здійснено комплексний аналіз ефективності застосування простих нейронних мереж та згорткових нейронних мереж (CNN) у задачах обробки ультразвукових діагностичних знімків. Ультразвукова діагностика, як один із найбільш поширених і доступних методів медичної візуалізації, має суттєві обмеження, пов'язані з фізичними властивостями ультразвукових хвиль, що призводить до появи шумів, артефактів та низької контрастності зображень. Це ускладнює точну інтерпретацію знімків і підвищує значення автоматизованих методів обробки, які можуть допомогти лікарям у постановці діагнозу.

Порівняльний аналіз показав, що згорткові нейронні мережі суттєво перевершують прості нейронні мережі з одним прихованим шаром за точністю класифікації патологій на ультразвукових знімках. CNN демонструють високу стійкість до шумів і варіативності даних, що забезпечує більш надійні результати, особливо у складних клінічних випадках. Крім того, можливість застосування інтерпретованих методів візуалізації, таких як Grad-CAM, дозволяє лікарям бачити, які саме ділянки зображення вплинули на рішення моделі, що підвищує довіру до автоматизованих систем і сприяє їх впровадженню у клінічну практику. Водночас прості нейронні мережі мають переваги у швидкості обробки та меншій обчислювальній складності, що робить їх корисними для систем з обмеженими ресурсами або для швидкої попередньої обробки даних.

Важливою складовою ефективності нейронних моделей є якість вхідних ультразвукових знімків, яка значною мірою залежить від характеристик апаратного забезпечення – типу датчика, частоти ультразвуку, параметрів сканування та інших факторів. Виявлено, що CNN краще адаптуються до варіацій якості зображень, зберігаючи високу точність навіть за наявності шумів і артефактів, тоді як прості нейронні мережі втрачають продуктивність у таких умовах. Це підкреслює необхідність врахування особливостей апаратури при розробці та впровадженні моделей, а також важливість використання різноманітних та репрезентативних наборів даних для навчання.

Перспективи подальших досліджень пов'язані з оптимізацією нейронних мереж для роботи у реальному часі, інтеграцією моделей у медичні інформаційні системи з дотриманням стандартів обробки медичних даних (DICOM, HL7), а також розробкою гібридних архітектур, які поєднують переваги CNN і трансформерів. Не менш важливою є співпраця з клініцистами для якісного анотування даних і оцінки результатів, що сприятиме підвищенню довіри до автоматизованих систем і їх широкому впровадженню.

Таким чином, результати дослідження підтверджують, що застосування згорткових нейронних мереж у задачах обробки ультразвукових діагностичних знімків є ефективним і перспективним напрямом, який здатен суттєво підвищити якість діагностики та автоматизувати аналіз медичних даних. Водночас врахування особливостей апаратного забезпечення та оптимізація моделей для конкретних клінічних умов залишаються ключовими завданнями для подальшого розвитку цієї галузі.

Список використаної літератури

1. Kim T., Kim J. A shallow neural network approach for ultrasound image classification. Biomedical Engineering Letters. 2021. Vol. 11, No. 3. P. 315–321. DOI: <https://doi.org/10.1007/s13534-021-00207-7>
2. Wu Y., He K., Li H. Comparative performance of CNN and shallow ANN in ultrasound image enhancement. Ultrasonic Imaging. 2022. Vol. 44, No. 2. P. 105–120. DOI: <https://doi.org/10.1177/01617346211037324>

3. Selvaraju R. R. et al. Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization. *International Journal of Computer Vision*. 2020. Vol. 128. P. 336–359. DOI: <https://doi.org/10.1007/s11263-019-01228-7>
4. Zhang L., Wang S., Liu Q. Lightweight convolutional networks for real-time ultrasound image interpretation. *Sensors*. 2023. Vol. 23, No. 6. Article 2874. DOI: <https://doi.org/10.3390/s23062874>
5. Chen X., Zhou Y., Li R. Ultrasound image analysis using weak supervision and transfer learning. *Computers in Biology and Medicine*. 2021. Vol. 134. Article 104478. DOI: <https://doi.org/10.1016/j.compbiomed.2021.104478>
6. Aryashah2k. Breast Ultrasound Images Dataset. *Kaggle*. URL: <https://www.kaggle.com/datasets/aryashah2k/breast-ultrasound-images-dataset> (дата звернення: 20.05.2025)

References

1. Kim T., Kim J. (2021) A shallow neural network approach for ultrasound image classification., vol. 11, no. 3, pp. 315–321. <https://doi.org/10.1007/s13534-021-00207-7>
2. Wu Y., He K., Li H. (2022) Comparative performance of CNN and shallow ANN in ultrasound image enhancement. *Ultrasonic Imaging*, vol. 44, no. 2, pp. 105–120. <https://doi.org/10.1177/01617346211037324>
3. Selvaraju R. R., Cogswell M., Das A., Vedantam R., Parikh D., Batra D. (2020) Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization. *International Journal of Computer Vision*, vol. 128, pp. 336–359. <https://doi.org/10.1007/s11263-019-01228-7>
4. Zhang L., Wang S., Liu Q. (2023) Lightweight convolutional networks for real-time ultrasound image interpretation. *Sensors*, vol. 23, no. 6, article 2874. <https://doi.org/10.3390/s23062874>
5. Chen X., Zhou Y., Li R. (2021) Ultrasound image analysis using weak supervision and transfer learning. *Computers in Biology and Medicine*, vol. 134, article 104478. <https://doi.org/10.1016/j.compbiomed.2021.104478>
6. Aryashah2k (2020) Breast Ultrasound Images Dataset. *Kaggle*. Retrieved from: <https://www.kaggle.com/datasets/aryashah2k/breast-ultrasound-images-dataset> (accessed May 20, 2025).