



Ю. І. Петриняк, І. Б. Пірко

Національний лісотехнічний університет України, м. Львів, Україна

ДІАГНОСТИКА СЕРЦЕВИХ ЗАХВОРЮВАНЬ МЕТОДАМИ ГЛИБИННОГО НАВЧАННЯ

Наведено результати дослідження, в якому розроблено та впроваджено моделі глибокого навчання для діагностики серцевих захворювань на підставі ехокардіографічних зображень. Проаналізовано сучасні методи діагностики, з'ясовано їхні обмеження та недоліки, що спонукало до пошуку нових підходів. Встановлено, що традиційні методи часто не забезпечують достатньої точності виявлення серцевих патологій, що може призводити до помилок у діагностиці пацієнта та його лікуванні. Досліджено можливості застосування штучного інтелекту, зокрема нейронних мереж, для автоматизації процесу аналізу ехокардіографічних зображень. Розроблено архітектуру нейронної мережі, яка продемонструвала високу ефективність у виявленні різних типів серцевих захворювань. Проведено порівняння нової моделі з традиційними методами, що підтвердило її переваги в точності сегментації та класифікації патологій. Введено алгоритми, які дають змогу значно підвищити чутливість і специфічність діагностики, що є важливим для своєчасного виявлення захворювань. Результати дослідження свідчать про те, що застосування розробленої моделі може істотно поліпшити якість медичних послуг, зменшуючи ризик помилок у діагностиці та підвищуючи ефективність лікування. Вказано на важливість інтеграції сучасних технологій у медичну практику, що відкриває нові можливості для раннього виявлення серцевих захворювань та покращення загального стану здоров'я населення. Результати дослідження можуть стати основою для подальших наукових розробок у цій галузі, а також для впровадження нових стандартів діагностики у клінічній практиці. Проаналізовано архітектуру нейронної мережі, досліджено вплив різних параметрів, таких як кількість епох і розмір партії на ефективність навчання. Наведені результати підтверджують переваги нової моделі над традиційними методами, а також обговорено потенційні напрями для подальших досліджень у цій сфері. Отримані результати демонструють значне покращення в діагностиці серцевих захворювань.

Ключові слова: штучні нейронні мережі; розпізнавання медичних зображень; аналіз медичних даних; діагностика серцевих патологій.

Вступ / Introduction

Серцево-судинні захворювання є однією з провідних причин інвалідності та смертності населення. Останніми роками завдяки підвищенню доступності та якості діагностики вдалося досягти успіхів у лікуванні серцевих захворювань. Удосконалення діагностичних технологій і постійне зростання обсягу наукової інформації дає можливість підтримки прийняття лікарських рішень. Впровадження у клінічну практику технологій штучного інтелекту дає змогу автоматизувати оброблення й аналіз великих даних, виявляти на цій основі приховані або неочевидні закономірності та отримувати нові знання [10]. Штучний інтелект – це галузь комп'ютерних наук, яка прагне імітувати розумові процеси людини, здатність до навчання та зберігання знань, а її методи застосовують у кардіології для виявлення предикторів розвитку захворювань, прогнозування їхнього клінічного перебігу, підвищення ефективності лікування [16]. Методи машинного навчання є основним інструментом штучного інтелекту багатьох автоматизованих систем, що навчаються, які, використовуючи різні види моделювання та спираючись на доступні дані, ухвалюють

необхідні рішення для реалізації прогностичної функції [13]. Алгоритми машинного навчання використовують у суміжних галузях: когнітивних обчисленнях, комп'ютерному зорі та робототехніці. Вони надають можливість для опрацювання та аналізу великих складних різномірних даних. Нині методи машинного навчання використовують у різних шкалах оцінки серцево-судинних ризиків. До них належать Framingham risk score, Reynolds, шкала американської колегії кардіологів, а також шкали Score, Qrisk procam. Ці шкали оцінюють серцево-судинний ризик на підставі методів традиційної статистики та логістичної регресії, які припускають наявність тільки лінійних зв'язків між предикторами та наслідками [8].

Об'єкт дослідження – діагностика серцево-судинних захворювань за медичними ехокардіографічними зображеннями.

Предмет дослідження – методи та алгоритми глибокого навчання, що використовуються для аналізу медичних зображень на підставі даних візуалізації серця, що дасть змогу дослідити та виявити шаблони, які можуть бути неочевидними за традиційних методів аналізу.

Інформація про авторів:

Петриняк Юрій Іванович, магістр за спеціальністю Комп'ютерні науки, аспірант, кафедра комп'ютерних наук.

Email: petrynyak.yuriy@ntlu.lviv.ua; <https://orcid.org/0009-0003-0185-6695>

Пірко Ігор Богданович, канд. фіз.-мат. наук, доцент, кафедра комп'ютерних наук.

Email: pirk@ntlu.edu.ua; <https://orcid.org/0009-0008-2378-2929>

Цитування за ДСТУ: Петриняк Ю. І., Пірко І. Б. Діагностика серцевих захворювань методами глибокого навчання. Науковий вісник НЛТУ України. 2024, т. 34, № 7. С. 86–91.

Citation APA: Petrynyak, Yu. I., & Pirko, I. B. (2024). Diagnosing heart disease using machine learning methods. *Scientific Bulletin of UNFU*, 34(7), 86–91. <https://doi.org/10.36930/40340711>

Мета роботи – розробити модель глибинного навчання для діагностики захворювань серця на підставі ехокардіографічних зображень та проаналізувати її ефективність, що дасть змогу істотно покращити точність та швидкість діагностики серцевих захворювань.

Для досягнення зазначеної мети визначено такі основні завдання дослідження:

1. Проаналізувати сучасні методи глибинного навчання, які використовують для діагностики серцево-судинних захворювань, що дасть змогу виявити їхні переваги та недоліки, а також визначити найефективніші підходи для інтеграції у клінічну практику.
2. Розробити та налаштувати нейронну мережу для аналізу ехокардіографічних зображень, що забезпечить автоматизований та точний аналіз серцевих зображень, що значно зменшить час, необхідний для діагностики.
3. Оцінити точність та ефективність запропонованої моделі для виявлення серцевих патологій, що забезпечить об'єктивну базу для порівняння нової моделі з наявними методами діагностики.
4. Оцінити можливість інтеграції розробленої моделі у медичну практику, що приведе до зниження навантаження на медичний персонал, дасть можливість лікарям зосередитися на більш складних випадках і прийнятті клінічних рішень.

Аналіз останніх досліджень та публікацій. З початку 2000 р. збільшується кількість наукових робіт, присвячених результатам застосування методів машинного навчання для створення діагностичних і прогностичних моделей серцево-судинних захворювань. У роботі [18] показано потенціал використання моделей машинного навчання для виявлення пацієнтів з високим ризиком серцево-судинних захворювань. Автори зазначають, що більшість методів оцінювання серцевого ризику ґрунтуються на використанні невеликої кількості вхідних змінних, що може спричинити їхню недостатню точність. Шляхом аналізу різних ознак було розроблено дві моделі для прогнозування смерті пацієнтів від серцево-судинних захворювань упродовж наступних 30 днів і впродовж одного року. Точність отриманих моделей характеризувалася площею під кривою AUC (англ. *Area Under Curve*), яка становила 0,87 і 0,89.

У роботі [22] для ідентифікації пацієнтів із серцевою недостатністю використовували кілька методів машинного навчання: модель, яка базувалася на 10 вхідних ознаках і логістичній регресії, показала AUC 0,77 і передбачила серцеву недостатність більш ніж за 6 місяців до діагнозу.

У дослідженні [21] було оцінено різні методи машинного навчання для створення моделі прогнозування інфаркту міокарда з використанням відомих факторів ризику. Автори вважають, що електронні записи про стан здоров'я EHR (англ. *Electronic Health Records*) – нова реляційна сфера з великим потенціалом для покращення клінічних результатів. Вони застосували два алгоритми статистичного реляційного навчання SRL (англ. *Statistical Relational Learning*) для виконання завдання прогнозування первинного інфаркту міокарда. Дослідники показали, що один алгоритм SRL, а саме – посилення реляційного функціонального градієнта, перевершує пропозиційних вчителів, особливо в медично відповідній області високого запам'ятовування. Вони стверджують, що обидва алгоритми SRL прогнозують результати краще, ніж їхні пропозиційні аналоги, тому їхні методи можуть посилити поточну епідеміологічну

практику. Фінальна модель мала точність прогнозування AUC 0,84 і точність 79,1 %.

У роботі [1] автори використовували ехокардіографічні дані для створення моделі для прогнозування ризику у пацієнтів з гострими коронарними синдромами. Її AUC становила 0,84.

У дослідженні [7] було створено модель для прогнозування госпіталізації пацієнтів із серцевою недостатністю на підставі таких характеристик: демографічні дані (вік, стать, раса та місце проживання), діагностоване захворювання, куріння, артеріальний тиск, лабораторні та апаратні тести. Автори використовували різні алгоритми машинного навчання, такі як опорні вектори, AdaBoost, логістичну регресію та наївний класифікатор Байєса; алгоритм AdaBoost показав найвищу точність прогнозування 82 %.

У роботі [20] для створення моделі прогнозування серцевих захворювань було застосовано складний багатоетапний підхід, спочатку використовували кілька вхідних ознак, які впливають на прогноз. Автори дійшли висновку, що їм вдалося виявити маловивчені, але важливі предиктори серцевих захворювань.

У роботі [12] було створено модель для прогнозування ризику смерті у пацієнтів із серцевою недостатністю (точність 96,3 %, AUC 0,89). Важливим є те, що використання машинного навчання для створення більш точних моделей створює проблему чорного ящика. Тому, окрім прагнення до максимальної точності, варто також докладати зусиль для забезпечення інтерпретованості та зрозумілості результатів роботи моделі.

У роботі [6] автори порівнювали машинне навчання і традиційні регресійні методи для прогнозування погіршення стану пацієнтів із серцевою недостатністю. Для створення моделей, що прогнозують зупинку серця, переведення в реанімацію та смерть, використовували кілька підходів. Найточнішою виявилася модель, яку було навчено за допомогою алгоритму випадкового лісу (AUC 0,80).

Машинне навчання можна використовувати для проведеної перспективних наукових розробок і відкриття нових взаємозв'язків між предикторами серцево-судинних захворювань.

Результати дослідження та їх обговорення / Research results and their discussion

Методи машинного навчання, що застосовуються в кардіології з прогностичною та діагностичною метою, поділяють на два основні класи: навчання без учителя та з учителем. Перший клас містить різні методи класифікації, які використовують для класифікації хворих з урахуванням індивідуальних особливостей їхнього генетичного, імунологічного чи клініко-функціонального статусу. Машинне навчання з учителем використовують заздалегідь розмічені набори даних, обробляння яких дає змогу виокремити фактори, що впливають на клінічний перебіг серцево-судинних захворювань та їх прогноз [17]. Для реалізації цих завдань використовують такі методи машинного навчання, як дерева рішень, випадковий ліс, наївний байєсівський класифікатор, метод опорних векторів SVM (англ. *Support Vector Machine*), k-найближчих сусідів kNN (англ. *k-Nearest Neighbor Method*), кожний з яких має свої переваги та недоліки. Наразі до найперспективніших методів машинного навчання відносять глибоке навчання, яке ре-

алізується за допомогою багаточасових штучних нейронних мереж.

Лінійна регресія – це лінійний класифікатор, що належить до базових технологій машинного навчання, який дає змогу прогнозувати ймовірність розвитку деяких подій на підставі незалежних змінних. Вона якнайкраще підходить для розв'язання задач, де ймовірність розвитку захворювань лінійно пов'язана з факторами ризику, а вони, водночас, мають бути лінійно незалежними між собою. Потреба виконання цих умов істотно обмежує сферу її застосування у прогностичних дослідженнях [19]. Лінійну регресію часто використовують у наукових дослідженнях для діагностики та прогнозування розвитку серцево-судинних захворювань. У роботі [5] на клінічних даних пацієнтів було розроблено модель лінійної регресії, що давала змогу ідентифікувати хворих із точністю 88 %. Цей метод застосовували в моделі прогнозування порушень провідності серця та використовували для оцінювання впливу окремих факторів ризику на розвиток серцево-судинних захворювань.

Метод найближчих сусідів kNN є одним із найдоступніших методів машинного навчання, що дає змогу класифікувати дані за ступенем їхньої близькості до заздалегідь розміченої вибірки, отриману класифікацію ознак легко інтерпретувати. Цей метод не дає змоги виокремлювати предиктори й оцінити взаємозв'язки між аналізованими факторами та наслідками. Окрім цього, класифікатор на підставі kNN можна використовувати тільки в комбінації з навчальною вибіркою. Для автоматизованої ідентифікації серцево-судинних захворювань за даними електрокардіограм застосовували класифікатор kNN, який демонстрував максимальну діагностичну точність у 98 %, а чутливість і специфічність – у 95 % і 99,2 % [15]. Для діагностики було розроблено модель на підставі kNN з використанням просторово-часових характеристик кривих деформації міокарда. Запропонована модель з точністю перевершувала висновки експертів з ультразвукової діагностики.

Метод опорних векторів SVM – один із найпопулярніших методів машинного навчання з учителем, який застосовують для розв'язання задач класифікації та регресії. Основна ідея методу полягає в побудові гіперплощини, що розділяє об'єкти вибірки оптимальним способом. Алгоритм ґрунтується на припущенні, що чим більша відстань між гіперплощиною та об'єктами класів, що розділяються, тим менший рівень середньої помилки класифікатора. SVM можна застосовувати для верифікації нелінійних взаємозв'язків досліджуваних факторів і результатів [14]. Гібридні моделі з використанням SVM мають вищу точність у поділі пацієнтів. У цьому дослідженні, окрім клініко-демографічних даних, для моделювання було використано результати електрокардіограм і рівень кардіоспецифічних ферментів.

Отже, методи машинного навчання щораз частіше використовують для інтелектуального аналізу даних, що характеризують статус пацієнтів із серцево-судинними захворюваннями, як додатковий інструмент діагностичних і прогностичних досліджень. До найперспективніших напрямків застосування методів машинного навчання у клінічній кардіології можна вважати розробку автоматизованих систем діагностики та передбачення серцево-судинних подій. Перша з них дає змогу здійснювати автоматичний аналіз результатів інструментальних і лабораторних досліджень, створювати прог-

рамні продукти, що підтримують ухвалення лікарських рішень, скорочувати час і вартість діагностичних досліджень. Моделі передбачення подій можуть забезпечити вищу точність прогнозування серцево-судинних захворювань.

У дослідженні взяло участь 120 пацієнтів, яким здійснювали коронарографію. Лікар аналізував дані медичної карти (скарги, анамнез, об'єктивні, лабораторні та інструментальні дані) і вносив ці результати в базу даних машинного навчання в бінарному форматі. На першому етапі збирання даних за кожним спостереженням структуровані параметри вносили в табличну форму, а також вводили зображення запису електрокардіограми у форматі jpeg у базу даних. Для навчання нейронних мереж використовували морфометричні, лабораторні та інструментальні дані пацієнтів. Такими даними були вік, стать, хронічний коронарний синдром, патологія сегмента коронарної артерії на електрокардіограмі, наявність або відсутність супутньої патології (цукрового діабету, гіпертонічної хвороби, ожиріння, анемії, гострого порушення мозкового кровообігу, атеросклерозу, аритмії), наявність шкідливих звичок, наявність стресових факторів, низька фізична активність.

Описані вище фактори фіксували у структурованому бінарному вигляді (0, 1) у табличному форматі. Реєстрацію електрокардіограм проводили з використанням одного виду апарату, запис передавали оператору машинного навчання в електронному вигляді у форматі jpeg. Для вироблення алгоритму навчання нейронної мережі сумарно було використано 22 параметри (ключові ознаки).

Нейронна мережа навчалася на даних, отриманих під час аналізу коронарограм. Як значення взято наявність атеросклерозу, стеноз. Значення стенозу було внесено в таблицю у цифровому вигляді у відсотках, далі переведено в бінарний вигляд, інші показники заповнювали в бінарному вигляді за наявністю або відсутністю ураження. Описані вище значення передбачав навчений алгоритм машинного навчання.

Алгоритму необхідно було розв'язати задачу класифікації уражень, спрогнозувати відсутність або наявність стенозів і їхню вираженість. Для класифікації уражень за бінарною системою використано нейронну мережу, що приймає на вхід структуровані дані та зображення, на виході отримано мультифакторну класифікацію. Співвідношення у прикладах на навчання та тестування становлять 100/20. Прогнозування та оцінювання результатів проведено на тестовій вибірці.

Пацієнти в тестовій вибірці були з нетиповою клінічною картиною і складною патологією. Цю умову взято для перевірки роботи алгоритму в умовах реальної клінічної практики. Як програмне забезпечення для побудови архітектури нейронної мережі використано набори бібліотек Python (Pandas – для роботи з табличними даними, Tensorflow – для конструювання нейронних мереж та їх навчання). Використовувався метод навчання з учителем на наявних даних, у яких були відомі результати, а параметри нейронної мережі підлаштовували так, щоб мінімізувати помилку. Проводили аналіз структурованих табличних даних навчальної вибірки, що складається зі 100 пацієнтів.

До завдання дослідження входило порівняння точності навченої моделі нейронної мережі на вхідних структурованих даних і записів лікарів-кардіологів, зро-

блених на реальних пацієнтах. До кожного завдання було додано електрокардіограми. За основний метод розрахунку помилки було взято AUC score.

На вхід нейронної мережі одночасно надходили електрокардіограми розміром $200 \times 200 \times 1$ і структуровані табличні дані. На виході нейронна мережа прогнозувала значення уражених коронарних значень у ймовірнісному вигляді. Для опрацювання структурованих даних взято тільки повнозв'язні шари. У середині нейронної мережі використовували об'єднувальний шар для узагальнення ваг зображення і набору даних. Після узагальнювального шару – два повнозв'язні шари. Вихідний шар складається з нейронів для передбачень за кожним параметром. Як оптимізатор взято Adam. Навчання проводили на 100 епохах (1 епоха – один прямий прохід і один зворотний прохід усіх навчальних прикладів). Кількість навчальних прикладів за одну ітерацію – 8, розмір валідаційної вибірки 0.1. Як відправну метрику для оцінювання якості моделі обрано AUC (площу під ROC-кривою).

На тестовій вибірці, що складається з 20 пацієнтів, результат нейронної мережі становив: AUC score – 0,74, accuracy – 80 %, precision – 63 %, recall – 55 %, f1 score – 59 %. У проведеному дослідженні використали відносно невелику кількість даних: 22 ознаки, електрокардіограми, отримані у хворих. У зв'язку з цим було побудовано архітектуру нейронної мережі з невеликою кількістю параметрів. Результат багаторівневої класифікації передбачуваних уражень по кожній магістральній коронарній артерії обрано архітектурою нейронної мережі показав якість моделі AUC=0,74. Створена модель нейромережевого аналізу дає змогу з досить високою ймовірністю прогнозувати ураження магістральних коронарних артерій. Щороку з'являється велика кількість моделей для оцінювання серцево-судинного ризику. Більшість моделей ґрунтуються на даних клінічних і реєстрових досліджень. Однак, тільки невелика частина моделей використовується в реальній клінічній практиці. Очевидно, що замість створення чергової нежиттєздатної моделі необхідний якісно інший підхід. Нейронні мережі бачать закономірності, не доступні людині. Отримані результати дають змогу робити висновки про можливе практичне застосування методу нейромережевого аналізу в клінічній практиці. У цих умовах штучний інтелект дає змогу правильно інтерпретувати сукупність даних і націлити лікаря на виконання технології.

Дослідження полягає у перетворенні дев'яти класів сигналів електрокардіограм на двійкові зображення, а потім – у розробленні моделі глибокого навчання для їхньої класифікації. У цій роботі використовувалася база даних Національного інституту метрології Німеччини. Вона містить записи про здорових людей і пацієнтів із різними захворюваннями серця. Кожен запис містить 15 вимірних сигналів, 12 стандартних відведень та 3 електрокардіограми. Детальне клінічне резюме було надано в заголовному файлі, тоді як значення сигналу електрокардіограми – у файлі.dat. Сигнали в цій базі даних відповідають дев'яти класам серцевих захворювань: міокардит, вада клапанів серця, гіпертрофія міокарда, дисритмія, блокада гілок пучка, кардіоміопатія / серцева недостатність, інфаркт міокарда, різне і здорова людина. Вибір цієї бази даних базується на великій кількості наданих записів. Ці записи містили осіб обох статей, здорових або пацієнтів з різними захворюваннями серця.

Підготовка даних складається з чотирьох етапів: автоматичного маркування необроблених даних, попереднього оброблення отриманих сигналів, поділу кожного сигналу на кілька невеликих сигналів, перетворення кожного сигналу на зображення (рис. 1).




Рис. 1. Етапи попереднього оброблення даних / Stages of data preprocessing

Автоматичне маркування даних зумовлене великою кількістю записів у базі даних, ручне опрацювання яких складне і забирає багато часу. Спочатку всі файли, що містять діагноз, були зібрані в одну папку. Потім їх сканували один за одним з автоматичним пошуком назви запису і діагнозу. Використання бібліотек Python дало змогу швидко перебирати файли папки. Таблиця Excel була створена з використанням бібліотеки `xlswriter`, яка містила 2 стовпці: перший – назва запису, другий – сам діагноз. Клас було названо за діагнозом, номер рядка відповідав кількості записів. Отже, як назву кожного запису, так і діагноз можна знайти автоматично.

Усі записи було зібрано в одну папку після успішного завершення попереднього кроку, було створено папки з назвами класів. Бібліотека Excel використовувалася для читання файлу, створеного на першому етапі, який містив два стовпці: ім'я запису та ім'я класу. Процес переміщення файлів з основної папки у вкладені папки був таким: назва запису обчислювалася з першого стовпця, діагноз – з другого. Отже, було відомо, який запис відповідає якійсь папці (ім'я класу). Це згортання було виконано за допомогою бібліотеки `shutil`, яка давала можливість перемішувати файли між папками.

Метод попереднього оброблення даних містить два етапи. Перший – це нормалізація амплітуди сигналу, другий – згладжування кожного сигналу, для якого був застосований усереднений фільтр. Тривалість записів бази даних становить від 15 до 60 с. Отже, кожен запис був розділений на 15-30 сегментів тривалістю 2 с. Сегментація була необхідною для збільшення розміру вибору та зменшення розміру зображень у ролі остаточної форми даних перед подачею в модель.

На наступному етапі сегментовані сигнали були збережені у вигляді зображення RGB. Потім ці зображення були перетворені в двійкові, де фон чорний, об'єкт білий. Після цього кроку дані були готові до введення в модель глибокого навчання.

Підписи на рис. 2 відповідають за такі блоки: ОЗ – операція згортки; ОБ – остаточний блок; БН – батч-нормалізація; ФН – функція нелінійності; ОД – операція дропауту; ОП – операція пулінгу; ПЛШ – повнозв'язний лінійний шар; КВ – конкатенація векторів; СФА – сигмоїдна функція активації.

Архітектура попередньо навченої моделі складається з таких рівнів. Перший і другий шари є обертовим шаром з максимальним шаром об'єднання, водночас, як шари з 3-го по 5-й мають три зворотних шари з одним максимальним шаром об'єднання, а шари з 6-го по 8-й – два повнозв'язні закриті шари з одним повністю під'єднаним вихідним шаром. Функція активації лінійного блоку випрямляча використовувалася для всіх шарів, окрім вихідного. Кількість епох і розмір партії становили 80 і 64 відповідно.

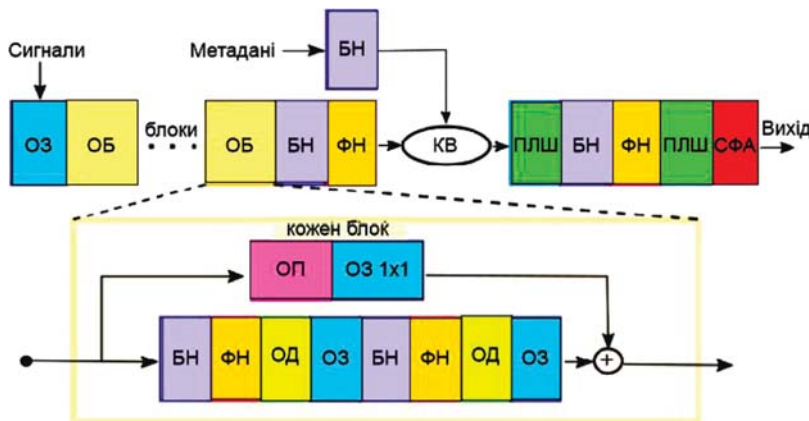


Рис. 2. Архітектура нейронної мережі / Neural network architecture

Обговорення результатів дослідження. Згідно з дослідженням [23], автори провели інтерпретацію ехокардіограм засобами технологій машинного та глибокого навчання, алгоритми яких можуть досягати точності до 93 % у класифікації ехокардіографічних сигналів. Виявилось, що глибоке навчання є більш ефективним щодо розпізнавання ехокардіографічних зображень, воно здатне обробляти великі обсяги даних і враховувати складні їхні шаблони.

Автори роботи [3] обговорюють методи, які пов'язані із застосуванням глибокого навчання в ехокардіографії для автоматичного виділення та кількісного аналізу структур серця. Алгоритми глибокого навчання діють як прогностичні інструменти, вони виявляють різні структурні та функціональні шаблони серця, що можуть бути пропущені під час інтерпретації лікарем. Дослідження показало, що алгоритми глибокого навчання можуть аналізувати ліву шлуночкову фракцію викиду та подовжню деформацію серця.

У дослідженні [11] обговорюють використання технологій глибокого навчання в медичній візуалізації, методи та підходи у сфері глибокого навчання в медичній діагностиці. Глибинні нейронні мережі використовуються для сегментації та реєстрації медичних зображень. Особливу увагу приділено згортковим нейронним мережам, які застосовуються для розв'язання проблем сегментації. Ці методи та підходи об'єднуються для покращення можливостей радіологів у діагностиці та обробленні медичних зображень.

У роботі [4] наведено застосування методів машинного навчання в разі серцевої недостатності, в т.ч. діагностику, класифікацію, повторну госпіталізацію та дотримання режиму лікування. Застосування методів машинного навчання використано для покращення діагностики серцевої недостатності та лікування. Розроблені методи глибокого навчання забезпечують кращу продуктивність у виконанні завдань шляхом вивчення складних закономірностей, прихованих у великих медичних даних.

У роботі [2] показано, що ехокардіографія є основним методом візуалізації в діагностиці серцево-судинних захворювань. Згорткові нейронні мережі в використано для точної та надійної ідентифікації, кількісного оцінювання та інтерпретації ехокардіографічних зображень. Наведено інтеграцію штучного інтелекту як інструменту для стрес-ехокардіографії, техніки, яка є важливою для оцінювання функції серця в умовах стресу. Розглянуто методи машинного та глибокого навчання,

які можуть покращити аналіз зображень способом автоматизації кількісного аналізу та інтерпретації складних ехокардіографічних даних. Результати цієї роботи узгоджуються з результатами наших досліджень.

Отже, внаслідок виконаної роботи можна сформулювати такі наукову новизну та практичну значущість результатів дослідження.

Наукова новизна отриманих результатів дослідження – проведено аналіз ехокардіографічних зображень засобами нейронної мережі для діагностики серцевих захворювань, який забезпечує більш високу точність і швидкість їх аналізу, здатний автоматично виявляти складні шаблони в даних.

Практична значущість результатів дослідження – розроблений метод глибокого навчання для діагностики серцевих захворювань буде впроваджено в кардіологічну практику, що значно зменшить ризик ускладнень і підвищить загальний рівень здоров'я населення.

Висновки / Conclusions

Розроблено модель глибокого навчання для діагностики захворювань серця на підставі ехокардіографічних зображень, проаналізовано її ефективність, що дало змогу значно підвищити точність виявлення серцевих патологій порівняно з традиційними методами. За результатами проведеного дослідження можна зробити такі основні висновки.

1. Встановлено, що застосування сучасні методи глибокого навчання для діагностики серцево-судинних захворювань, можна значно підвищити точність виявлення патологій порівняно з традиційними підходами. Ці методи ефективно використовують великі масиви медичних даних, що відкриває нові можливості для діагностики вад серця.
2. Розроблено та налаштовано архітектуру нейронної мережі для аналізу ехокардіографічних зображень, що продемонструвала високу ефективність у виявленні різних типів серцевих патологій.
3. Підтверджено високу точність та надійність запропонованої моделі глибокого навчання. Отримані результати демонструють переваги діагностики патологій серця з допомогою нейронної мережі.
4. Проведено порівняння роботи моделі глибокого навчання з традиційними методами діагностики, показано, що нові підходи забезпечують більш точну сегментацію і класифікацію серцевих захворювань, що може сприяти ранньому виявленню захворювань і запобіганню їхньому прогресуванню.

Розроблену модель можна інтегрувати у клінічну практику для зниження навантаження на медичний персонал та покращення якості медичних послуг.

References

1. Al-Dhabyani, W., Goma, M., Khaled, H., & Fahmy, A. (2019). Dataset of breast ultrasound images. *Data in Brief*, 28, 1–5. <https://doi.org/10.1016/j.dib.2019.104863>
2. Alsharqi, M., Upton, R., Mumith, A., & Leeson, P. (2018). Artificial intelligence: a new clinical support tool for stress echocardiography. *Expert Review of Medical Devices*, 15(8), 513–515. <https://doi.org/10.1080/17434440.2018.1497482>
3. Alsharqi, M., Woodward, W., Mumith, J., Markham, D., Upton, R., & Leeson, P. (2018). Artificial intelligence and echocardiography. *Echo research and practice*, 5(4), 115–125. <https://doi.org/10.1530/erp-18-0056>

4. Awan, S., Sohel, F., Sanfilippo, M., Bennamoun, M., & Dwivedi, G. (2018). Machine learning in heart failure: ready for prime time. *Current opinion in cardiology*, 33, 190–195. <https://doi.org/10.1097/HCO.0000000000000491>
5. Boeldt, D., Wineinger, N., Waalen, J., Gollamudi, S., & Grossberg, A. (2015). How Consumers and Physicians View New Medical Technology: Comparative Survey. *Journal of Medical Internet Research*, 17(9), 1–2. <https://doi.org/10.2196/jmir.4456>
6. Churpek, M., Yuen, T., & Winslow, C. (2016). Multicenter Comparison of Machine Learning Methods and Conventional Regression for Predicting Clinical Deterioration on the Wards. *Critical Care Medicine*, 44(2), 368–374. <https://doi.org/10.1097/CCM.0000000000001571>
7. Dai, W., Brisimi, T., & Adams, W. (2015). Prediction of hospitalization due to heart diseases by supervised learning methods. *International Journal of Medical Informatics*, 84(3), 189–197. <https://doi.org/10.1016/j.ijmedinf.2014.10.002>
8. Goldberger, A., Amaral, L., & Glass, L. (2015). PhysioBank, PhysioToolkit and PhysioNet. *Components of a New Research Resource for Complex Physiologic Signals Circulation*, 101(23), 215–220. <https://doi.org/10.1161/01.CIR.101.23.e215>
9. Hrytsiuk, Yu. I. (2022). Software quality management system. *Ukrainian Journal of Information Technology*, 4(1), 01–20. <https://doi.org/10.23939/ujit2022.01.001>
10. Johnson, K., Glicksberg, B., Khader, S., & Ali, M. (2018). Artificial Intelligence in Cardiology. *Journal of the American College of Cardiology*, 71(23), 2668–2679. <https://doi.org/10.1016/j.jacc.2018.03.521>
11. Lee, J., Jun, S., Cho, Y., Lee, H., Kim, G., Seo, J., & Kim, N. (2017). Deep learning in medical imaging: general overview. *Korean journal of radiology*, 18, 570–584. <https://doi.org/10.3348/kjr.2017.18.4.570>
12. Loghmanpour, N., Kanwar, M., & Druzdzel, M. (2015). A new Bayesian network-based risk stratification model for prediction of short-term and long-term mortality. *American Society for Artificial Internal Organs Journal*, 61(3), 313–323. <https://doi.org/10.1097/MAT.0000000000000209>
13. Marvin, A., Konstam, M., Hill, J., Kovacs, R., & Harrington, R. (2017). The Academic Medical System: Reinvention to Survive the Revolution in Health Care. *Journal of the American College of Cardiology*, 69(10), 1305–1312. <https://doi.org/10.1016/j.jacc.2016.12.024>
14. Mortazavi, B., Downing, N., & Bucholz, M. (2016). Analysis of machine learning techniques for heart failure readmissions. *Circ Cardiovasc Qual Outcomes*, 629–640. <https://doi.org/10.1161/CIRCOUTCOMES.116.003039>
15. Shameer K., Johnson K., Glicksberg B., Dudley J., & Sengupta P. (2018). Machine learning in cardiovascular medicine: are we there yet. *British Medical Journal*, 104(14), 1156–1164. <https://doi.org/10.1136/heartjnl-2017-311198>
16. Shameer, K., Badgeley, M., Miotto, R., & Glicksberg, B. (2017). Translational bioinformatics in the era of real-time biomedical, health care and wellness data streams. *Briefings in Bioinformatics*, 18(1), 105–124. <https://doi.org/10.1093/bib/bbv118>
17. Shameer, K., Johnson, K., Yahi, A., & Miotto, R. (2017). Predictive modeling of hospital readmission rates using electronic medical record-wide machine learning: a case-study using mount sinai heart failure cohort. *Biocomputing*, 2017, 276–287. https://doi.org/10.1142/9789813207813_0027
18. Song, X., Mitnitski, A., Cox, J., & Rockwood, K. (2004). Comparison of machine learning techniques with classical statistical models in predicting health outcomes. *Studies in Health Technology and Informatics*, 107(1), 736–740. <https://doi.org/10.3233/978-1-60750-949-3-736>
19. Stockmann, C., Hersh, A., Sherwin, C., & Spigarelli, M. (2014). Alignment of United States funding for cardiovascular disease research with deaths, years of life lost and hospitalizations. *International Journal of Cardiology*, 172(1), 19–21. <https://doi.org/10.1016/j.ijcard.2013.12.095>
20. Tay, D., Poh, C., & Kitney, R. (2015). A novel neural-inspired learning algorithm with application to clinical risk prediction. *Journal of Biomedical Informatics*, 54, 305–314. <https://doi.org/10.1016/j.jbi.2014.12.014>
21. Weiss, J., Natarajan, S., & Peissig, P. (2012). Machine Learning for Personalized Medicine: Predicting Primary Myocardial Infarction from Electronic Health Records. *Artificial Intelligence Magazine*, 33(4), 33–45. <https://doi.org/10.1609/aimag.v33i4.2438>
22. Wu, J., Roy, J., & Stewart, W. (2010). Prediction modeling using EHR data: challenges, strategies, and a comparison of machine learning approaches. *Medical Care*, 48(6), 106–113. <https://doi.org/10.1097/MLR.0b013e3181de9e17>
23. Ye, Z., Kumar, Y., Sing, G., Zhang J., & Ni, X. (2020). Deep echocardiography: A first step toward automatic cardiac disease diagnosis using machine learning. *Journal of internet technology*, 21(6), 1589–1600. <https://doi.org/10.3966/160792642020112106002>

Yu. I. Petrynyak, I. B. Pirko

Ukrainian National Forestry University, Lviv, Ukraine

DIAGNOSING HEART DISEASE USING MACHINE LEARNING METHODS

The results of a study in which deep learning models were developed and implemented for diagnosing heart diseases based on echocardiographic images are presented. Modern diagnostic methods are analyzed, their limitations and shortcomings are clarified, which prompted the search for new approaches. It was found that traditional methods often do not provide sufficient accuracy in detecting heart pathologies, which can lead to errors in patient diagnosis and treatment. The possibilities of using artificial intelligence, in particular neural networks, to automate the process of analyzing echocardiographic images are investigated. The architecture of a neural network has been developed, which has demonstrated high efficiency in detecting various types of heart diseases. The new model has been compared with traditional methods, which confirmed its advantages in the accuracy of segmentation and classification of pathologies. Algorithms have been introduced that allow significantly increasing the sensitivity and specificity of diagnostics, which is important for the timely detection of diseases. The results of the study indicate that the use of the developed model can considerably improve the quality of medical services, reducing the risk of errors in diagnosis and increasing the effectiveness of treatment. The importance of integrating modern technologies into medical practice is emphasized, which opens up new opportunities for early detection of heart diseases and improving the general health of the population. The results of the study can become the basis for further scientific developments in this field, as well as for the implementation of new diagnostic standards in clinical practice. The architecture of the neural network is analyzed, the influence of various parameters, such as the number of epochs and batch size on the learning efficiency is investigated. The results presented confirm the advantages of the new model over traditional methods, and potential directions for further research in this area are also discussed. The results obtained demonstrate a significant improvement in the diagnosis of heart diseases.

Keywords: artificial neural networks; medical image recognition; medical data analysis; diagnosis of heart pathologies.