

Юрій Петриняк, Ігор Пірко*

¹ НЛТУ України, Львів, Україна, ORCID: 0009-0003-0185-6695,
petrynyak.yuriy@nltu.lviv.ua

² НЛТУ України, Львів, Україна, ORCID: 0009-0008-2378-2929,
pirko@nltu.edu.ua

Інтелектуальний аналіз ехокардіограм за допомогою згорткових нейронних мереж

Анотація. Аналіз ехокардіограм з використанням методів глибокого навчання може підвищити точність діагностики та якість медичних послуг. У цьому напрямку проведено багато досліджень. Поділяючи область серця на сегменти, створюється його 3D-модель і визначаються різні параметри. Оскільки ехокардіограми складаються з зображень та відео, для їх аналізу ефективніше використовувати методи глибокого навчання, порівняно з традиційними методами машинного навчання. Системи CNN підходять для роботи з зображеннями і показали найкращі результати серед систем штучного інтелекту. Були проведені дослідження з використанням мереж CNN для розрізнення ділянок серця і зменшення шуму на зображеннях. Повністю автоматизована система, яка може розрізняти параметри серця і виявляти захворювання, має багато переваг, потреба в такій системі зростає.

Ключові слова – глибоке навчання, згорткові нейронні мережі, ехокардіограма.

Згорткові нейронні мережі CNN (Convolutional Neural Network) – це алгоритми штучного інтелекту, які виконують завдання, що пов'язані з обробкою зображень, класифікацією, поділом на кадри з найкращими результатами. Особливо в телемедичних мережах CNN широко використовуються для аналізу даних зображень, враховуючи дані ультразвукових і магнітно-резонансних зображень. Найбільш часто використовувані шари в них – це вхідний, згортки, пакетної нормалізації, RELU, Softmax і вихідний шар.

Матеріали і методи дослідження. Для створення бази даних були використані відеоролики з ехокардіограмами, доступні на інтернет-сайтах. Оскільки більшість з них мали навчальний характер, містили багато додаткових кадрів,

які не показували ехокардіограми. Тому часовий інтервал ехокардіограм з цих відео було скорочено до 2-5 секунд. З вирізаних відеофрагментів були видалені різні непотрібні символи, записи та інформацію про пацієнта. Потім відеофрагменти були розбиті на кадри, розмір розбитих кадрів був змінений до 112 x 112. У процесі видалення шуму з розрізаних відеокадрів була зроблена спроба розрізати зображення серця на відео на квадрати. Причина полягає в тому, що зміна розміру обрізаного квадратами зображення впливає на якість інформації. Хоча цей ефект може не впливати на продуктивність CNN для звичайних зображень, він дуже важливий для ехокардіографічних зображень, оскільки форма і розмір серцевої стінки на зображенні серця також змінюється. Тим не менш, це найважливіші фактори для постановки діагнозу. Було створено базу даних з 15 000 зображень, отриману базу даних розділили на дві частини у співвідношенні 9:1, одну для навчання, іншу для тестування.

Результати. Мережа CNN складається з 16 шарів: вхідного шару, шару згортки, шару пакетної нормалізації, шару RELU, шару Softmax та вихідного шару. Для цього було використано спеціальні бібліотеки Python.




Рисунок 1. Процес навчання мережі

Мережа була оптимізована за допомогою оптимізатора Adam, при цьому швидкість навчання становила 0,0001, значення GradientDecayFactor – 0,95,

L2Regularisation – 0,001, Epsilon – 0,001. Ці значення були обрані для досягнення максимальної продуктивності на основі декількох експериментів. Загальний час навчання становив 15 епох. Однак навчання було зупинено в точці, де точність класифікації мережі була найбільш критичною, а саме на 12-й епосі. Процес навчання проілюстровано на рис. 1.

Точність класифікації (Accuracy) навченої мережі склала 98,2 %. Потім була створена матриця помилок для розрахунку інших параметрів мережі (рис. 2). Це було використано для визначення чутливості, специфічності, показника F1.

Таблиця 1. Значення статистичних параметрів, які оцінюють продуктивність мережі

	Dilated	Hypertropic
Specifity	95,7	100
Sensitivity	100	95,7
Precision	97,1	100
F1-score	98,5	97,8
Accuracy	98,2	98,2
	Dilated	Hypertropic

У табл. 1 наведено показники точності для двох типів кардіоміопатії (дилатаційної та гіпертрофічної). Це дає змогу оцінити, наскільки добре модель класифікує ці два типи захворювань.




Рисунок 2. Confusion matrix

Specificity (специфічність) вказує на здатність моделі правильно ідентифікувати негативні випадки (людей без захворювання). У випадку дилатаційної кардіоміопатії специфічність 95,7 % означає, що модель правильно класифікувала 95,7 % здорових людей. Sensitivity (чутливість) вказує на здатність моделі правильно ідентифікувати позитивні випадки (тобто людей із захворюванням). У випадку дилатаційної кардіоміопатії чутливість 100 % означає, що модель правильно ідентифікувала всіх пацієнтів із захворюванням. Precision (точність) – це частка правильно передбачених позитивних результатів серед усіх передбачених позитивних результатів. Точність 97,1 % для дилатаційної кардіоміопатії означає, що 97,1 % всіх випадків, класифікованих як такі, що мають цю хворобу, були дійсно правильними.

F1-score (F1-оцінка) – середнє гармонійне значення точності та чутливості. Це загальний показник, який врівноважує хибнопозитивні та хибнонегативні результати. Для дилатаційної кардіоміопатії показник F1 становить 98,5 %, що свідчить про високу ефективність моделі. Accuracy (точність) – сума частки всіх прогнозованих результатів, які були правильно передбачені (як позитивних, так і негативних). Точність 98,2 % для обох типів кардіоміопатії означає, що модель правильно класифікувала 98,2 % всіх випадків.

Висновок. У цьому дослідженні було розроблено та навчено згорткову нейронну мережу для аналізу ехокардіограм. Це дозволило класифікувати два типи кардіоміопатії – дилатаційну та гіпертрофічну. Успішно підготовлено базу даних для навчання та тестування моделі. Модель досягла високої точності класифікації 98,2 % і показала хорошу чутливість і специфічність для обох типів захворювань. Оптимізація за допомогою алгоритму Адама та налаштування параметрів моделі дали найкращі результати для 12-ї епохи. Ці результати підтверджують ефективність використання CNN для аналізу ехокардіографічних зображень в системах телемедицини.

Список використаних літературних джерел

- [1] Bertelli L., Cucchiara R., Paternostro G., Prati A. (2006). A semi-automatic system for segmentation of cardiac M-mode images. *Pattern Analysis and Applications*. 9 (4), 293–306.
- [2] Thomas J., Popovic Z. (2006). Assessment of left ventricular function by cardiac ultrasound. *Journal of the American College of Cardiology*. 48 (10), 2012–2025.
- [3] Chacko R., Singh M. (2014). Sequential functional analysis of left ventricle from 2D echocardiography images. *Indian Journal of Experimental Biology*. 52 (6), 630–636.
- [4] Suphalakshmi A., Anandhakumar P. (2009). Automatic segmentation of echocardiographic images using full causal hidden markov model. *European Journal of Scientific Research*, 585–594.

Analysis of echocardiograms using deep learning methods

Yuriy Petrynyak, Igor Pirko

Analysis of echocardiograms using deep learning methods can improve diagnostic accuracy and quality of medical services. Many studies have been conducted in this direction. By dividing the heart area into segments, a 3D model of the heart is created and various parameters are determined. Since echocardiograms consist of images and video, it is more efficient to use deep learning methods than machine learning methods to analyse them. CNN systems are suitable for working with images and have shown the best results among artificial intelligence systems. Studies have been conducted using CNN networks to distinguish heart regions and reduce noise in images. A fully automated system that can distinguish between heart parameters and detect diseases has many advantages, and the need for such a system is growing.