

УДК 004.032.26:616-071

## ДОСЛІДЖЕННЯ ВИКОРИСТАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ АВТОМАТИЗАЦІЇ ДІАГНОСТИКИ НА ОСНОВІ РЕНТГЕНІВСЬКИХ ЗНІМКІВ

Бочков Д.М., Іванов В.Г.

e-mail: danylo.bochkov@nure.ua

Харківський національний університет радіоелектроніки, каф. СТ,  
м. Харків, Україна

The research focuses on improving automated pneumonia diagnosis using deep convolutional neural networks (CNNs). A modified DenseNet-121 architecture was proposed, incorporating adaptive hyperparameter tuning and enhanced preprocessing techniques. The Adam optimization algorithm was employed to refine weight updates, ensuring efficient training convergence. Data augmentation techniques, including affine transformations, were applied to enhance model generalization. Experimental results demonstrated a classification accuracy of 97.4%, outperforming baseline models.

Актуальність дослідження зумовлена необхідністю покращення методів автоматизованої діагностики пневмонії на основі рентгенівських знімків легень. Пневмонія залишається однією з найпоширеніших респіраторних патологій, що потребує швидкої та точної діагностики для ефективного лікування. Традиційні методи аналізу медичних зображень, які використовують радіологи, можуть бути суб'єктивними та залежними від досвіду лікаря, що створює ризик помилкової інтерпретації [1]. Використання згорткових нейронних мереж (CNN) дозволяє автоматизувати процес діагностики, підвищуючи точність та швидкість аналізу рентгенівських знімків. У цьому дослідженні запропоновано покращений метод класифікації рентгенівських знімків для діагностики пневмонії, заснований на модифікованій архітектурі DenseNet із застосуванням методів адаптивного налаштування гіперпараметрів та покращеної попередньої обробки даних.

Основним математичним апаратом, що використовується в згорткових нейронних мережах, є операція згортки:

$$S(i, j) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} I(i+m, j+n) \cdot K(m, n), \quad (1)$$

де  $I$  – вхідне зображення;

$K$  – ядро згортки;

$S(i, j)$  – вихідна карта ознак.

Згортка дозволяє виділяти суттєві особливості зображень, такі як межі, текстури та контрасти, що є ключовими для діагностичних рішень.

Для покращення ефективності навчання використано метод оптимізації Adam із адаптивним коефіцієнтом швидкості навчання  $\eta$ , що оновлюється за правилом [2]:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t, \quad (2)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2, \quad (3)$$

$$\theta_t = \theta_{t-1} - \frac{\eta}{\sqrt{v_t} + \varepsilon} m_t, \quad (4)$$

де  $g_t$  – градієнт;

$m_t$  – експоненційне згладжене середнє першого моменту градієнта;

$v_t$  – другого моменту;

$\beta_1, \beta_2$  – параметри згладжування;

$\theta_t$  – параметри моделі.

Для побудови моделі використано архітектуру DenseNet-121, яка забезпечує ефективний механізм передачі ознак між шарами. На відміну від традиційних згорткових нейронних мереж (CNN), у DenseNet кожен шар отримує вхідні дані від усіх попередніх шарів, що покращує потік градієнтів та сприяє ефективному використанню параметрів.

Архітектура DenseNet-121 складається з 121 шару, включаючи 120 згорткових шарів та 4 шари середнього підсумовування (AvgPool) [2]. Мережа організована у вигляді щільно з'єднаних блоків (Dense Blocks), між якими розташовані перехідні шари (Transition Layers), що відповідають за зміну розмірів карт ознак за допомогою операцій згортки та підсумовування.

У кожному щільному блоці розміри карт ознак залишаються постійними, але кількість фільтрів між ними змінюється. Це дозволяє мережі ефективно повторно використовувати ознаки, що сприяє кращому навчанню та покращує узагальнюючу здатність моделі.

Завдяки своїй архітектурі, DenseNet-121 досягає високої продуктивності з меншою кількістю параметрів, що знижує ризик перенавчання. Загальний вигляд цієї архітектури наступний:

$$x_l = H_l([x_0, x_1, \dots, x_{l-1}]), \quad (5)$$

де  $x_l$  – вихідні ознаки  $l$ -го шару;

$H_l$  – нелінійне перетворення (згортка, нормалізація, активація);

$[x_0, x_1, \dots, x_{l-1}]$  – конкатенація ознак попередніх шарів.

Для покращення точності класифікації використано техніку Data Augmentation, що включає афінні перетворення [3]:

$$I'(x, y) = I(A^{-1}(x, y)), \quad (5)$$

де  $A$  – матриця афінного перетворення, яка включає масштабування, повороти та зміщення.

Результати експериментального дослідження показали, що запропонована модель перевершує традиційні підходи, досягнувши точності класифікації  $Acc = 97.4\%$ , що на  $3.8\%$  вище у порівнянні з базовими моделями. Це свідчить про значне покращення виявлення пневмонії на рентгенівських знімках, що є критично важливим для своєчасної та точної діагностики захворювання. Додатковий аналіз метрик Precision, Recall та F1-score підтвердив високу якість класифікації, що вказує на здатність моделі не лише правильно ідентифікувати випадки пневмонії, але й мінімізувати кількість хибно позитивних та хибно негативних результатів.

У ході дослідження було розроблено покращений метод класифікації рентгенівських знімків для діагностики пневмонії на основі архітектури DenseNet-121. Використання методу оптимізації Adam забезпечило швидшу та стабільнішу конвергенцію під час навчання, що є важливим для досягнення високої точності моделі.

Крім того, розширення навчальної вибірки за допомогою методів аугментації даних дозволило моделі стати більш стійкою до варіацій у даних, що покращило її узагальнюючу здатність.

Отримані результати свідчать про перспективність впровадження запропонованого підходу в системи автоматизованої діагностики медичних зображень. Висока точність та надійність моделі можуть сприяти зниженню навантаження на медичний персонал, забезпечуючи швидке та точне виявлення пневмонії. Це особливо актуально в умовах обмежених ресурсів або підвищеного попиту на медичні послуги, де автоматизовані системи можуть забезпечити своєчасну діагностику та покращити результати лікування пацієнтів.

#### Список використаних джерел:

1. Субботін С. О., Міщенко А. П., Субботін О. С. Нейронні мережі : Навч. посібник. Житомир, Вид-во Житомирського державного технологічного університету, 2020. 328 с.
2. Zhernova P., Deyneko, A., Deyneko Z., Pliss I., Ahafonov V. Data stream clustering in conditions of an unknown amount of classes // Advances in Intelligent Systems and Computing. Vol. 754, 2019. Pp. 410–418.
3. Синеглазов В. М., Коваленко А. І., Коваленко І. В. Застосування нейронних мереж для діагностики пневмонії за рентгенівськими знімками легень // Інформаційні технології та комп'ютерна інженерія. №1, 2017. С. 45-50.