

УДК 004.8:616.8

ЕКСПЕРИМЕНТАЛЬНА ОЦІНКА ЕФЕКТИВНОСТІ ЗГОРТКОВОЇ НЕЙРОННОЇ МЕРЕЖІ ДЛЯ АНАЛІЗУ ДІАГНОСТИЧНИХ ЗОБРАЖЕНЬ

Олейников О. Ю., Безкоровайний В. В.

Харківський національний університет радіоелектроніки, Харків

Одним з найбільш поширених застосувань нейронних мереж у наш час є аналіз діагностичних зображень у системах медичної діагностики, що дозволяє швидко і більш точно ідентифікувати захворювання та підтримувати клінічні рішення [1].

Для оцінки ефективності запропонованої згорткової нейронної мережі (CNN) було проведено систематичний експеримент на підготовленому датасеті Brain Stroke CT Image Dataset з платформи Kaggle, який містить КТ-зображення мозку з категоріями «Норма» та «Інсульт». Дані були розділені на навчальну та тестову вибірки у співвідношенні 80% до 20%, при цьому забезпечувалося балансування класів для уникнення зміщення моделі [2]. Для підвищення різноманітності даних та стійкості моделі застосовувалася аугментація, що включала обертання, масштабування та дзеркальні відображення зображень. Попередня обробка включала нормалізацію яскравості та контрасту, а також фільтрацію шумів, що дозволяло зменшити вплив артефактів сканування на результати класифікації.

Архітектура запропонованої моделі була розроблена з урахуванням специфіки обробки медичних КТ-зображень та необхідності виділення локальних ознак патологічних зон мозку [3]. Модель складалася з п'яти послідовних згорткових шарів, кожен із яких використовував ядро розміром 3×3 пікселі. Кількість каналів на кожному наступному згортковому шарі поступово збільшувалася від 32 до 256, що дозволяло на початкових шарах виділяти базові контури та текстурні патерни, а на глибших – більш складні та абстрактні ознаки ішемічних ділянок. Після кожного згорткового шару

застосовувався шар підвибірки MaxPooling із розміром вікна 2×2 , що забезпечувало зменшення просторового розміру ознак, підвищуючи обчислювальну ефективність і водночас зберігаючи ключову інформацію.

Для стабілізації процесу навчання та запобігання коливанням градієнтів після кожного згорткового шару була використана нормалізація пакетів (Batch Normalization), яка дозволяла стандартизувати вхідні дані для наступного шару та прискорювала конвергенцію моделі [4]. Крім того, для зниження ризику перенавчання та забезпечення узагальнювальної здатності мережі після повнозв'язних (Fully Connected) шарів застосовувався Dropout із ймовірністю 0.3, що випадково відключало певну частину нейронів під час навчання, примушуючи модель формувати більш стійкі та загальні ознаки [5].

Процес навчання моделі здійснювався із використанням адаптивного оптимізатора Adam, який поєднує переваги алгоритмів AdaGrad та RMSProp та дозволяє автоматично коригувати швидкість навчання для кожного параметра. Початкова швидкість навчання була встановлена на рівні 0.0001, що дозволяло забезпечити поступове оновлення ваг без ризику різких коливань градієнтів. Розмір пакета даних становив 32, що оптимально балансувало між ефективністю обчислень та стабільністю градієнтів. Модель навчалася протягом 50 епох із використанням функції втрат Binary Cross-Entropy, яка дозволяє моделі мінімізувати розбіжність між прогнозованими ймовірностями та фактичними мітками класів (табл. 1).

Оцінка моделі проводилася на тестовій вибірці та додатковому зовнішньому наборі КТ-зображень для перевірки узагальнювальних властивостей. Аналіз матриці невідповідностей показав, що хибні класифікації переважно виникають на зображеннях із нечітким контуром ішемічної ділянки або наявністю артефактів сканування, що вказує на можливість подальшого вдосконалення методів попередньої обробки (рис. 1).

Таблиця 1 – Параметри навчання моделі

Параметр	Значення
Оптимізатор	Adam
Початкова швидкість	0.0001
Розмір пакета	32
Кількість епох	50
Функція втрат	Binary Cross-Entropy
Dropout	0.3



Рисунок 1 – Матриця невідповідностей моделі

Динаміка функції втрат та точності під час навчання показала плавне зниження втрат та поступове збільшення точності без різких коливань, що свідчить про коректний підбір гіперпараметрів та ефективність оптимізатора (рис. 2).

Тестування на зовнішньому наборі зображень підтвердило відсутність перенавчання, оскільки точність залишалася високою на рівні 94,1%. Отримані результати доводять ефективність запропонованої архітектури CNN для задачі автоматизованого виявлення інсультів на КТ-зображеннях із

набору Brain Stroke CT Image Dataset, забезпечують високу узагальнюваність та інтерпретованість результатів, що дозволяє інтегрувати систему у клінічну практику для підтримки діагностичних рішень.



Рисунок 2 – Динаміка втрат і точності під час навчання моделі

Напрямок подальших досліджень передбачає удосконалення архітектури і параметрів мережі з урахуванням множини показників витрат і точності діагностування [6].

Література:

1. Reddy, P., & Kumar, N. Stroke Prediction Using Deep Autoencoders on Multi-Modal Imaging Data // Computers in Medicine. 2022. Vol. 30. P. 115–128.
2. Zhang, H., & Xu, L. Ensemble Deep Learning Methods for Early Stroke Detection // Journal of Biomedical Informatics. 2021. Vol. 118. Article 103790.
3. Petrenko, V., & Bondarenko, Y. CNN-based Hemorrhagic Stroke Classification from CT Scans // International Journal of Computer Assisted Radiology and Surgery. 2020. Vol. 15, No. 6. P. 1015–1026.

4. Kim, H., & Choi, Y. Attention Mechanisms in Deep Networks for Ischemic Stroke Segmentation // *Computers & Electrical Engineering*. 2021. Vol. 93. Article 107213.
5. Vlasova, V., & Minukhina, S. Deep Learning Models for Automated Stroke Detection in MRI // *IEEE Access*. 2020. Vol. 8. P. 12239–12250.
6. Beskorovainyi V. Combined method of ranking options in project decision support systems // *Innovative Technologies and Scientific Solutions for Industries*. 2020. No 4 (14). P. 13–20.