

ЗАСТОСУВАННЯ МЕТОДІВ МАШИННОГО НАВЧАННЯ ДЛЯ ПРОГНОЗУВАННЯ СТАДІЙ ЗАХВОРЮВАННЯ ЦУКРОВОГО ДІАБЕТУ

Рудой В.В., Мінухін С.В.

e-mail: valerii.rudoi@nure.ua, serhii.minukhin@nure.ua

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

This research analyzes the effectiveness of machine learning methods for predicting diabetes stages using biochemical blood test data and retinal images. The study employs deep neural networks for biochemical data analysis and convolutional neural networks for retinal image processing. A hybrid model is proposed, integrating both data types using transformer-based architectures. SHAP method is used for model explain ability, ensuring transparency for clinical use. The results demonstrate high prediction accuracy, highlighting the potential for improving diabetes management and complication prevention.

Цукровий діабет є одним із найпоширеніших хронічних захворювань у світі, яке супроводжується високим ризиком розвитку ускладнень, таких як діабетична ретинопатія, нефропатія та серцево-судинні захворювання. Рання діагностика та точне прогнозування стадій діабету мають вирішальне значення для своєчасного лікування та покращення якості життя пацієнтів [1].

З метою визначення стадії діабету використовувалися два набори даних, один з яких включає показники аналізу крові, а другий – зображення сітківки ока. Набір даних Diabetes Health Indicators Dataset містить 250 тисяч записів клінічного аналізу крові із 21 ознакою. Цільова змінна має три класи: 0 – відсутність діабету, 1 – переддіабет, 2 – діабет, що дозволяє аналізувати різні стадії захворювання [1]. Датасет APTOS Blindness Detection містить зображення очного дна, на яких зображені різні стадії діабетичної ретинопатії, що є результатом довготривалого впливу діабету на судини сітківки ока [2].

Для аналізу біохімічних показників крові були застосовані глибинні нейронні мережі (DNN), зокрема багатошарові перцептрони (MLP), які дозволяють моделювати складні нелінійні залежності між цими показниками та стадіями діабету.

Архітектура мережі включає шари:

$$y = f(W_n \cdot \sigma(\dots \sigma(W_1 \cdot X + b_1) \dots) + b_{n-1}) + b_n), \quad (1)$$

де X – вхідні дані (показники біохімічного аналізу крові), W_i – ваги для i -го шару, b_i – зміщення (bias), σ – нелінійна активаційна функція.

Мережа оптимізувалася за допомогою функції втрат на основі перехресної ентропії для задачі класифікації:

$$L = -\frac{1}{N} \sum_{i=1}^N (y_i \cdot \log(\hat{y}_i) + (1 - y_i) \cdot \log(1 - \hat{y}_i)), \quad (2)$$

де y_i – реальний клас, $\hat{y}_i$ – передбачена ймовірність, N – кількість зразків.

Для аналізу зображень сітківки ока, які є важливими для виявлення ускладнень (діабетичної ретинопатії), було застосовано згорткові нейронні мережі (CNN). CNN дозволяють автоматично витягувати інформативні ознаки із зображень завдяки застосуванню згорткових фільтрів [3]. Основна операція згортки описується рівнянням:

$$z_{i,j,k} = \sum_{m=1}^M \sum_{n=1}^N X_{i+m-1,j+n-1} \cdot K_{m,n,k} + b_k, \quad (3)$$

де X – вхідне зображення, K – фільтр, b_k – зміщення, $z_{i,j,k}$ – вихідне значення після застосування фільтру.

Після застосування згортки і пулінг-операцій (зокрема, MaxPooling) мережа формує високоінформативні ознаки, які передаються до повнозв'язних шарів для класифікації [3]. На виході для обчислення ймовірностей класів використана Софтмакс-функція:

$$P(y = c|X) = \frac{\exp(z_c)}{\sum_{k=1}^C \exp(z_k)}, \quad (4)$$

де z_k – класифікація k -го класу, C – загальна кількість класів.

В роботі запропоновано гібридний підхід, що поєднує аналіз біохімічних даних та зображень сітківки ока. Архітектура моделі складається з двох основних модулів: модуля аналізу табличних даних на основі DNN та модуля аналізу зображень на основі CNN. Інтеграція результатів здійснюється через трансформерний шар, який дозволяє враховувати вагомість кожного джерела даних.

Формально механізм уваги у трансформері можна представити у такому вигляді:

$$Attention(Q, K, V) = \text{soft max} \left(\frac{QK^T}{\sqrt{d_k}} \right) \cdot V, \quad (5)$$

де Q, K, V – матриці запитів, ключів та значень, d_k – розмірність ключів.

Такий підхід дозволяє моделі визначити, які саме ознаки з кожного джерела даних є найбільш важливими для передбачення.

Одним із методів пояснюваності моделей машинного навчання є SHAP (SHapley Additive exPlanations), який використовується для оцінки впливу кожної ознаки на остаточне передбачення [4]. Його застосування сприяє підвищенню прозорості роботи моделі та довіри до отриманих результатів. SHAP базується на концепції кооперативної теорії ігор, де

внесок кожної ознаки до передбачення обчислюється на основі Шеплі-значень:

$$\phi_i = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|!(|N|-|S|-1)!}{|N|!} [v(S \cup \{i\}) - v(S)], \quad (6)$$

де ϕ_i – внесок i -ої ознаки, N – множина всіх ознак, S – підмножина ознак без i , $v(S)$ – прогноз моделі для ознак у підмножині S , $v(S \cup \{i\}) - v(S)$ – вплив додавання ознаки i .

У дослідженні для аналізу зображень сітківки ока було використано архітектуру ResNet50, яка продемонструвала найвищу ефективність серед протестованих моделей (ResNet, EfficientNet, VGG) [5]. Оптимізація ResNet50 включала налаштування кількості епох, швидкості навчання та застосування аугментації даних (обертання, масштабування, зсуви), що підвищило стійкість моделі до варіацій у зображеннях. У результаті ResNet50 досягла високої точності (92%) у виявленні патологічних змін під час аналізу окремих зображень.

Без застосування DNN точність моделі досягала 85%. Це свідчить про значне покращення результатів після інтеграції трансформерного шару з результатами DNN. Зокрема, без використання додаткової моделі точність була обмежена через недостатню здатність базової архітектури ResNet50 до обробки складних нелінійних взаємозв'язків у зображеннях. При інтеграції з результатами DNN точність була підвищена до 94%, що дозволило моделі ефективніше виявляти особливості, пов'язані зі станом судинної сітки ока, такі як мікроаневризми та діабетична ретинопатія.

Список використаних джерел:

1. Аврунін О. Г., Бодянський Є. В., Калашник М. В., Семенець В. В., Філатов В. О. Сучасні інтелектуальні технології функціональної медичної діагностики. – Харків: ХНУРЕ, 2018. – 236 с.
2. Боровицький В. М. Розробка програм для цифрової обробки зображень з застосуванням OpenCV, Навчальний посібник. Київ: «Політехніка». – 2022. – 84 с.
3. Zhang C., Hu W. Advances in AI-driven Healthcare Solutions. – New York: CRC Press, 2022. – 320 p.
4. Захаров В. М., Козак О. П. Основи обробки медичних зображень за допомогою машинного навчання. – Львів: Видавництво Львівської політехніки, 2021. – 280 с.
5. Johnson M., Singh R. Machine Learning for Medical Diagnosis: Techniques and Applications. – London: Springer, 2023. – 350 с.