



Н. С. Мірошніченко¹, І. Г. Перова²

¹ХНУРЕ, м. Харків, Україна, nelia.miroshnychenko@nure.ua,
ORCID iD: 0000-0002-3846-1668

²ХНУРЕ, м. Харків, Україна, rikywenok@gmail.com,
ORCID iD: 0000-0003-2089-5609

ОПТИМІЗАЦІЯ ЗМЕНШЕННЯ РОЗМІРНОСТІ МЕДИЧНИХ ДАНИХ ІЗ ЗАСТОСУВАННЯМ МОДИФІКОВАНОГО АВТОЕНКОДЕРА

У статті розглядається оптимізація процесу зменшення розмірності вибірок медичних даних із застосуванням модифікованого автоенкодера. Запропонований підхід передбачає попередню обробку даних через автоенкодер для виділення найбільш інформативних ознак. Отримані скорочені представлення надалі обробляються адаптивним нейро-фаззі методом із динамічним коефіцієнтом підсилення цільових векторів, що забезпечує результати для подальшого аналізу та класифікації.

У роботі наведено математичне формулювання алгоритму, описано модифікації автоенкодера, спрямовані на підвищення точності відновлення даних та зменшення інформаційних втрат під час редукції розмірності. Проведено експериментальне дослідження на медичних наборах даних, що демонструє ефективність запропонованого методу.

ЗМЕНШЕННЯ РОЗМІРНОСТІ, NEURAL NETWORK, МОДИФІКОВАНИЙ АВТОЕНКОДЕР, МЕДИЧНІ ДАНІ, MACHINE LEARNING

N.S. Miroshnychenko, I.G., Perova. Optimization of Medical Data Sample Dimensionality Reduction Using a Modified Autoencoder. The article examines the optimization of the dimensionality reduction process for medical data samples using a modified autoencoder. The proposed approach involves preliminary data processing through the autoencoder to extract the most informative features. The resulting reduced representations are subsequently processed by an adaptive neuro-fuzzy method with a dynamic target vector amplification coefficient, which provides outputs for further analysis and classification.

The paper presents the mathematical formulation of the algorithm and describes the modifications made to the autoencoder to improve data reconstruction accuracy and reduce information loss during dimensionality reduction. An experimental study conducted on medical datasets demonstrates the effectiveness of the proposed method.

DIMENSIONALITY REDUCTION, NEURAL NETWORK, MODIFIED AUTOENCODER, MEDICAL DATA, MACHINE LEARNING

Вступ

У сучасних медичних інформаційних системах накопичуються великі обсяги даних, що містять десятки або навіть сотні ознак, пов'язаних зі станом пацієнтів, результатами лабораторних досліджень, медичними зображеннями та біомедичними сигналами. Саме висока розмірність вибірок даних ускладнює ефективну обробку, аналіз та інтерпретацію даних, спричиняючи проблему так званого «прокляття розмірності» [1]. Традиційні методи зменшення розмірності, а саме: метод головних компонент (PCA) та лінійний дискримінантний аналіз (LDA), не завжди здатні забезпечити збереження нелінійних залежностей та повноти інформації, характерних для медичних даних [2].

Автоенкодери, як один із типів штучних нейронних мереж, широко використовуються для розв'язання задач нелінійного зменшення розмірності даних [3]. Проте традиційні моделі автоенкодерів не завжди забезпечують збереження суттєвої діагностичної інформації та часто характеризуються недостатньою точністю відновлення даних. У зв'язку з цим зростає потреба в удосконаленні їхньої архітектури та інтеграції з адаптивними інтелектуальними методами для підвищення ефективності обробки даних і покращення результатів подальшої класифікації.

У даній статті запропоновано підхід до оптимізації процесу зменшення розмірності медичних даних шляхом використання модифікованого автоенкодера у поєднанні з адаптивним нейро-фаззі методом із динамічним коефіцієнтом підсилення цільових векторів. У статті подано математичне представлення автоенкодера та розглянуто особливості його взаємодії з адаптивним нейро-фаззі методом. Проведено експериментальні дослідження на реальній вибірці медичних даних з метою оцінювання ефективності запропонованого підходу.

Отримані результати підтверджують доцільність використання модифікованого автоенкодера для зменшення розмірності даних зі збереженням діагностично значущої інформації та мінімальними втратами інформативності.

1. Метод зменшення розмірності на основі модифікованого автоенкодера

Для реалізації комбінованого підходу до зменшення розмірності першочергово необхідно розглянути математичну основу модифікованого автоенкодера. Саме він забезпечує отримання інформативного компактного представлення медичних даних, яке надалі обробляється нейро-фаззі методом.

Автоенкодера – це нейронні мережі, які здійснюють зменшення розмірності даних шляхом навчання нижчовимірному представлення $z_{pre}(m)$ з початково-го високовимірною вхідного вектора $x_{pre}(m)$ та подальшої його реконструкції у вигляді $x'_{pre}(m)$.

1. Функція кодування:

Кожен вхідний високовимірний вектор $x_{pre}(m)$ перетворюється у приховане (латентне) представлення $z_{pre}(m)$. Лінійне перетворення може бути подане у вигляді вагової матриці W_{enc} та вектора зміщення b_{enc} :

$$z_{pre}(m) = \sigma(W_{enc}x_{pre}(m) + b_{enc}) \quad (1)$$

де σ – є нелінійною функцією активації, яка може бути як лінійною (наприклад, тотожне відображення), так і нелінійною (наприклад, сигмоїда, гіперболічний тангенс).

2. Функція декодування:

Приховане представлення $z_{pre}(m)$ відображається назад у наближення $x'_{pre}(m)$ до початкових даних за допомогою:

$$x'_{pre}(m) = W_{dec}z_{pre}(m) + b_{dec} \quad (2)$$

де W_{dec} – матриця ваг декодера, а b_{dec} – вектор зміщення декодера.

3. Функція втрат:

Функція втрат визначається як середньоквадратична помилка між вхідними даними, представленими вектором $x_{pre}(m)$, та реконструйованими даними $x'_{pre}(m)$ для навчання. Функція втрат задається наступним чином:

$$L = \frac{1}{K} \sum_{m=1}^K x_{pre}(m) - x'_{pre}(m)^2 \quad (3)$$

де K – загальна кількість пацієнтів [4].

4. Оптимізація:

Необхідно мінімізувати функцію втрат L , для чого застосовуються методи оптимізації, зокрема стохастичний градієнтний спуск. Важливим кроком є обчислення градієнтів функції втрат $L(x_{pre}(m), x'_{pre}(m))$ по відношенню до параметрів $W_{enc}, b_{enc}, W_{dec}, b_{dec}$. Градієнти обчислюються із застосуванням методу зворотного поширення помилки. Зокрема, градієнт функції втрат щодо параметрів декодера можна записати у такому вигляді:

$$\begin{aligned} \nabla_{x'_{pre}(m)} L(x_{pre}(m), x'_{pre}(m)) &= 2(x'_{pre}(m) - x_{pre}(m)) \\ \nabla_{W_{dec}} L(x_{pre}(m), x'_{pre}(m)) &= \nabla_{x'_{pre}(m)} L(x_{pre}(m), x'_{pre}(m)) z_{pre}(m)^T \\ \nabla_{b_{dec}} L(x_{pre}(m), x'_{pre}(m)) &= \nabla_{x'_{pre}(m)} L(x_{pre}(m), x'_{pre}(m)) \end{aligned} \quad (4)$$

Градієнт функції втрат щодо параметрів енкодера можна представити у вигляді:

$$\begin{aligned} \nabla_{z_{pre}(m)} L(x_{pre}(m), x'_{pre}(m)) &= W_{dec}^T \nabla_{x'_{pre}(m)} L(x_{pre}(m), x'_{pre}(m)) \\ \nabla_{W_{enc}} L(x_{pre}(m), x'_{pre}(m)) &= \nabla_{z_{pre}(m)} L(x_{pre}(m), x'_{pre}(m)) (x_{pre}(m))^T \\ \nabla_{b_{enc}} L(x_{pre}(m), x'_{pre}(m)) &= \nabla_{z_{pre}(m)} L(x_{pre}(m), x'_{pre}(m)) \end{aligned} \quad (5)$$

Після обчислення градієнтів функції втрат, наступним кроком необхідно оновити параметри в напрямку зменшення функції втрат. Для кожного параметра Q , де Q може бути $W_{enc}, b_{enc}, W_{dec}, b_{dec}$, оновлення виконується згідно з формулою:

$$Q \leftarrow Q - \alpha \nabla_Q L(x_{pre}(m), x'_{pre}(m)) \quad (6)$$

де α – швидкість навчання.

Зазначений алгоритм виконується для кожного навчального прикладу $x_{pre}(m)$ із тренувального набору протягом кількох епох навчання. Епохою називають один повний прохід через весь навчальний набір даних. У процесі багаторазових ітерацій (епох) значення функції втрат зазвичай поступово зменшується, що свідчить про те, що модель успішно навчається. Після завершення навчання отримане латентне (закодоване) представлення $z_{pre}(m)$ може бути використане для виконання класифікаційних задач [5].

2. Нейро-фаззі методом із динамічним коефіцієнтом підсилення цільових векторів

На відміну від стандартних нейронних мереж, даний метод поєднує механізми векторного представлення, нечітких функцій належності та конкурентного навчання. Завдяки такій комбінації модель ефективно класифікує дані навіть тоді, коли окремі об'єкти можуть належати до кількох класів одночасно.

Метод працює з набором еталонних векторів, по одному для кожної категорії. Кожен вхідний вектор порівнюється з цими еталонними представниками, після чого визначається ступінь його належності до кожного класу за допомогою спеціальних функцій належності. Вони дозволяють не лише визначити найближчий клас, але й оцінити рівень нечіткості у прийнятті рішення. Це, у свою чергу, зменшує вплив шуму та покращує роботу з реальними медичними даними, які часто є неоднорідними [6].

Навчання мережі відбувається поетапно. На кожній ітерації еталонні вектори коригуються відповідно до того, чи відповідає прогнозований клас фактичному. У разі правильної класифікації еталонний вектор наближається до вхідного, підвищуючи точність його представлення. Якщо ж прогноз помилковий, модель коригує еталонні вектори так, щоб збільшити відстань між класами. Різні правила оновлення для вектора-переможця та всіх інших забезпечують конкурентну взаємодію між класами й сприяють покращенню точності класифікації.

Ключову роль у роботі методу відіграє динамічний коефіцієнт підсилення, який визначає інтенсивність навчання. У стандартному підході його значення поступово зменшується від епохи до епохи. Натомість модифікована версія використовує рекурсивний

механізм обчислення цього коефіцієнта, що враховує як поточний стан мережі, так і накопичену інформацію з попередніх кроків. Це дозволяє здійснювати оновлення еталонних векторів більш плавно та адаптивно, що є суттєвою перевагою для медичних даних з їх складною структурою та високою варіативністю [7].

На виході метод формує мітку класу, який є найбільш ймовірним для поточного вхідного вектора. Використання нечітких функцій належності робить алгоритм стійким до варіативності у вибірці та дозволяє коректно працювати навіть тоді, коли межі між класами частково накладаються.

Детальний математичний опис представленого методу наведений в нашій попередній публікації [8].

3. Експериментальні дослідження

У попередніх розділах розглянуто класичний та модифікований автоенкодер для зменшення розмірності великої вибірки даних, а також нейро-фаззі метод для класифікації даних. З метою перевірки ефективності розглянутих підходів виконано серію експериментальних досліджень на реальних медичних даних.

В якості вибірки медичних даних було обрано медичну вибірку, що включає психофізіологічні дані пацієнтів, зібрані в рамках скринінгу на професійне вигорання. Вибірка містить результати стандартизованих психодіагностичних тестів:

1. ERI (Effort-Reward Imbalance) – оцінює дисбаланс між зусиллями, витраченими на роботу, та винагородою.

2. MBI (Maslach Burnout Inventory) – вимірює рівень емоційного вигорання, деперсоналізації та особистих досягнень.

3. FBI (Freudenberg Burnout Inventory) – визначає ступінь професійного вигорання на ранніх стадіях [9].

Вибірка дослідження складається з 228 пацієнтів. Для кожного учасника було зібрано від 200 до 269 ознак, включно з демографічними, клінічними та психодіагностичними показниками.

Для подальшої обробки та аналізу було вирішено сфокусуватися на показниках тесту Maslach Burnout Inventory (MBI), оскільки він дозволяє кількісно оцінити рівень професійного вигорання. MBI включає три підшкали:

1. Emotional Exhaustion (EE) – емоційне виснаження, що характеризує втому та зниження емоційних ресурсів;

2. Depersonalization (DP) – деперсоналізація, що відображає цинічне або відчужене ставлення до пацієнтів;

3. Personal Accomplishment (PA) – зниження особистих досягнень, що показує суб'єктивне відчуття власної професійної ефективності [10].

Після відбору лише MBI-показників загальна кількість ознак була зменшена до 25, що зробило подальшу обробку даних більш ефективною та дозволило сфокусуватися на ключових індикаторах вигорання.

Кожне питання оцінюється за шкалою Лайкерта від 0 до 6, де вищі бали для EE та DP означають більший рівень вигорання, а для PA – нижчі бали вказують на зниження почуття досягнень.

Для подальшого аналізу сумарні бали кожної підшкали було обчислено для кожного учасника, після чого кожна підшкала була категоризована у три рівні вигорання: низький, середній та високий. На основі комбінації підшкал формувался загальний показник вигорання (Result_raw), а потім учасники були розподілені у три підсумкові групи вигорання (Result_MBI). Такий підхід дозволяє врахувати одночасний стан усіх підшкал та коректно класифікувати рівень вигорання пацієнтів, навіть якщо межі між групами частково накладаються.

Аналіз розподілу пацієнтів за рівнем професійного вигорання, проведений за результатами тесту MBI, показав, що більшість працівників перебувають у групі з високим рівнем вигорання. Зокрема:

– 54,8 % (125 осіб) належать до групи з високим рівнем вигорання (група 2);

– 24,6 % (56 осіб) – до групи із середнім рівнем вигорання (група 1);

– лише 20,6 % (47 осіб) мають низький рівень вигорання (група 0).

Такий розподіл свідчить про значне поширення синдрому емоційного вигорання серед працівників, що підкреслює необхідність впровадження заходів профілактики та психологічної підтримки в цій професійній групі.

Для подальшого аналізу було вирішено використати окремі питання тесту MBI як вхідні ознаки моделей машинного навчання, а сформовані групи (Result_MBI) – як цільові мітки.

Це дозволяє не лише візуалізувати латентні представлення пацієнтів, а й оцінити ефективність методів зменшення розмірності та класифікації для визначення рівня вигорання.

На наступному етапі проведено експериментальні дослідження для оцінки ефективності методів зменшення розмірності та класифікації рівня вигорання.

Вибірку було випадковим чином розділено на навчальну й тестову підмножини у співвідношенні 80/20. Попередня обробка даних включала нормалізацію ознак методом StandardScaler, що забезпечує однаковий масштаб усіх вхідних значень та покращує збіжність моделей.

Для зменшення розмірності простору ознак було застосовано класичний та модифікований автоенкодер, які стискали 25 вхідних параметрів до 8-розмірного латентного простору (encoding_dim = 8).

Автоенкодер навчався з такими параметрами: швидкість навчання $\alpha = 0.001$, кількість епох $\text{epochs_ae} = 3000$, обмеження ваг $\text{clip_value} = 5.0$. Модифікований автоенкодер додатково містив вектор зсуву β , що мав компенсувати лінійні зміщення та покращити якість представлення латентного простору.

Після навчання латентні вектори були використані як вхідні ознаки для моделі NeuroFuzzy з динамічним коефіцієнтом підсилення цільових векторів,

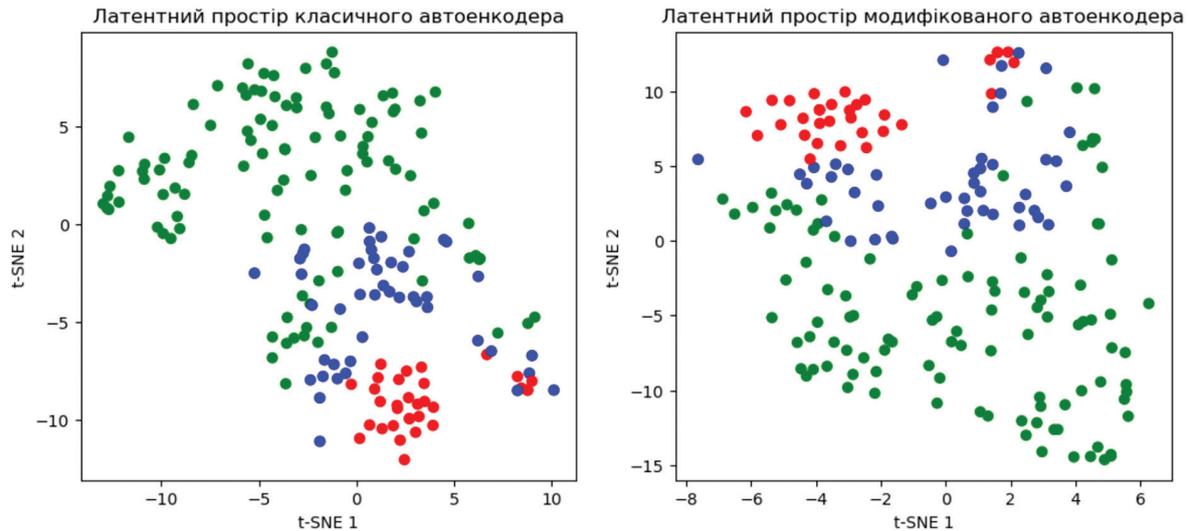


Рис. 1. Латентні представлення автоенкодерів у просторі t-SNE

Як видно з отриманих графіків Кожна точка відповідає окремому пацієнту, а колір позначає рівень вигорання за тестом МВІ: зелений – високий рівень вигорання (група 2), синій – середній рівень (група 1), червоний – низький рівень (група 0).

На лівому графіку (класичний автоенкодер у поєднанні з нейро-фаззі) точки трьох кольорів сильно перемішані між собою без чіткої структури. На правому графіку (модифікований автоенкодер у поєднанні з нейро-фаззі) спостерігається виражене розділення на три компактні, майже неперекриваючі кластери, що точно відповідають трьом рівням вигорання. Це свідчить про те, що модифікована модель успішно розплутала рівень професійного вигорання як окремий домінуючий фактор латентного простору, тоді як класичний автоенкодер такої здатності не продемонстрував.

Для порівняння впливу попередньої обробки даних було проведено експеримент на сирих, необроблених даних без застосування зменшення розмірності та нормалізації. Дані було подано на вхід моделі NeuroFuzzy з динамічним коефіцієнтом підсилення цільових векторів, після чого отримані латентні представлення було знижено до двох вимірів за допомогою t-SNE для наочного представлення. На рис. 2 наведено розподіл пацієнтів у вихідному просторі ознак без попереднього зменшення розмірності.

який адаптивно підсилює внесок менш представлених класів у процесі навчання. Це забезпечує більш збалансоване навчання та підвищує точність класифікації рівня вигорання.

Для візуального аналізу структури груп пацієнтів латентні представлення після проходження через NeuroFuzzy було знижено до двох вимірів за допомогою t-SNE [11]. На рис. 1 представлено порівняння латентних просторів для класичного та модифікованого автоенкодера після обробки NeuroFuzzy.

Ці латентні представлення відображають структуру даних після адаптації NeuroFuzzy і дозволяють оцінити, наскільки добре модель виділяє кластери пацієнтів із різними рівнями вигорання навіть у сирих, необроблених просторі ознак.

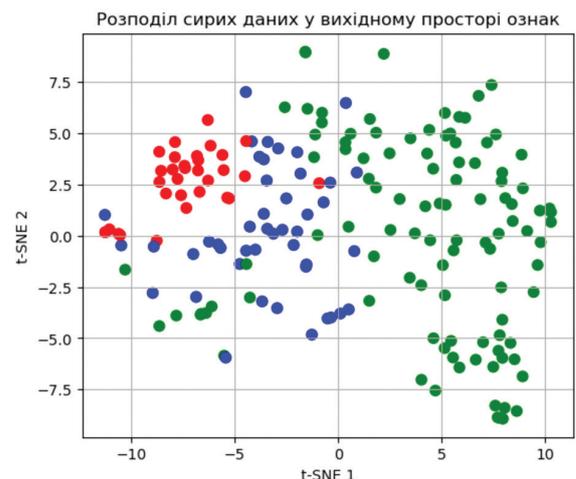


Рис. 2. Розподіл пацієнтів у вихідному просторі ознак без попереднього зменшення розмірності

Навіть без застосування будь-яких моделей у просторі оригінальних ознак помітна виразна тенденція до групування точок відповідно до рівня вигорання: червоний кластер переважно зосереджений ліворуч, синій – у центральній частині, зелений – праворуч.

Проте між класами зберігаються зони перекриття, а окремі точки суттєво віддалені від основної маси «свого» класу. Це свідчить про те, що, попри загальну розділюваність, сирі дані містять значний шум і надлишкову інформацію, які можуть ускладнювати роботу класифікатора.

Щоб кількісно оцінити, наскільки сильно ці фактори впливають на реальну продуктивність класифікації та чи здатні різні стратегії зменшення розмірності усунути зазначені проблеми, було проведено порівняльний експеримент. Нейро-фаззі класифікатор навчався і тестувався у трьох варіантах:

1) безпосередньо на сирих даних (без попередньої обробки);

2) на латентному представленні, отриманому за допомогою класичного автоенкодера;

3) на латентному представленні, отриманому за допомогою модифікованого автоенкодера.

Результати оцінки точності (ассигасу) показали наступне:

– при прямому використанні сирих даних нейро-фаззі класифікатором точність складала 0.615;

– при попередньому зменшенні розмірності класичним автоенкодером і подальшій класифікації на отриманому латентному представленні точність зросла до 0.703;

– найкращий результат – 0.850 – було отримано при використанні модифікованого автоенкодера і подальшої класифікації за допомогою нейро-фаззі метода із динамічним коефіцієнтом підсилення цільових векторів.

Таким чином, попри візуально помітну тенденцію до кластеризації у просторі сирих ознак, безпосереднє застосування нейро-фаззі класифікатора до необроблених даних дало найнижчу точність через наявність шуму, надлишкових і слабоінформативних ознак [12]. Класичний автоенкодер забезпечив певне покращення за рахунок зменшення розмірності, однак лише модифікований автоенкодер сформував високоякісне латентне представлення, у якому три рівні професійного вигорання максимально розплетані.

Висновки

Проведені експериментальні дослідження на реальних медичних даних показали, що рівень професійного вигорання, визначений за тестом Maslach Burnout Inventory (MBI), є клінічно значущим і добре вимірюваним показником. Понад половина обстежених (54,8 %) мали високий рівень вигорання, що підкреслює актуальність розробки автоматизованих інструментів ранньої діагностики та моніторингу цього стану.

Візуалізація латентних просторів та кількісна оцінка точності класифікації дозволили зробити такі основні висновки:

– Сирі дані, що складаються з 25 окремих пунктів опитувальника MBI, вже містять виражену внутрішню структуру: три рівні вигорання (низький, середній, високий) утворюють досить чіткі кластери навіть у просторі оригінальних ознак. Проте наявність зон перекриття та значної кількості шумових і надлишкових ознак суттєво обмежує ефективність прямого застосування складних класифікаторів.

– Нейро-фаззі класифікатор із динамічним коефіцієнтом підсилення менш представлених класів, навчений безпосередньо на сирих даних, продемонстрував точність лише 61,5%. Це підтверджує, що висока розмірність і шум ускладнюють формування чітких і узагальнювальних фазі-правил.

– Використання класичного автоенкодера для зменшення розмірності з 25 до 8 вимірів дозволило підвищити точність класифікації до 70,3%. Покращення пояснюється частковим усуненням шуму та надлишкових кореляцій, однак класичний автоенкодер, оптимізований лише за критерієм відновлення, не гарантує збереження і посилення дискримінативної інформації, необхідної для розрізнення рівнів вигорання.

– Найкращий результат – точність 85,0% отримано при гібридному підході модифікованого автоенкодера в парі з нейро-фаззі методом. Модифікація автоенкодера (введення параметра β) сформувала компактне 8-вимірне латентне представлення, у якому три рівні вигорання утворюють майже ідеально розділені, компактні та неперекриваючі кластери. Саме таке високоякісне представлення дозволило нейро-фаззі системі максимально ефективно побудувати прозорі, інтерпретовні та точні правила класифікації.

Запропонована гібридна модель поєднує переваги глибокого нелінійного зменшення розмірності та інтерпретовності нейро-фаззі логіки, забезпечуючи одночасно високу точність 85%, стійкість до шуму, низьку обчислювальну складність та клінічну осмисленість отриманих рішень. Це робить її перспективним інструментом для впровадження в системи скринінгу та моніторингу професійного вигорання медичних працівників високого ризику.

Отже, модифікований автоенкодер не просто виконує стискання даних, а цілеспрямовано формує латентний простір, оптимізований під задачу діагностики вигорання. Подальше використання такого представлення нейро-фаззі класифікатором є найбільш ефективним і клінічно обґрунтованим рішенням серед усіх розглянутих підходів. Подальші дослідження доцільно спрямувати на валідацію моделі на більших та різномірних вибірках, а також на інтеграцію розробленої системи в реальні процеси психологічного супроводу працівників.

Список літератури:

- [1] Wolski, M., & Gomolińska, A. (2020). Data meaning and knowledge discovery: Semantical aspects of information systems. *International Journal of Approximate Reasoning*, 119, 40–57. <https://doi.org/10.1016/j.ijar.2020.01.002>.
- [2] Ayesha, S., Hanif, M. K., & Talib, R. (2020, July). Overview and comparative study of dimensionality reduction techniques for high dimensional data. *Information Fusion*, 59, 44–58. <https://doi.org/10.1016/j.inffus.2020.01.005>.
- [3] Turchenko, V., Chalmers, E., & Luczak, A. (2019). A DEEP CONVOLUTIONAL AUTO-ENCODER WITH POOLING – UNPOOLING LAYERS IN CAFFE. *International Journal of Computing*, 18(1), 8-31. <https://doi.org/10.47839/ijc.18.1.1270>.
- [4] Miroshnychenko N., Perova I., Grebennik I., Chyhryn D Dimensionality reduction methods for large datasets. / The 13th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications, 4-6 September, 2025, Gliwice, Poland.
- [5] Miroshnychenko, N.S., Perova, I.H., Datsok, O.M. Semi-supervised learning information system for analyzing high-dimensional data samples / N.S. Miroshnychenko, I.H. Perova, O.M. Datsok // *Visnyk of the National University "Lviv Polytechnic" Information Systems and Networks*. – 2024. Issue 16. – pp. 133-144, <https://doi.org/10.23939/sisn2024.16.133> (in Ukrainian).
- [6] Sayed-Mouchaweh, M. (2020). *Artificial Intelligence Techniques for a Scalable Energy Transition: Advanced Methods, Digital Technologies, Decision Support Tools, and Applications*. Springer Nature.
- [7] Miroshnychenko N. Analysis of methods for managing high-dimensional medical data with limited patient samples / Conference proceedings "Intelligent systems of decision-making and problems of computational intelligence (ISDMCI2024)", June 20-23, 2024. P. 29-31.
- [8] Miroshnychenko N. Investigating the Management of Datasets Featuring Elevated Dimensionality and a Restricted Patient Sample. *ISDMCI 2024*, Vol. 1, pp. 349–370. https://doi.org/10.1007/978-3-031-70959-3_18.
- [9] Yuguero, O., Hodkinson, A., Panagioti, M., Pifarre, J., & Peters, D. (2023). The public health problem of burnout in health professionals. *Frontiers Media SA*.
- [10] Kinman, G. (2025). Maslach burnout inventory. *PubMed*, 74(9), 630–631. <https://doi.org/10.1093/occmed/kqae116>.
- [11] Spiwok, V., & Kříž, P. (2020, June 30). Time-Lagged t-Distributed Stochastic Neighbor Embedding (t-SNE) of Molecular Simulation Trajectories. *Frontiers in Molecular Biosciences*, 7. <https://doi.org/10.3389/fmolb.2020.00132>.
- [12] Penzenyuk, A. (2024). Автоматизоване виявлення та попередження перенаванчання в нейронних мережах. *COMPUTER-INTEGRATED TECHNOLOGIES EDUCATION SCIENCE PRODUCTION*, 54, 36–42. <https://doi.org/10.36910/6775-2524-0560-2024-54-04>.

Надійшла до редколегії 07.10.2025