2. Grad-CAM: visual explanations from deep networks via gradient-based localization / R. R. Selvaraju, M. Cogswell, A. Das et al. *Proceedings of the IEEE International Conference on Computer Vision (ICCV).* 2017. P. 18–26.

3. Ribeiro M., Singh S., Guestrin C. Why should I trust you?: explaining the predictions of any classifier. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining.* 2016. P. 115–124.

4. An image is worth 16×16 words: transformers for image recognition at scale / A. Dosovitskiy, L. Beyer, A. Kolesnikov et al. *Advances in Neural Information Processing Systems.* 2020. Vol. 33. P. 58–68.

5. Кульчицька О. Ю., Січко Т. В. Цифрова обробка зображень та відео. *Прикладні інформаційні технології:* тези доповідей Всеукраїнської науково-практичної конференції (м. Вінниця, 29 квітня 2020 р.). Вінниця, 2020. С. 110–111.

УДК 004.8

Грибаніна А. О., студентка 4 курсу спеціальності 122 «Комп'ютерні науки»,
Ніколюк П. К., д-р фіз.-мат. наук, професор кафедри інформаційних технологій

МОДЕЛІ НЕЙРОННИХ МЕРЕЖ

Донецький національний університет імені Василя Стуса, м. Вінниця

Стрімкий розвиток технологій штучного інтелекту (ШІ) зумовлює зростання попиту на адаптивні моделі, здатні обробляти складні структури даних у режимі реального часу. У сучасних дослідженнях центральне місце займають нейронні мережі – обчислювальні системи, що успішно вирішують задачі класифікації, прогнозування, аналізу образів, керування автономними системами та моделювання складних процесів.

Нейронні мережі, на відміну від класичних алгоритмів, дають змогу виявляти приховані залежності, працювати з великими обсягами даних і формувати узагальнені представлення, що підвищує їх практичну ефективність. Мета цієї роботи – проаналізувати сучасні архітектури нейронних мереж (2017–2024) та продемонструвати апроксимацію функції в MATLAB як приклад їх застосування. Особливу увагу приділено автоенкодерам, згортковим мережам (CNN), рекурентним структурам (RNN) та трансформерам.

Сучасний етап розвитку нейронних мереж характеризується переходом від простих багатошарових моделей до архітектур, які здатні опрацьовувати просторові, часові та гібридні дані (рис. 1).

До ключових ознак сучасних ШНМ належать:

– ієрархічність структури, що дає змогу поетапно формувати ознаки;
– механізми уваги, які підсилюють релевантні елементи даних;
– паралельна обробка інформації, характерна для трансформерних моделей;

– ефективне стискання та реконструкція даних, реалізовані в автоенкодерах;
– стійкість до шумів та нелінійностей, важлива для технічних систем і БПЛА.

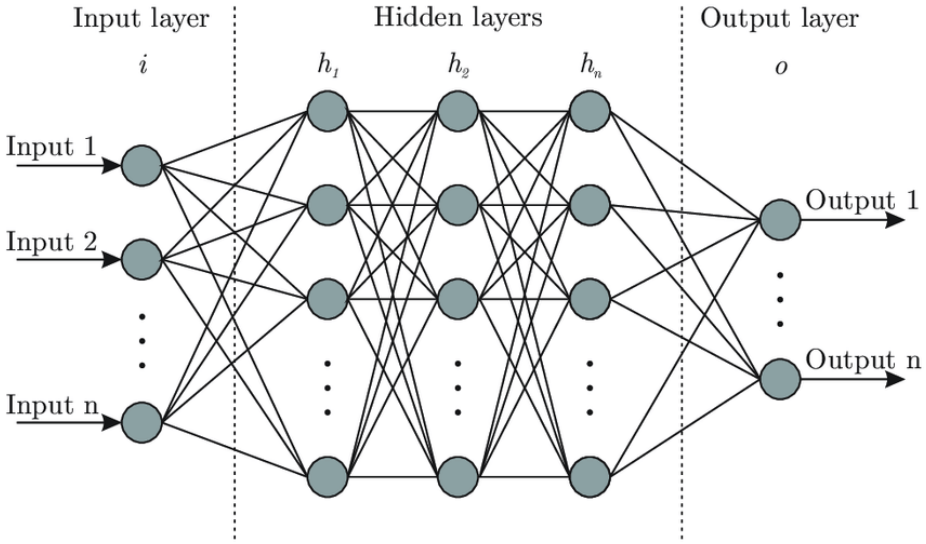


Рисунок 1 – Проста багатошарова модель.

Сучасні архітектури забезпечують глибоке семантичне розуміння даних, виходячи за межі класичної регресії чи класифікації.

Сучасні нейронні архітектури з високою науковою цінністю. Автоенкодери як засіб виявлення латентних структур. Автоенкодери застосовують для стискання та реконструкції даних, виявлення аномалій і підвищення якості зображень. Структура включає: енкодер (формує латентне представлення), декодер (відновлює дані) та латентний простір. Варіаційні автоенкодери (VAE) дають змогу моделювати розподіли даних і генерувати нові приклади.

Архітектури зі згортковими шарами (CNN). CNN ефективні для обробки просторових даних (ResNet, MobileNet, EfficientNet):

– розпізнавання та сегментація зображень;
– виявлення об’єктів на відео;
– оцінка стану поверхонь, дефектів та медичних аномалій;
– аналіз даних сенсорів у робототехніці та навігації БПЛА.

Перевага CNN – автоматичне виділення ознак без ручного проєктування фіч.

Трансформери та механізм самоуваги. Transformer із механізмом self-attention дає змогу:

– паралельну обробку великих даних;
– виявлення глобальних закономірностей;
– інтеграцію різних джерел інформації.

Застосування: Vision Transformer, GPT, BERT, класифікація аерофотознімків, автономне управління.

Гібридні нейромережеві системи. Поєднання CNN, LSTM та attention-механізмів дає змогу інтегрувати просторові та часові ознаки, підвищуючи точність прогнозування та адаптивність систем. Використовуються у робототехніці та автономних апаратах.

Експериментальне моделювання НМ у MATLAB. Щоб продемонструвати здатність нейронної мережі до навчання, було обрано завдання апроксимації заданої математичної функції. Функція для наближення: $y = \sin(x)$,

```
clc; clear; close all;

% Генерація вхідних даних та цільової функції (синус)
x = linspace(-2*pi, 2*pi, 200);
t = sin(x);

% Ініціалізація та конфігурація MLP з [10, 10] нейронами в шарах
net = feedforwardnet([10 10]);
net.trainParam.epochs = 500; % Кількість ітерацій навчання
net.trainParam.goal = 1e-5; % Цільова похибка

% Тренування моделі
net = train(net, x, t);

% Перевірка моделі (отримання виходу мережі)
y = net(x);

% Візуалізація результатів
figure;
plot(x, t, 'LineWidth', 2); hold on;
plot(x, y, '--', 'LineWidth', 2);
legend('Оригінальна функція', 'Наближення MLP');
title('Моделювання функції sin(x) за допомогою багатошарової мережі');
grid on;
```

Аналіз результатів. Розроблена модель продемонструвала високу точність наближення. Після 500 епох навчання середньоквадратична похибка знизилася до значення менше 10^{-5}. Графічне порівняння підтвердило високу точність моделі.

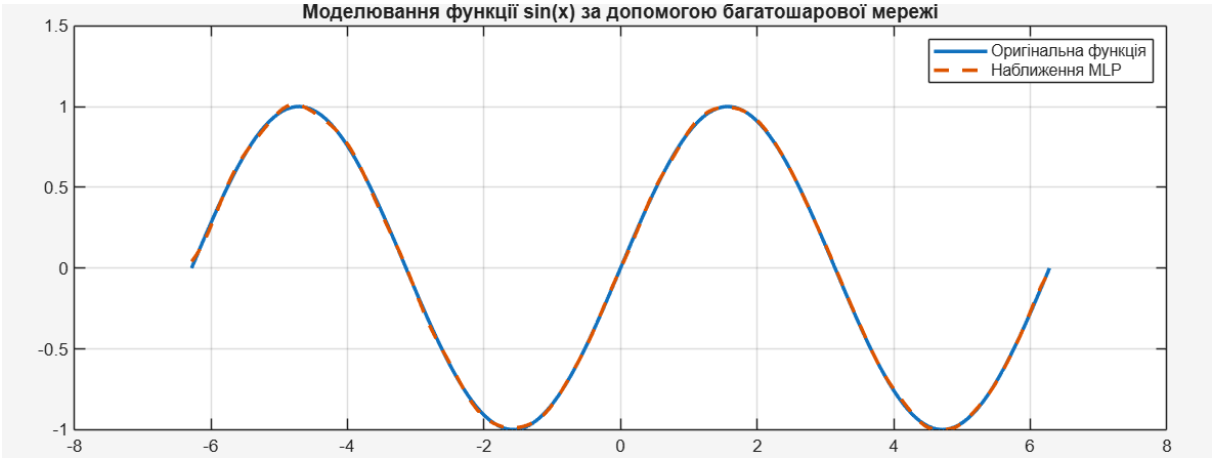


Рисунок 2 – Моделювання функції $\sin(x)$ за допомогою багатошарової мережі

Висновки. У роботі проведено поглиблений огляд сучасних архітектур нейронних мереж, що формують наукову основу сучасних систем штучного інтелекту. Особливу увагу приділено автоенкодерам, згортковим мережам, рекурентним структурам та трансформерам – моделям, що домінують у сучасних дослідженнях завдяки високій здатності до узагальнення та інтелектуального аналізу даних.

Експериментальне моделювання підтвердило здатність нейронних мереж ефективно апроксимувати складні функції, що підкреслює їх актуальність для задач прогнозування, керування та аналізу сигналів. Нейронні мережі залишаються ключовою технологією, яка визначає напрям розвитку ШІ та робототехніки.

Список використаних джерел

1. Kingma D., Welling M. Auto-encoding variational Bayes. 2014. URL: https://arxiv.org/abs/1312.6114 (дата звернення: 26.11.2025).

2. Deep residual learning for image recognition / K. He, X. Zhang, S. Ren, J. Sun. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR).* 2016. P. 770–778.

3. Hochreiter S., Schmidhuber J. Long short-term memory. *Neural Computation.* 1997. Vol. 9, № 8. P. 1735–1780.

4. Attention is all you need / A. Vaswani, N. Shazeer, N. Parmar et al. *Advances in Neural Information Processing Systems.* 2017. Vol. 30. P. 5998–6008.

5. Baltrusaitis T., Ahuja C., Morency L. Multimodal machine learning: a survey and taxonomy. *IEEE Signal Processing Magazine.* 2019. Vol. 36, № 1. P. 27–45.

УДК 004.8:330.4

Русавський О. О., аспірант,
Роштейн О. П., д-р техн. наук, професор
кафедри інформаційних технологій

ПРОЄКТУВАННЯ НЕЧІТКИХ КОГНІТИВНИХ КАРТ МЕТОДОМ НАЙМЕНШОГО ВПЛИВУ

Донецький національний університет імені Василя Стуса, м. Вінниця

Вступ. Нечіткі когнітивні карти (НКК) [1; 2] є зручним інструментом для моделювання узагальнених динамічних систем, до яких належать промислове підприємство, людський організм, бойові дії та інші системи, що розглядаються як взаємопов'язана сукупність об'єктів і процесів, які змінюються з часом [3]. Важливим етапом побудови НКК є визначення сили впливу (w_{ij}) між концептами C_i та C_j, які відповідають змінним стану системи. Пряме призначення числових значень сил впливу w_{ij} пов'язане з великою часткою суб'єктивізму. Експерту важко дати чітку числову оцінку величини w_{ij}, але він легко користується якісними порівняннями, як-от: однакова, трохи більше (менше), набагато більше (менше) тощо. Парні порівняння реалізовані в методі ієрархії Сааті [4]. Складність цього методу полягає в необхідності побудови повної матриці парних порівнянь і перевірки її узгодженості.

Для зменшення кількості опитувань експертів і обчислень пропоновано скористатись методом «найгіршого випадку», який представлено у роботі [5].