

обчислень, бажано, щоб її похідна легко обчислювалась. Найчастіше активаційна функція також є функцією з насиченням. Однією з найбільш часто використовуваних активаційних функцій є бінарна сигмоїдна функція з областю значень в (0, 1) і визначена як:

$$F_1(x) = \frac{1}{1 + e^{-x}}$$

$$, f'_1(x) = f_1(x) * [1 - f_1(x)]$$

Використання нейромережі надає змогу з високою точністю ідентифікувати обличчя людини, на основі чого можуть працювати системи надання доступу до будинку, інших помешкань або території. Недоліком таких систем є висока ціна, але їх використання є безумовно корисним для забезпечення високого рівня життя людей.

#### *Список використаних джерел*

- 1 [https://focus.ua/ukraine/449216-v\\_2019\\_godu\\_v\\_ukraine\\_zafiksirovano\\_1428\\_ubiistv\\_samyi\\_nizkii\\_uroven\\_za\\_gody\\_nezavisimos\\_tii](https://focus.ua/ukraine/449216-v_2019_godu_v_ukraine_zafiksirovano_1428_ubiistv_samyi_nizkii_uroven_za_gody_nezavisimos_tii);
- 2 [https://www.kmu.gov.ua/storage/app/sites/1/17-civik-2018/zvit\\_2019/zvit-npu-2019.pdf](https://www.kmu.gov.ua/storage/app/sites/1/17-civik-2018/zvit_2019/zvit-npu-2019.pdf);
- 3 <https://findface.pro/en/>;
- 4 <https://sud.ua/ru/news/ukraine/134506-ubiystva-v-ukraine-natspolitsiya-raskryla-statistiku>.

**Науковий керівник:** Денісова, О.О., к.е.н., доцент.

*Івченко Р. А., аспірант*  
*Криворізький національний університет*  
[ivchenko.ra@gmail.com](mailto:ivchenko.ra@gmail.com)

### **ПОБУДОВА БАГАТОШАРОВОЇ НЕЙРОМЕРЕЖЕВОЇ МОДЕЛІ ДЛЯ ПРОГНОЗУВАННЯ ВІДМОВ ЕЛЕКТРОМЕХАНІЧНОГО ОБЛАДНАННЯ ЗА ДОПОМОГОЮ БІБЛІОТЕКИ TENSORFLOW**

На сучасних великих промислових підприємствах (кількість співробітників це тисячі осіб, кількість номенклатури обладнання десятки тисяч, тощо) велика кількість достатньо складного обладнання, наприклад, механічного (млини, конвеєра) або електричного (електроприводи, насоси, електродвигуни і т.д.). На таких об'єктах як правило є служби та / або головного механіка (ОГМ) і відділи головного енергетика (ОГЕ), які займаються обслуговуванням і ремонтами (наприклад, планові та позапланові). З огляду на досить велику номенклатуру обладнання різного терміну служби, різноманітність і складність, а також зважаючи на те, що ці агрегати випускалися в різний час є необхідність застосування сучасних ІТ і систем управління, які спростили б проведення діагностики, прогнозування відмов, ремонтів, управління ТП.

Для прогнозування імовірності безвідмовної роботи та інтенсивності відмов було вирішено обрати нейромережеві структури. Розглянуто RBF (радіально базисну мережу) та багатошаровий перцептрон. У всіх випадках мережі продемонстрували здатність до фільтрації шумів. RBF в усіх випадках демонструвала трохи більше відхилення. У разі мережі радіального базису кількість нейронів збільшується в процесі навчання з метою досягнення заданої точності моделі. Однак число нейронів RBF-мережі значно (в даному дослідженні – на порядок) більше, ніж в перцептроні, що знижує швидкість роботи з RBF-мережею. У завданнях, які вимагають прогнозування поведінки функції за межами діапазону навчання, вигідніше застосовувати багатошаровий перцептрон, так як він має здатність екстраполювати функцію [1].

Було вирішено побудувати обрану модель у TensorFlow. Це відкрита програмна бібліотека для машинного навчання, розроблена компанією Google для вирішення завдань

побудови і тренування нейронної мережі. TensorFlow є системою машинного навчання Google Brain другого покоління, випущеною як відкрите програмне забезпечення.

Для прогнозування імовірності безвідмовної роботи та інтенсивності відмов було обрано метод навчання Linear Regression (лінійна регресія) за допомогою наступного коду [2]:

```
model = keras.Sequential([keras.layers.Dense(units=1, input_shape=[1])])
model.compile(tf.optimizers.Adam(learning_rate=0.001), loss='mean_squared_error')
history = model.fit(xs, ys, epochs=500)
```




Рисунок 1 – Результати тестування, співвідношення предикції до вибірки (імовірності безвідмовної роботи та інтенсивності відмов)

Як можна побачити для інтенсивності відмов, співвідношення предикції до реальних даних не демонструє точних результатів, тому буде доцільним включити Deep Learning (глибинне навчання) додаючи декілька прихованих шарів. Зробимо за допомогою наступного коду:

```
model = keras.Sequential([
    layers.Dense(64, activation='relu'),
    layers.Dense(64, activation='relu'),
    layers.Dense(1)
])
model.compile(loss='mean_absolute_error', optimizer=tf.keras.optimizers.Adam(0.001))
history = model.fit(t, RR, validation_split=0.2, verbose=0, epochs=500)
```




Рисунок 2 – Результати тестування, співвідношення предикції до вибірки (інтенсивності відмов) за допомогою багатошарової структури

Глибинне навчання – це галузь машинного навчання, що ґрунтується на наборі алгоритмів, які намагаються моделювати високорівневі абстракції в даних, застосовуючи глибинний граф із декількома обробними шарами, що побудовано з кількох лінійних або нелінійних перетворень [3].

Наразі предикція інтенсивності відмов набагато точніша і є можливість комфортно працювати з деяким відрізком даних для обраного типу обладнання.

Використовуючи багатошарові моделі перцептрона дозволило нам навчити нейромережу с меншою похибкою втрат та протестувати залежність вибірки інтенсивності відмов. Тому таку модель нейромережі буде доцільно використовувати у подальших дослідженнях та для побудови СППР.

### ***Список використаних джерел***

1. Гулаков К.В. Выбор архитектуры нейронной сети для решения задач аппроксимации и регрессионного анализа экспериментальных данных. Вестник Брянского государственного технического университета. 2013. № 2(38).
2. Базовая регрессия: прогнозирование топливной экономичности [Електронний ресурс] // TensorFlow Core – Режим доступу до ресурсу: [https://www.tensorflow.org/tutorials/keras/regression#linear\\_regression](https://www.tensorflow.org/tutorials/keras/regression#linear_regression).
3. Глибинне навчання [Електронний ресурс] // Wikipedia - Режим доступу до ресурсу: [https://uk.wikipedia.org/wiki/%D0%93%D0%BB%D0%B8%D0%B1%D0%B8%D0%BD%D0%BD%D0%B5\\_%D0%BD%D0%B0%D0%B2%D1%87%D0%B0%D0%BD%D0%BD%D1%8F](https://uk.wikipedia.org/wiki/%D0%93%D0%BB%D0%B8%D0%B1%D0%B8%D0%BD%D0%BD%D0%B5_%D0%BD%D0%B0%D0%B2%D1%87%D0%B0%D0%BD%D0%BD%D1%8F)

**Науковий керівник:** Купін А. І., д.т.н., професор.

***Картава А.І., магістр***  
*ДВНЗ «Київський національний економічний*  
*університет імені Вадима Гетьмана»*  
[\*ann.kartava@gmail.com\*](mailto:ann.kartava@gmail.com)

## **ПРОГНОЗУВАННЯ ПЕРСОНАЛЬНИХ ДОХОДІВ І ВИТРАТ СПОЖИВАЧА НА ОСНОВІ САМООРГАНІЗОВАНИХ КАРТ КОХОНЕНА**

Невід’ємною частиною управління персональними доходами та витратами будь-якого споживача є процес прогнозування, який передбачає аналіз минулих та поточних витрат та доходів, а також виявлення певних закономірностей, які дозволять споживачу своєчасно коригувати свої фінансові плани на майбутні періоди. Прогнозування персональних доходів і витрат спрощує процес виявлення закономірностей у зміні минулих та поточних доходів і витрат, щоб отримати коректний прогноз щодо майбутніх фінансових показників.

Головними проблемами прогнозування персональних доходів і витрат є:

- необхідність попереднього нагромадження даних про минулі та поточні фінансові операції споживача, на основі яких може здійснюватись аналіз і прогнозування;
- попередньо нагромаджені дані повинні бути повними та правильно категоризованими;
- вхідні дані повинні бути актуальними та зафіксованими; помилки або пропуски у даних значно погіршують якість побудованого прогнозу.

Найбільшої популярності серед методів прогнозування персональних доходів і витрат набули три основних напрямки: прогнозування з використанням адаптивних регресійних моделей, прогнозування з використанням динамічних Байєсовських мереж, а також прогнозування з використанням штучних нейронних мереж.

Як правило, адаптивні регресійні моделі використовують у короткостроковому прогнозуванні, тривалість якого не перевищує декількох місяців. Однак чим більша кількість невідомих параметрів, тим більше потрібно даних для отримання їх оцінок, і навпаки, чим