

**Євланов Максим Вікторович**, доктор технічних наук, професор, професор кафедри ІУС ХНУРЕ, м. Харків, Україна, e-mail: [maksym.ievlanov@nure.ua](mailto:maksym.ievlanov@nure.ua), ORCID: <https://orcid.org/0000-0002-6703-5166> (науковий керівник здобувача вищої освіти Лучицького В.В.).

**Мороз Борис Іванович**, доктор технічних наук, професор, професор кафедри програмного забезпечення комп'ютерних систем НТУ «Дніпровська політехніка», м. Дніпро, Україна, e-mail: [moroz.b.i@nmu.one](mailto:moroz.b.i@nmu.one), ORCID: <https://orcid.org/0000-0002-5625-0864>;

**Мороз Дмитро Максимович**, доктор філософії, доцент, доцент кафедри програмного забезпечення комп'ютерних систем НТУ «Дніпровська політехніка», м. Дніпро, Україна, e-mail: [moroz.d.m@nmu.one](mailto:moroz.d.m@nmu.one), ORCID: <https://orcid.org/0000-0003-2577-3352>

**Лучицький В'ячеслав Володимирович**, здобувач вищої освіти, група УПГІТм-22-3, факультет комп'ютерних наук, ХНУРЕ, м. Харків, Україна, e-mail: [viacheslav.luchytskyi@nure.ua](mailto:viacheslav.luchytskyi@nure.ua).

---

УДК 004.8:004.9

DOI: 10.30837/0135-1710.2024.182.093

*Є.В. БОДЯНСЬКИЙ, О.С. ЧАЛА*

## **ШВИДКА КЛАСИФІКАЦІЯ В ONLINE- ТА NEARLINE-РЕЖИМАХ В УМОВАХ КЛАСІВ, ЩО ПЕРЕТИНАЮТЬСЯ**

Предметом дослідження є процес швидкої класифікації в умовах класів, що перетинаються. Метою є розробка підходу до швидкої класифікації, який поєднує online- та nearline-режими для підвищення точності класифікації в умовах класів, що перетинаються. Розроблено багатопарову нейронну мережу з ядерними дзвонуватими функціями активації для роботи в online-режимі. Запропоновано адаптивну нейро-фаззі систему для класифікації даних у матричній формі, яка використовує гібридне комбіноване навчання для роботи в nearline-режимі. Підхід орієнтований на вирішення задач уточнення границь між класами, адаптації до змін у розподілі вхідних даних, усунення дисбалансу класів та видалення шумових точок.

### **1. Вступ**

Класифікація, яка є однією з ключових задач машинного навчання, полягає у віднесенні вхідних даних до одного з попередньо визначених класів. Ця задача має широкий спектр практичних застосувань, включаючи розпізнавання об'єктів на фотографіях, виявлення комп'ютерних вірусів, аналіз відеоданих із систем відеоспостереження тощо [1].

Швидка класифікація передбачає обробку даних у режимі реального часу (real time) або близькому до нього (near real time). Вирішення задачі швидкої класифікації потребує розробки архітектур нейронних мереж, здатних забезпечити високу точність класифікації при мінімальних обчислювальних витратах. Такі системи мають практичне застосування у задачах, де швидкість обробки є ключовим фактором, наприклад, у системах підтримки керування транспортними засобами або безпекового моніторингу [2].

Швидка класифікація поєднує online- та nearline-класифікацію. Online-класифікація орієнтована на обробку даних у режимі реального часу, що передбачає задоволення часових обмежень та, як наслідок, обмежень щодо обчислювальної складності алгоритмів обробки даних. Nearline-класифікація передбачає затримку в декілька хвилин на обробку даних, що дає можливість використовувати складніші моделі та отримати результати з вищою точністю. Як online-, так і nearline-класифікація передбачають узгодження швидкості та точності класифікації [3].

Швидка класифікація зазвичай виконується в умовах класів, що перетинаються (overlapping classes). Проблема класів, що перетинаються, виникає в тому випадку, коли об'єкти з різних класів мають схожі характеристики, тобто відповідні дані розміщуються рядом у просторі ознак. Як результат, відсутньою є чітка границя між класами, що суттєво ускладнює класифікацію [4]. Причинами перетину класів можуть бути низька роздільна здатність ознак, наявність шуму у вхідних даних, природна варіабельність даних в рамках класів тощо [5].

Реалізація швидкої класифікації в умовах класів, що перетинаються, пов'язана із вирішенням задач усунення дисбалансу класів, видалення точок шуму у просторі ознак, уточнення границі перетину класів та адаптації з урахування нестаціонарності вхідних даних (concept drift). Дисбаланс класів виникає, коли класи представлені суттєво різною кількістю зразків даних, що може впливати на точність класифікації. Точки шуму (noise points) є такими елементами даних, які не відповідають представленим класами закономірностям. Вказані точки можуть розглядатись як аномалії або викиди (outliers). Причинами точок шуму можуть бути помилки вимірювання, неправильне маркування вхідних даних для класифікації, непередбачувані впливи в процесі збору даних [6]. Видалення точок шуму у просторі ознак дає можливість підвищити точність класифікації з урахуванням випадкових флуктуацій у вхідних даних. Уточнення границі перетину класів є важливою умовою для підвищення точності класифікації у випадках, коли частина даних з різних класів має схожі характеристики. Врахування concept drift дозволяє виконати адаптацію моделі до змін у розподілі вхідних даних, які відбуваються з часом, що є актуальним для систем, які функціонують у динамічних середовищах [7].

Поєднання підходів online- та nearline-класифікації дає можливість створити умови для вирішення розглянутих задач в умовах класів, що перетинаються. Online-класифікація може бути використана для оперативного уточнення границь між класами та створення умов для адаптації до змін у розподілі вхідних даних. В подальшому в рамках nearline-класифікації можуть бути доповнені попередні результати online-класифікації за рахунок усунення дисбалансу класів та видалення шумових точок. Зазначене свідчить про актуальність інтеграції online- та nearline-підходів при реалізації швидкої класифікації в умовах класів, що перетинаються.

## **2. Аналіз літературних даних і постановка проблеми дослідження**

Методи online-класифікації орієнтовані на постійну адаптацію до нових даних у режимі реального часу. Дана адаптація реалізується з використанням інкрементного методу опорних векторів [8]. Підхід до online-класифікації з використанням еволюційних нейро-фаззі систем забезпечує високу швидкість навчання та точність класифікації [9]. Застосування нейронних мереж з нечіткою логікою для обробки потокових даних забезпечує високу точність класифікації при обмеженнях щодо витрат обчислювальних ресурсів [10]. Для вирішення задач усунення дисбалансу класів у online-режимі використовуються стратегії генерації додаткових даних у вибірці для менш представленого класу та зменшення кількості даних більш представленого класу [11]. Проте імплементація даних стратегій може привести до часткової втрати вхідної інформації.

Методи nearline-класифікації використовують розподілену обробку для зменшення часу класифікації [12]. В [13] запропоновано адаптивний підхід для обробки даних в умовах concept drift. Задача усунення дисбалансу класів вирішуються з використанням методу SMOTE, який збільшує кількість зразків менш представленого класу [14]. Видалення шумових точок здійснюється з використанням методу Edited Nearest Neighbors (ENN) для випадків, коли більшість найближчих сусідів належить до іншого класу [15].

Вдосконалену багатовимірну нео-нечітку систему для задач класифікації відео, що має можливість адаптації до змін у вхідних даних, запропоновано в [16].

Проблема класів, що перетинаються, вирішується з використанням стратегій відкидання зон перетину або їх об'єднання у мета-клас [17]. Використовується також підхід, який полягає у зменшенні кількості даних домінуючого класу у зоні перетину [18]. Використання нейро-фаззі систем для класифікації в умовах класів, що перетинаються, які здатні адаптуватися до змін у структурі даних з використанням комбінованого навчання, запропоновано в [9], [19], [20]. Такі нейро-фаззі системи та нео-нечіткі системи [16] мають можливість комплексного вирішення задач швидкої класифікації за рахунок використання ковзного вікна, адаптації границі між класами, а також використання фаззі-підходу.

Таким чином, сучасні підходи до швидкої класифікації вирішують окремо задачу усунення дисбалансу класів, видалення шумових точок у просторі ознак, уточнення границь перетину класів та адаптації до змін у розподілі вхідних даних (concept drift). Однак ці задачі в умовах класів, що перетинаються, є взаємопов'язаними і потребують комплексного вирішення. Тому при класифікації в нестационарному середовищі з дисбалансом класів, шумом у вхідних даних, перетином класів актуальною є задача побудови єдиного підходу до швидкої класифікації з використанням можливостей нейро-фаззі системи та нео-нечітких систем.

### 3. Мета і задачі дослідження

Метою даного дослідження є розробка підходу до швидкої класифікації, який поєднує online- та nearline-режими, для підвищення точності класифікації в умовах класів, що перетинаються.

Для досягнення поставленої мети у роботі вирішуються такі задачі: розробка багатопарової нейронної мережі з ядерними дзвонуватими функціями активації, що орієнтована на роботу в online-режимі; розробка адаптивної нейро-фаззі системи для вирішення задачі класифікації даних, представлених у матричній формі, яка орієнтована на роботу як у online-, так і у nearline-режимі.

Реалізація даного підходу полягає у реалізації швидкої класифікації у online-режимі з тим, щоб забезпечити оперативну адаптацію до змін у вхідних даних та подальше уточнення класифікації у nearline-режимі за рахунок усунення дисбалансу класів та видалення шумових точок.

### 4. Багатопарова нейронна мережа з ядерними дзвонуватими функціями активації

Розроблена багатопарова нейронна мережа з ядерними дзвонуватими функціями активації, яка є подальшим розвитком роботи [21], призначена для вирішення задач класифікації в умовах класів, що перетинаються, і відрізняється тим, що не потребує великих обсягів навчальних вибірок і не використовує зворотне поширення помилок.

Мережа містить три шари.

Вхідний шар отримує дані у вигляді матриць, що спрощує обробку зображень.

Прихований шар містить нейрони з ядерними дзвонуватими функціями активації, які моделюють складні нелінійні границі між класами. Рівень активації  $\psi_n(x(t))$  розраховується на основі відстані між вхідними даними та центром нейрона:

$$\psi_n(x(t)) = \exp(-Sp(x(t) - z_n)^T \Sigma_n^{-1}(x(t) - z_n)), \quad (1)$$

де  $x(t)$  – вхідні дані;  $z_n$  – центр  $n$ -го нейрона;  $\Sigma_n^{-1}$  матриця, що визначає форму та орієнтацію рецептивного поля, тобто області вхідних даних, на яку реагує конкретний

нейрон у прихованому шарі.

Такий підхід дає можливість мережі ефективно розрізняти класи навіть у випадках, коли їхні границі є складними та нелінійними.

Вихідний шар формує результат класифікації на основі виходів прихованого шару. Він використовує лінійну комбінацію виходів  $\tilde{\psi}(x(t))$  нейронів прихованого шару з вектором  $v$  вагових коефіцієнтів :

$$\hat{y}(t) = v^T \tilde{\psi}(x(t)). \quad (2)$$

Дана система використовує рекурентний алгоритм навчання, який може оновлювати параметри мережі в реальному або близькому до реального часі. Такий підхід дозволяє мережі адаптуватися до нових даних без необхідності повторного навчання на всьому наборі даних. Адаптивне налаштування параметрів функцій активації виконується за допомогою градієнтного методу. Тобто якщо поточний вихід мережі відрізняється від бажаного, ваги коригуються у напрямку, що зменшує цю різницю. Параметр швидкості навчання  $\omega_v(t+1)$  визначає, наскільки великою буде така корекція. Даний алгоритм не використовує зворотне поширення помилки, що дозволяє уникнути проблеми «зникаючого градієнта».

Таким чином, використання ядерних функцій активації забезпечує адаптацію системи до складних границь між класами при класифікації в умовах класів, що перетинаються. Онлайн-уточнення границь класів створює умови для адаптації до змін у розподілі вхідних даних.

### **5. Адаптивна нейро-фаззі система для вирішення задачі класифікації даних, представлених у матричній формі**

Адаптивна нейро-фаззі система призначена для вирішення задачі класифікації при представленні даних як у матричній, так і в векторній формі в умовах класів, що перетинаються, та є подальшим розвитком роботи [22].

Дана система складається з чотирьох шарів.

Перший шар містить нейрони, які працюють на основі активаційних функцій, що залежать від відстані між вхідними даними та певним центром у просторі ознак. Вказані центри визначаються під час навчання і розташовуються у просторі ознак так, щоб мінімізувати похибку класифікації. Кількість нейронів визначається кількістю спостережень  $N$ . Активаційні функції цього шару позначаються як  $\psi(x, z_{i_n}, \sigma_{i_n}^2)$ , де  $z_{i_n}$  – центр активаційної функції;  $\sigma_{i_n}^2$  – параметр, що визначає «ширину» дзвонуватої активаційної функції.

Другий шар складається з елементарних суматорів для кожного класу. На виходах  $o_n^{(2)}(x)$  формуються сигнали, які є оцінками Парзена щільності розподілу ймовірностей. Тобто розраховується сума активацій нейронів, що належать до  $n$ -го класу для вхідного образу  $x$ .

Третій шар коригує оцінки з урахуванням емпіричних апріорних ймовірностей та вартості помилок класифікації:

$$o_n^{(3)}(x) = o_n^{(2)}(x) \frac{N_n}{N} S_n, \quad (3)$$

де  $\frac{N_n}{N}$  – емпірична апріорна ймовірність  $n$ -го класу;  $S_n$  – вартість помилки класифікації

для  $n$ -го класу.

Вихідний шар визначає рівні належності класифікованих образів до конкретних класів.

Налаштування параметрів активаційних функцій здійснюється згідно з концепцією «нейрони в точках даних», де центри активаційних функцій визначаються як

$$z_{t_n} = x(k) | x(k) \in Cl_n, \quad (4)$$

де  $z_{t_n}$  – центр активаційної функції;  $x(k)$  –  $k$ -те спостереження у наборі даних, представлено вектором ознак;  $Cl_n$  –  $n$ -й клас.

Концепція «нейрони в точках даних» передбачає, що центри активаційних функцій нейронів встановлюються згідно зі значеннями вхідних даних. Тобто кожен нейрон у мережі відповідає конкретному спостереженню з навчального набору даних. Такий підхід забезпечує високу швидкість навчання, оскільки кожне нове спостереження стає центром відповідної активаційної функції.

Дана система використовує гібридне комбіноване навчання, яке включає «лінійне навчання» на основі концепції «нейрони в точках даних», самоорганізацію за принципом «переможець забирає все» для оновлення центроїдів класів, навчання векторного квантування для адаптивного коригування положення центроїдів, а також оцінку рівнів належності на основі нечіткої кластеризації. Навчання реалізується у послідовному online- або nearline-режимі, що дає можливість системі адаптуватись за допомогою алгоритмів рекурентного навчання. Це дозволяє системі динамічно змінювати свою архітектуру шляхом додавання нових нейронів, а також параметри у процесі надходження нових даних.

Дана система може бути використана в режимах online та nearline в залежності від обсягу даних, що обробляються. Nearline-режим дозволяє балансувати між швидкістю обробки та точністю моделі, забезпечуючи можливість більших об'ємів обчислень без значної затримки.

Дана система створює умови для усунення дисбалансу класів на основі налаштування вагових коефіцієнтів для різних класів. Видалення шумових точок може бути реалізовано на основі використання радіально-базисних функцій, що дають можливість зменшити вплив видалених точок. Крім того, nearline-навчання дає можливість уточнити класифікацію з урахуванням змін у розподілі вхідних даних.

Таким чином, комплексне використання багатошарової нейронної мережі з ядерними дзвонуватими функціями активації в online-режимі та адаптивної нейро-фаззі системи в nearline-режимі забезпечує вирішення задач уточнення границь між класами та адаптації класифікації до змін у розподілі вхідних даних, а також створює умови для вирішення задачі видалення шумових точок та усунення дисбалансу класів.

## **6. Експериментальна перевірка підходу до швидкої класифікації в умовах класів, що перетинаються, на основі комбінування online- та nearline-режимів**

Експериментальна перевірка технології виконана для задачі розпізнавання зображень у системі відеоспостереження. Такі системи використовують два відеопотоки: основний (Main Stream) та додатковий (Sub Stream). Основний потік містить відео з максимальною роздільною здатністю, доступною для відеокамери. Додатковий потік характеризується нижчою якістю зображення, що дозволяє знизити об'єм переданих через мережу даних. Додатковий потік обробляється в online-режимі, а основний – в nearline-режимі.

При проведенні експерименту використано датасет CDnet (Change Detection Dataset), який використовується для оцінки алгоритмів відеоспостереження. Він містить

послідовності кадрів з низькою і високою роздільною здатністю [23].

Для оцінки впливу concept drift використано набір «winterDriveway» із вказаного датасету із низькою роздільною здатністю 320 на 240 пікселів. Набір містить зображення машин під снігом. Починаючи з кадру in000387, відбувається зміна розподілу: на зображенні крім машин з'являється водій (рис. 1). Оцінку зміни розподілу виконано з використанням показника точності (accuracy) [24] шляхом визначення змін точності показника через 10 кадрів з округленням до сотих і представлено в табл. 1. Із таблиці видно несуттєве, в межах 2% зниження точності класифікації в результаті зміни розподілу вхідних даних.



Рис. 1. Зміна розподілу вхідних даних

Оцінка балансу класів орієнтована на обробку зображень з вищою роздільною здатністю у nearline-режимі. Для оцінки балансу класів використано показник збалансованої точності (Balanced Accuracy). Даний показник обчислюється на основі значень чутливості та специфічності [25]. Збалансована точність, на відміну від традиційного показника точності, не залежить від розподілу класів у тестовому наборі даних.

Таблиця 1

Зміна точності класифікації в результаті зміни розподілу вхідних даних

| Номер кадру | Точність, |
|-------------|-----------|
| in000387    | 0,89      |
| in000397    | 0,88      |
| in000407    | 0,87      |
| in000417    | 0,87      |
| in000427    | 0,87      |
| in000437    | 0,87      |

У процесі експерименту використано 50 зображень 720 x 576 із незбалансованого набору PETS2006 із датасету CDnet. Отримане значення показника чутливості становить 0,89, показника специфічності 0,871. Відповідно, значення показника збалансованої точності становить 0,88, що свідчить про те, що модель добре справляється з класифікацією, навіть враховуючи незбалансованість класів.

### 7. Обговорення результатів

Результати виконаної експериментальної перевірки показали, що комбінування багатосарової нейронної мережі з ядерними дзвонуватими функціями активації та адаптивної нейро-фаззі системи для класифікації даних дає можливість комплексно вирішити задачі зміни розподілу вхідних даних та балансування класів. Тобто послідовне

використання моделей в online- та nearline-режимах створює умови для вирішення типових проблем класифікації в умовах класів, що перетинаються.

Подальший розвиток підходу пов'язаний із розробкою інформаційної технології, яка на основі комбінування online- та nearline-режимів забезпечувала б також додаткове вирішення задач видалення точок шуму та усунення дисбалансу класів для проведення класифікації, що створює умови для підвищення точності класифікації при наявності помилок вимірювання внаслідок неточності сенсорів або використання некоректних методів збору даних.

## **8. Висновки**

У дослідженні розроблено підхід до швидкої класифікації в умовах класів, що перетинаються, на основі комбінування online- та nearline-режимів, який орієнтований на вирішення задач оперативної адаптації до змін у вхідних даних та уточнення результатів класифікації за рахунок усунення дисбалансу класів та видалення шумових точок. Даний підхід передбачає використання у online-режимі багатосарової нейронної мережі з ядерними дзвонуватими функціями активації та у nearline-режимі адаптивної нейро-фаззі системи, що призначена для вирішення задачі розпізнавання образів, які задані у матричній або векторній формі.

Запропоновано багатосарову нейронну мережу з ядерними дзвонуватими функціями активації. Мережа призначена для вирішення задачі класифікації в умовах класів, що перетинаються. Дана мережа відрізняється використанням рекурентного алгоритму навчання, що дає можливість відмовитись від процедури зворотного поширення помилок і, як наслідок, уникнути негативного ефекту «зникаючого градієнта». Багатосарова нейронна мережа не потребує великих навчальних вибірок і орієнтована на використання у online-режимі. У практичному плані мережа забезпечує адаптацію системи до складних границь між класами та створює умови для адаптації до змін у розподілі вхідних даних.

Запропоновано адаптивну нейро-фаззі (нейронечітку) систему для класифікації в умовах класів, що перетинаються. Система використовує дані, задані як у матричній, так і в векторній формі. Система, на відміну від існуючих, використовує гібридне комбіноване навчання для налаштування не лише синаптичних ваг, а й параметрів ядерних (дзвонуватих) функцій активації. Безпосередньо навчання реалізовано в послідовному online- або nearline-режимі при надходженні нових даних, що дає можливість уточнити результати класифікації з урахуванням змін у розподілі вхідних даних. У практичному плані мережа створює умови для усунення дисбалансу класів та шумових точок з урахуванням рівня належності для результатів класифікації.

### **Перелік посилань:**

1. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT press.
2. Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... & Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. arXiv preprint arXiv:1704.04861.
3. Wang, J., Ma, Y., Zhang, L., Gao, R. X., & Wu, D. (2018). Deep learning for smart manufacturing: Methods and applications. *Journal of Manufacturing Systems*, 48, 144-156.
4. Xiong, H., Wu, J., & Liu, L. (2010). Classification with class-overlapping: A systematic study and a new measure of class separability. *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, 40(4), 973-985.
5. Vuttipittayamongkol, P., Zhang, X., & Yang, H. (2020). Overlap-based undersampling for improving classification performance on imbalanced data with overlapping classes. *Knowledge-Based Systems*.
6. GeeksforGeeks. (2024). How to handle Noise in Machine learning? Retrieved from <https://www.geeksforgeeks.org/how-to-handle-noise-in-machine-learning/>
7. Krawczyk, B., Minku, L. L., Gama, J., Stefanowski, J., & Woźniak, M. (2017). Ensemble learning for data stream analysis: A survey. *Information Fusion*, 37, 132-156.
8. Bifet, A., Holmes, G., Kirkby, R., & Pfahringer, B. (2010). MOA: Massive Online Analysis. *Journal of Machine*

Learning Research, 11(May), 1601-1604.

9. Bodyanskiy, Y., Pliss, I., & Vynokurova, O. (2015). An adaptive learning algorithm for evolving neuro-fuzzy systems in the online mode. *Information Sciences*, 294, 189-204.
10. Bodyanskiy, Y., Pliss, I., Chala, O., & Deineko, A. (2016). Evolving fuzzy-probabilistic neural network and its online learning. In 10th International Conference on Advanced Computer Information Technologies. Deggendorf, Germany. <https://doi.org/10.1109/ACIT49673.2020.9208904>
11. Wang S., Minku L.L., Yao X. (2016). Dealing with Multiple Classes in Online Class Imbalance Learning. *Proceedings of the Twenty-Fifth International Joint Conference on Artificial Intelligence*.
12. Ma C., Zhang Y., Li J. (2023). Multi-Scenario Nearline Retrieval for E-commerce Platforms. *Journal of Data and Information Science*.
13. Žliobaitė I., Pečenizkiy M., Gama J. (2016). An overview of concept drift applications in data mining. In *Big Data Analysis: New Algorithms for a New Society*
14. Chawla N.V., Bowyer K.W., Hall L.O., Kegelmeyer W.P. (2002). SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research*.
15. Batista G.E.A.P.A., Prati R.C., Monard M.C. (2004). A Study of the Behavior of Several Methods for Balancing Machine Learning Training Data. *SIGKDD Explorations Newsletter*.
16. Bodyanskiy, Y., & Chala, O. (2024). Enhanced multidimensional neo-fuzzy classification system and its learning for the video classification task. *Management Information System and Devices*, 181, 42-50. Retrieved from [https://www.ewdtest.com/asu/wp-content/uploads/2024/09/ASUtaPA\\_181\\_42\\_50.pdf](https://www.ewdtest.com/asu/wp-content/uploads/2024/09/ASUtaPA_181_42_50.pdf)
17. Xiong H., Wu J., Liu L. (2010). Classification with class-overlapping: A systematic study and a new measure of class separability. *IEEE Transactions on Systems*.
18. Das S., Dey S., Pal S.K. (2020). Handling Class Overlap and Imbalance in Classification Problems Using a Hybrid Approach. *IEEE Transactions on Neural Networks and Learning Systems*.
19. Bodyanskiy Y., Chala O.V. & others. (2017). Evolutionary neuro-fuzzy networks with cascade structure for intelligent data analysis tasks.
20. Bodyanskiy, Y., Deineko, A., Pliss, I., & Chala, O. (2020). Fast probabilistic neuro-fuzzy system for pattern classification task. *Information Technology and Management Science*, 23, 12-16.
21. Chala, O., Bodyanskiy, Y., Sachenko, A., & Dobrowolski, M. (2023). Matrix hyper-basis function neural network and its online learning. In *The 12th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications*, September 7-9, Dortmund, Germany (pp. 1-4).
22. Bodyanskiy, Y., Deineko, A., Pliss, I., & Chala, O. (2020). Matrix fuzzy-probabilistic neural network in image recognition task. In *Proceedings of the IEEE Third International Conference on Data Stream Mining & Processing (DSMP)*, Lviv, Ukraine, August 21-25 (pp. 33-36).
23. Wang, Y., Jodoin, P.-M., Porikli, F., Konrad, J., Benezeth, Y., & Ishwar, P. (2014). CDnet 2014: An expanded change detection benchmark dataset. In *Proceedings of the IEEE Workshop on Change Detection (CDW-2014) at CVPR-2014* (pp. 387-394). Retrieved from <http://jacarini.dinf.usherbrooke.ca/dataset2014>
24. Powers, D. M. W. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness & correlation. *Journal of Machine Learning Technologies*, 2(1), 37-63.

Надійшла до редколегії 25.09.2024 р.

**Бодяньський Євген Володимирович**, доктор технічних наук, професор, професор кафедри ШІ ХНУРЕ, м. Харків, Україна, e-mail: [evgeniy.bodyanskiy@nure.ua](mailto:evgeniy.bodyanskiy@nure.ua); ORCID: 0000-0001-5418-2143  
**Чала Ольга Сергіївна**, старший викладач кафедри штучного інтелекту ХНУРЕ, м. Харків, Україна, e-mail: [olha.chala@nure.ua](mailto:olha.chala@nure.ua); ORCID: 0000-0002-7603-1247