

## ЗАСТОСУВАННЯ АЛГОРИТМІВ МАШИННОГО НАВЧАННЯ В ТЕХНОЛОГІЇ ЕЛЕКТРОННОГО НОСА

І. Оленич, О. Осадчук

*Львівський національний університет імені Івана Франка,  
вул. Драгоманова, 50, 79005 Львів, Україна  
[igor.olenych@lnu.edu.ua](mailto:igor.olenych@lnu.edu.ua)*

У роботі досліджено методи ідентифікації газів інтелектуальною системою електронного носа. Реалізовано моделі багатокласової класифікації сенсорних даних, одержаних одноелементним газовим сенсором на основі графенового польового транзистора. Досліджено ефективність розпізнавання етанолу, аміаку, ацетону та толуолу у газоподібному стані за допомогою методів опорних векторів (SVM), градієнтного підсилювання (Gradient boosting),  $k$ -найближчих сусідів (KNN) та дерева рішень (Decision tree). Виявлено, що точність ідентифікації аналізованих газів суттєво залежить від їх концентрації. Встановлено, що метод KNN забезпечує надійну ідентифікацію газів у широкому діапазоні концентрацій. Продемонстровано можливість підвищення ефективності багатокласової класифікації сенсорних даних шляхом оптимізації гіперпараметрів моделей машинного навчання.

*Ключові слова:* інтелектуальний сенсор, ідентифікація газів, машинне навчання, багатокласова класифікація.

### 1. Вступ

Сучасний рівень розвитку електроніки та інформаційних технологій дає змогу імітувати низку людських відчуттів. На відміну від комп'ютерного зору та машинного розпізнавання звуків і природної мови, які демонструють значний успіх і широке застосування, технології машинного розпізнавання смаків і запахів все ще перебувають на ранніх стадіях розвитку і потребують багато досліджень для вдосконалення та промислового масштабування. Технологія електронного носа є основним засобом як для якісної ідентифікації газів, так і кількісного визначення їхньої концентрації [1, 2]. Машинний нюх має високий потенціал для застосування у різних галузях, зокрема для моніторингу навколишнього середовища [3] і харчових продуктів [4], у медицині для діагностики різних захворювань [5, 6], хімічній і видобувній промисловості, машинобудуванні та робототехніці [7-10], у системах безпеки [11] тощо.

Штучна нюхова система охоплює три основні компоненти: газовий сенсор (первинний перетворювач), пристрій одержання та попередньої обробки сигналу, а також алгоритм розпізнавання образів. Для забезпечення ефективного виявлення та розпізнавання газів зазвичай використовують не один сенсор, а багатоелементну матрицю, кожен елемент якої характеризується індивідуальним профілем функції перетворення завдяки особливостям його виготовлення або додатковим впливом зовнішніх факторів [12, 13]. Вихідні сигнали від сенсорних елементів надходять до пристрою обробки даних, який забезпечує аналого-цифрове перетворення сигналів та

виділення ознак для подальшого аналізу. Ідентифікацію газу здійснюють за допомогою різних методів машинного або глибокого навчання. Зокрема, в технології електронного носа широко використовують аналіз головних компонент, лінійний дискримінантний аналіз, метод опорних векторів (Support vector machines, SVM), метод  $k$ -найближчих сусідів ( $k$ -nearest neighbor, KNN), кластерний аналіз, штучні нейронні мережі, а також гібридні методи [12–17].

Однак деякі методи штучного інтелекту, такі як рекурентні нейронні мережі, є надто складними для реалізації в портативних системах машинного нюху на основі малопотужних обчислювальних пристроїв. Тому розроблення простих і надійних систем електронного носа, які забезпечують ідентифікацію якнайбільшої кількості газів із задовільною точністю і можуть бути реалізовані з використанням енергоефективного обладнання, є актуальним прикладним завданням.

Хоча багатовимірні сенсорні дані, одержані матрицею чутливих елементів, можуть надати більше інформації для розпізнавання газів порівняно з одноелементним сенсором, дрейф вихідних сигналів має негативний вплив на точність ідентифікації, а його врахування для багатьох чутливих елементів може значно ускладнити аналіз [18, 19]. Зменшення кількості сенсорних елементів дає змогу не тільки спростити структуру штучної нюхової системи, але й покращити стабільність та ефективність детектування газу упродовж тривалого часу.

Щоб ідентифікувати газ одноелементним сенсором, чутливий елемент у процесі вимірювання зазвичай піддають додатковому впливу [20]. Зокрема, таким впливом може бути напруга затвору графенового польового транзистора у разі його використання як сенсорного елемента газоаналізатора [14, 21]. Враховуючи, що локальне електричне поле адсорбованих молекул суттєво впливає на залежність провідності (опору) плівки графену від напруги затвора поблизу точки нейтральності заряду, якій відповідає мінімум провідності або максимум опору, то залежність форми профілю провідності (опору) графенового польового транзистора від природи та концентрації газових молекул може бути підґрунтям для їх ідентифікації. Тому мета роботи полягала у дослідженні ефективності розпізнавання газів різними методами машинного навчання, які не потребують значних обчислювальних ресурсів і можуть бути реалізовані на мікрокомп'ютерній та мікроконтролерній базі з використанням технологій граничних обчислень (edge computing). Особлива увага була зосереджена на пошуку шляхів підвищення точності моделей машинного навчання для ідентифікації газів за допомогою одноелементної системи електронного носа на основі графенового польового транзистора.

## 2. Методи та засоби реалізації

Для дослідження було використано набори сенсорних даних, одержаних за допомогою графенового польового транзистора на основі сандвіч-структури плівка відновленого оксиду графену – поруватий кремній на кремнієві підкладці для чотирьох екологічно важливих сполук у газоподібному стані: етанолу, аміаку, ацетону і толуолу. Набори даних були у вигляді залежностей опору  $R$  плівки відновленого оксиду графену від напруги затвору  $V_G$  у діапазоні 0–1,5 В для різних концентрацій аналізованих газів. Концентрація молекул етанолу, аміаку, ацетону та толуолу поступово збільшувалась від 0 до 9–14 % з кроком 0,4; 0,3; 0,4 та 0,25 %, відповідно, що забезпечувало по 35–36 експериментальних залежностей  $R = f(V_G)$  для кожного газу при різних концентраціях. Попередня обробка сенсорних даних полягала у нормалізації вимірних значень опору, в

результаті чого було одержано набір залежностей відносного опору  $R/R_{max}$  плівки відновленого оксиду графену від напруги затвору  $V_G$ , як це ілюструє рис. 1. Значення  $R_{max}$  відповідає точці нейтральності заряду графенового польового транзистора за відсутності аналізованих газів.




Рис. 1. Залежність відносного опору  $R/R_{max}$  плівки відновленого оксиду графену від напруги затвору  $V_G$  та концентрації молекул етанолу (а), аміаку (б), ацетону (в) і толуолу (г).

Fig. 1. Dependence of the relative resistance  $R/R_{max}$  of the reduced graphene oxide film on the gate voltage  $V_G$  and the concentration of ethanol (a), ammonia (b), acetone (c) and toluene (d) molecules.

Як можна побачити на рис. 1, положення максимуму опору плівки відновленого оксиду графену на шкалі  $V_G$ , його величина і нахил лівої та правої частин профілю опору залежать як від природи аналізованого газу, так і його концентрації. Виявлені особливості відгуку електропровідності графенового польового транзистора на адсорбцію газових молекул дають змогу ідентифікувати аналізовану сполуку за допомогою моделей машинного навчання.

Комп'ютерний аналіз сенсорних даних здійснювався методами SVM, градієнтного підсилювання (Gradient boosting), KNN та дерева рішень (Decision tree). Для створення

програмних модулів було використано мову програмування Python та середовище розробки Jupyter Notebook. Обробка табличних даних здійснювалась за допомогою бібліотеки Pandas. Запропоновані моделі машинного навчання були реалізовані мовою Python з використанням бібліотеки Scikit-learn. Ця бібліотека надає широкий спектр засобів реалізації багатьох популярних алгоритмів машинного навчання, а також алгоритми для оцінювання ефективності моделей.

### 3. Результати та їх аналіз

Набори експериментальних даних для кожного аналізованого газу були об'єднані у загальний DataFrame і були розділені на навчальну та тестову вибірки, обсяг яких складав 80 і 20% від загальної кількості нормалізованих профілів опору плівки відновленого оксиду графену, відповідно. Навчені моделі машинного навчання використовувались для класифікації тестової вибірки сенсорних даних, у результаті чого були одержані звіти про ефективність розроблених моделей, які зображені на рис. 2 – рис. 5. Тут класи 0, 1, 2, 3 відповідають профілям опору сенсорного елемента під впливом адсорбції молекул етанолу, аміаку, ацетону та толуолу, відповідно.

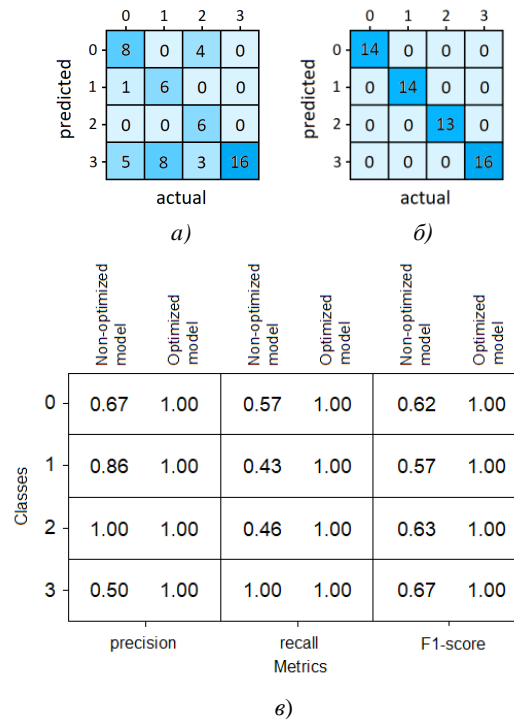


Рис. 2. Матриці невідповідностей неоптимізованої (а) та оптимізованої (б) моделей і звіт щодо оцінювання ефективності класифікації сенсорних даних методом SVM (в).

Fig. 2. Confusion matrices of non-optimized (a) and optimized (b) models and the report on the evaluation of the effectiveness of sensor data classification using the SVM method (c).

Фінальним етапом комп'ютерного аналізу сенсорних даних є оцінка ефективності реалізованих моделей. Зазвичай результати розв'язання задачі класифікації позначають як правильно або неправильно класифіковані екземпляри. Ці розв'язки візуально представляють у вигляді матриці невідповідностей (Confusion Matrix) [22]. На рис. 2 – рис. 5 також зображені матриці невідповідностей для кожної з розглянутих моделей. На основі матриць невідповідностей та їх значень були обчислені різноманітні метрики ефективності багатокласової класифікації.

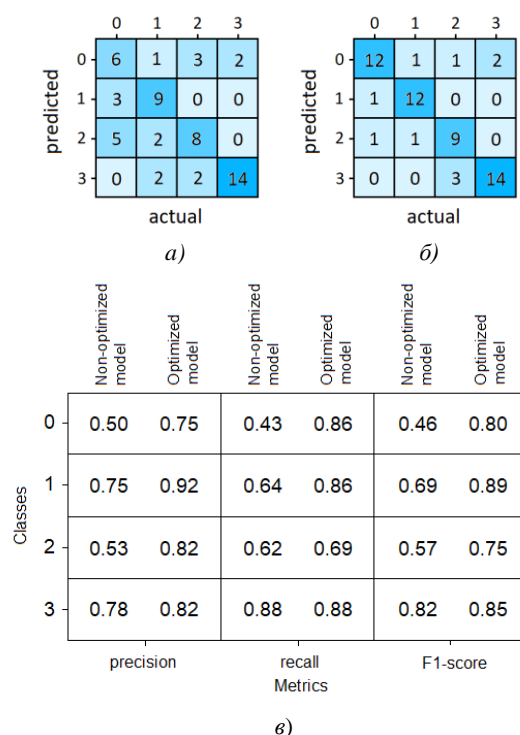


Рис. 3. Матриці невідповідностей неоптимізованої (а) та оптимізованої (б) моделей і звіт щодо оцінювання ефективності класифікації сенсорних даних методом Gradient boosting (в).

Fig. 3. Confusion matrices of non-optimized (a) and optimized (b) models and the report on the evaluation of the effectiveness of sensor data classification using the Gradient boosting method (c).

Оцінювання ефективності запропонованих моделей машинного навчання для класифікації сенсорних даних здійснювалось засобами бібліотеки Scikit-learn з використанням метрик *accuracy*, *precision*, *recall* та *F1-score*. У випадку багатокласової класифікації вони узагальнюють метрики, визначені для бінарної класифікації. Загалом, багатокласова матриця невідповідностей має розмірність  $n \times n$ , де  $n$  – кількість міток різних класів  $C_0, C_1, \dots, C_{n-1}$  (для запропонованих моделей  $n = 4$ ). Тому традиційна для бінарної класифікації характеристика екземплярів  $TP, TN, FP, FN$ , де  $TP$  і  $FP$  – кількість правильно і неправильно класифікованих екземплярів позитивного класу, а  $TN$  і  $FN$  – кількість правильно і неправильно класифікованих екземплярів негативного класу, не застосовна для цього випадку. Замість цього аналіз зосереджують на конкретному класі,

в результаті чого визначають набір показників для кожного класу. Показники для всієї матриці невідповідностей можна визначити на основі відповідної комбінації показників кожного з класів [22]. Зокрема,

- *accuracy*, яка визначає відношення правильно класифікованих екземплярів до загальної кількості екземплярів:

$$accuracy = \frac{\sum_{i=1}^n TP(C_i)}{\sum_{i=1}^n \sum_{j=1}^n C_{i,j}};$$

- *precision*, яка визначає відношення правильно класифікованих екземплярів  $C_i$ -ого класу до загальної кількості екземплярів цього ж класу:

$$precision(C_i) = \frac{TP(C_i)}{TP(C_i) + FP(C_i)};$$




Рис. 4. Матриці невідповідностей неоптимізованої (а) та оптимізованої (б) моделей і звіт щодо оцінювання ефективності класифікації сенсорних даних методом KNN (в).

Fig. 4. Confusion matrices of non-optimized (a) and optimized (b) models and the report on the evaluation of the effectiveness of sensor data classification using the KNN method (c).

- *recall*, що визначає частку правильно класифікованих екземплярів  $C_i$ -ого класу до загальної кількості дійсно позитивних екземплярів:

$$recall(C_i) = \frac{TP(C_i)}{TP(C_i) + FN(C_i)};$$

- *F1-score*, як міра узгодженості між влучністю (*precision*) і повнотою (*recall*), що демонструє наскільки багато екземплярів прогнозується моделлю правильно і скільки істинних екземплярів модель не пропустить, тобто дає змогу одержати узагальнену оцінку ефективності моделі:

$$F1 - score(C_i) = 2 \frac{precision(C_i) \cdot recall(C_i)}{precision(C_i) + recall(C_i)}.$$




Рис. 5. Матриці невідповідностей неоптимізованої (а) та оптимізованої (б) моделей і звіт щодо оцінювання ефективності класифікації сенсорних даних методом Decision tree (в).

Fig. 5. Confusion matrices of non-optimized (a) and optimized (b) models and the report on the evaluation of the effectiveness of sensor data classification using the Decision tree method (c).

Аналіз одержаних результатів дає змогу зробити висновок, що класичні методи машинного навчання класифікують сенсорні дані у вигляді залежностей відносного опору  $R/R_{max}$  плівки відновленого оксиду графену від напруги затвора  $V_G$  із задовільною точністю, що у більшості випадків дає змогу розпізнавати аналізовані гази. Проте

надзвичайно важливе значення мають кількісні та якісні характеристики набору тренувальних даних. Найбільшу точність класифікації сенсорних даних запропонованими моделями машинного навчання з базовими для бібліотеки Scikit-learn гіперпараметрами демонструє метод KNN.

Іншим важливим параметром, що може впливати на ефективність класифікації, є концентрація аналізованих газів, адже за низьких концентрацій експериментальні залежності опору плівки відновленого оксиду графену від напруги затвору при адсорбції різних газів майже не відрізняються. Щоб з'ясувати вагомість такого впливу, було визначено точність класифікації для двох наборів сенсорних даних, які відповідають концентраціям аналізованих газів  $<5\%$  і  $>5\%$  (табл. 1).

Таблиця 1. Точність (accuracy) моделей машинного навчання для багатокласової класифікації сенсорних даних.

Table 1. Accuracy of machine learning models for multi-class classification of sensory data.

Метод	Точність (accuracy) моделі			
	Для концентрації газів $<5\%$	Для концентрації газів $>5\%$	Неоптимізована модель	Оптимізована модель
SVM	0,60	0,97	0,63	1,00
Gradient boosting	0,52	0,94	0,65	0,82
KNN	0,72	1,00	0,86	0,86
Decision tree	0,44	0,94	0,72	0,75

У разі низьких концентрацій спостерігається зменшення точності багатокласової класифікації за метрикою *accuracy* порівняно з моделями, навчання та тестування яких здійснювалося з використанням повного набору даних. І навпаки, моделі машинного навчання демонструють кращу ефективність у випадку, коли тестовий набір містить тільки сенсорні дані для концентрацій молекул етанолу, аміаку, ацетону та толуолу  $>5\%$ . Найбільший вплив концентрації газових молекул на ефективність класифікації спостерігався для методів Gradient boosting і Decision tree. Зазначені методи характеризувалися доволі низькою точністю розпізнавання газів за низької концентрації. Отже, вилучення з набору даних залежності відносного опору плівки відновленого оксиду графену від напруги затвору при нульовій концентрації аналізованих газів може підвищити кількісні значення параметрів, які характеризують ефективність класифікації.

Інший спосіб підвищити точність багатокласової класифікації полягає в оптимізації гіперпараметрів запропонованих моделей машинного навчання [23]. Процес налаштування параметрів здійснювався індивідуально для кожної моделі шляхом автоматичного перебору усіх комбінацій аргументів за допомогою функції GridSearchCV. Параметри, які забезпечували найбільшу точність класифікації, були використані для тренування моделі. Зокрема, у разі використання оптимальних для розробленої моделі значень контрольного параметра помилки, типу і параметрів гіперплощини ( $C = 0,1$ ,  $\gamma = 10$ ,  $\text{kernel} = \text{poly}$ ) метод SVM забезпечував надійну ідентифікацію газів ( $\text{accuracy} = 1$ ). Для методу Gradient boosting було визначено оптимальні значення параметрів  $n\_estimators = 100$  та  $\text{learning\_rate} = 0,2$ , які визначають кількість послідовних дерев і вплив точності кожного дерева на кінцевий результат



класифікації, відповідно. Як наслідок, точність класифікації збільшилась до 82 % (див. табл. 1). Метод KNN демонстрував точність класифікації 86 % для базового значення  $n\_neighbor = 5$  кількості сусідів, що розглядаються при аналізі. Налаштування цього параметру не забезпечувало кращих значень за метрикою *accuracy*. Незначне підвищення точності розпізнавання газів (на 3 %) спостерігалось для методу Decision tree у разі вибору оптимального значення глибини дерева  $max\_depth = 10$ . Отже, оптимізація гіперпараметрів розроблених моделей машинного навчання дає змогу підвищити ефективність багатокласової класифікації сенсорних даних і точність розпізнавання газів.

#### 4. Висновки

У роботі розроблено моделі машинного навчання для ідентифікації етанолу, аміаку, ацетону та толуолу в газоподібному стані інтелектуальною системою електронного носа. За допомогою алгоритмів SVM, Gradient boosting, KNN і Decision tree проведено багатокласову класифікацію сенсорних даних у вигляді залежностей опору графенового польового транзистора від напруги затвору для різних концентрацій аналізованих газів. Здійснено порівняння ефективності розпізнавання газів запропонованими моделями машинного навчання у концентраційних діапазонах  $<5\%$  і  $>5\%$ . Встановлено, що точність ідентифікації аналізованих газів за метрикою *accuracy* суттєво залежить від їх концентрації. У зазначених діапазонах концентрацій найбільшу точність класифікації має метод KNN (0,72 і 1,00, відповідно). На основі аналізу ефективності класифікації розглянутими алгоритмами продемонстровано, що оптимізація моделей машинного навчання шляхом автоматичного налаштування їхніх гіперпараметрів дає змогу підвищити точність розпізнавання газів. Визначено оптимальні значення параметрів запропонованих моделей для моносенсорної інтелектуальної системи електронного носа.

#### СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

- [1] Xu Y., Zhao X., Chen Y., Zhao W. Research on a mixed gas recognition and concentration detection algorithm based on a metal oxide semiconductor olfactory system sensor array // *Sensors*. – 2018. – Vol. 18. – P. 3264.
- [2] Ye Z., Liu Y., Li Q. Recent progress in smart electronic nose technologies enabled with machine learning methods // *Sensors*. – 2021. – Vol. 21. – P. 7620.
- [3] Capelli L., Sironi S., Del Rosso R. Electronic noses for environmental monitoring applications // *Sensors*. – 2014. – Vol. 14. – P. 19979–20007.
- [4] Tan J., Xu J. Applications of electronic nose (e-nose) and electronic tongue (e-tongue) in food quality-related properties determination: A review // *Artificial Intelligence in Agriculture*. – 2020. – Vol 4. – P. 104–115.
- [5] Lekha S., M. S. Recent advancements and future prospects on e-nose sensors technology and machine learning approaches for non-invasive diabetes diagnosis: A review // *IEEE Rev. Biomed. Eng.* – 2021. – Vol. 14. – P. 127–138.
- [6] Vadala R., Pattnaik B., Bangaru S., Rai D., Tak J., Kashyap S., Verma U., Yadav G., Dhaliwal R.S., Mittal S., Hadda V., Madan K., Guleria R., Agrawal A., Mohan A. A review on electronic nose for diagnosis and monitoring treatment response in lung cancer // *Journal of Breath Research*. – 2023. – Vol. 17. – P. 024002.

- [7] *Huang S., Croy A., Panes-Ruiz L.A., Khavrus V., Bezugly V., Ibarlucea B., Cuniberti G.* Machine learning-enabled smart gas sensing platform for identification of industrial gases // *Adv. Intell. Syst.* – 2022. – Vol. 4. – P. 2200016.
- [8] *Li H., Wang D., Zhang Y.* Knowledge-based genetic algorithms data fusion and its application in mine mixed-gas detection // *Journal of Software.* – 2012. – Vol. 7. – P. 303–307.
- [9] *Haridas D., Chowdhuri A., Sreenivas K., Gupta V.* Fabrication of SnO<sub>2</sub> thin film based electronic nose for industrial environment // *Proceedings of the IEEE Sensors Applications Symposium, Limerick, Ireland.* – 2010. – P. 173–189.
- [10] *Maho P., Herrier C., Livache T., Comon P., Barthelmé S.* Real-time gas recognition and gas unmixing in robot applications // *Sensors and Actuators B: Chemical.* – 2021. – Vol. 330. – P. 129111.
- [11] *Iskandarani M.Z.* A novel odor key technique for security applications using electronic nose system // *Am. J. Applied Sci.* – 2010. – Vol. 7. – P. 1118–1122.
- [12] *Ma D., Gao J., Zhang Z., Zhao H.* Gas recognition method based on the deep learning model of sensor array response map // *Sensors and Actuators B: Chemical.* – 2021. – Vol. 330. – P. 129349.
- [13] *Duy N.V., Thai N.X., Ngoc T.M., Le D.T.T., Hung C.M., Nguyen H., Tonezzer M., Hieu N.V., Hoa N.D.* Design and fabrication of effective gradient temperature sensor array based on bilayer SnO<sub>2</sub>/Pt for gas classification // *Sensors and Actuators B: Chemical.* – 2022. – Vol. 351. – P. 130979.
- [14] *Hayasaka T., Lin A., Copa V.C., Lopez Jr L.P., Loberternos R.A., Ballesteros L.I.M., Kubota Y., Liu Y., Salvador A.A., Lin L.* An electronic nose using a single graphene FET and machine learning for water, methanol, and ethanol // *Microsystems & Nanoengineering.* – 2020. – Vol. 6. – P. 50.
- [15] *Mirzaee-Ghaleh E., Taheri-Garavand A., Ayari F., Lozano J.* Identification of fresh-chilled and frozen-thawed chicken meat and estimation of their shelf life using an E-nose machine coupled fuzzy KNN // *Food Anal. Methods.* – 2020. – Vol. 13. – P. 678–689.
- [16] *Kim E., Lee S., Kim J.H., Kim C., Byun Y.T., Kim H.S., Lee T.* Pattern Recognition for Selective Odor Detection with Gas Sensor Arrays // *Sensors.* – 2012. – Vol. 12. – P. 16262–16273.
- [17] *Plawiak P., Maziarz W.* Classification of tea specimens using novel hybrid artificial intelligence methods // *Sensors and Actuators B: Chemical.* – 2014. – Vol. 192. – P. 117–125.
- [18] *Liu H., Chu R.Z., Tang Z.A.* Metal oxide gas sensor drift compensation using a two-dimensional classifier ensemble // *Sensors.* – 2015. – Vol. 15. – P. 10180–10193.
- [19] *Qu C., Liu C., Gu Y., Chai S., Feng C., Chen B.* Open-set gas recognition: A case-study based on an electronic nose dataset // *Sensors and Actuators B: Chemical.* – 2022. – Vol. 360. – P. 131652.
- [20] *Su S., Hu J.* Gas identification by a single metal-oxide-semiconductor sensor assisted by ultrasound // *ACS Sensors.* – 2019. – Vol. 4. – P. 2491–2496.

- [21] *Olenych I.B., Horbenko Y.Y., Monastyrskii L.S., Aksimentyeva O.I., Boyko Y.V.* Humidity sensor element based on porous silicon – reduced graphene oxide sandwich-like structures // *Molecular Crystals and Liquid Crystals.* – 2023. – Vol. 767. – P. 9–15.
- [22] *Markoulidakis I., Rallis I., Georgoulas I., Kopsiaftis G., Doulamis A., Doulamis N.* Multiclass Confusion Matrix Reduction Method and Its Application on Net Promoter Score Classification Problem // *Technologies.* – 2021. – Vol. 9. – P. 81.
- [23] *Bergstra J., Bengio Y.* Random Search for Hyper-Parameter Optimization // *Journal of Machine Learning Research.* – 2012. – Vol. 13. – P. 281–305.

## APPLICATION OF MACHINE LEARNING ALGORITHMS IN ELECTRONIC NOSE TECHNOLOGY

**I. Olenych, O. Osadchuk**

*Ivan Franko National University of Lviv,  
50 Drahomanov St., UA–79005 Lviv, Ukraine  
[igor.olenych@lnu.edu.ua](mailto:igor olenych@lnu.edu.ua)*

Electronic nose (e-nose) technology is considered the main tool for gas identification and determination of its concentration. The artificial olfactory system includes three main components: a gas sensor or sensor matrix, receiving and pre-processing the signal device, and a pattern recognition algorithm. Gas identification is usually carried out using various methods of machine learning or deep learning. The simple and portable electronic nose systems that provide identification of the greatest possible number of gases with satisfactory accuracy and can be deployed on the low-power microcomputer and microcontroller bases are particularly promising for application in sensor electronics, IoT, robotics, etc. Therefore, the purpose of the work is to study the effectiveness of gas recognition by various machine learning methods that do not require significant computing resources and can be implemented using edge computing technologies. Particular attention was focused on improving the effectiveness of machine learning models for gas recognition.

Models of multi-class classification of the sensor data obtained using the graphene field-effect transistor in the form of dependence of the reduced graphene oxide film resistance on the gate voltage have been implemented. The effectiveness of recognition of ethanol, ammonia, acetone, and toluene in the gaseous state by support vector machine (SVM), gradient boosting, k-nearest neighbors (KNN), and decision tree methods was studied using confusion matrices and classification reports. The multi-class classification models have been evaluated according to the accuracy, precision, recall, and F1-score metrics. The effectiveness of gas recognition by the proposed machine learning models in concentration ranges <5% and >5% was compared. It was found that the accuracy of identification of the analyzed gases significantly depends on their concentration. In the specified concentration ranges, the KNN method has the highest classification accuracy (0.72 and 1.00, respectively). The possibility of increasing the accuracy of gas recognition by optimizing the hyperparameters of machine learning models has been demonstrated.

*Key words:* intelligent sensor, gas identification, machine learning, multi-class classification.

*Стаття надійшла до редакції 23.02.2024.*

*Прийнята до друку 01.03.2024.*