

Б. П. Книш, канд. техн. наук, доц.; Я. А. Кулик, канд. техн. наук, доц.

РОЗРОБКА МОДЕЛІ З ВИКОРИСТАННЯМ ВИПАДКОВОГО ЛІСУ ДЛЯ СИСТЕМИ ВИЯВЛЕННЯ ЧАДНОГО ГАЗУ НА ОСНОВІ БЕЗДРОТОВОГО ОПТИКО-ЕЛЕКТРОННОГО СЕНСОРА КОНЦЕНТРАЦІЇ

В роботі запропоновано модель з використанням випадкового лісу для системи виявлення чадного газу на основі бездротового оптико-електронного сенсора концентрації. В певному середовищі, яке може бути небезпечним для людини, розміщується сенсор, який дистанційно передає інформацію про концентрацію газу на комп'ютер, де за допомогою машинного навчання відбувається обробка отриманої інформації. В якості такого сенсора запропоновано використати оптико-електронний сенсор концентрації чадного газу завдяки високій чутливості, точності, надійності та стабільності, а також швидкій реакції, безконтактності вимірювань, стійкості до завад, можливості дистанційного моніторингу та мінімальним технічним обслуговуванням. В якості методів машинного навчання запропоновано використати метод випадкового лісу, оскільки він забезпечує високу точність в умовах неоднорідних даних та складних нелінійностей, добре працює з мінімальним тонким налаштуванням гіперпараметрів, має високу інтерпретованість, стійкість та гнучкість і найбільше підходить для виявлення чадного газу. Такі системи можуть виявляти чадний газ, шляхом вимірювання його концентрації з високою точністю за рахунок збору оптико-електронним сенсором даних у режимі реального часу, що в поєднанні з обробкою зібраних даних за допомогою машинного навчання демонструє великий потенціал у виявленні чадного газу, вимірюванні його концентрації і, відповідно, раннього попередження про його появу. Також в роботі запропоновано використовувати модель випадкового лісу для обробки даних бездротового оптико-електронного сенсора концентрації чадного газу. Для навчання цієї моделі запропоновано ознаки, що характеризують рівень поглинання та відносні зміни інтенсивності. Дослідження запропонованої моделі виявлення чадного газу на основі випадкового лісу було проведено шляхом моделювання, під час якого оцінювались точність навчання та перевірки моделі, чутливість, F-оцінка, ефективність, побудовано матрицю сплутаності за класами, а також дано оцінку важливості ознак.

Ключові слова: чадний газ, оптико-електронний сенсор, концентрація, машинне навчання, метод випадкового лісу.

Вступ

На сьогодні в багатьох галузях техніки існують різноманітні методи дослідження газів, які дають змогу визначити їх фізичні параметри, такі як густина, концентрація, вміст домішок, кількісний склад тощо. Серед них важливим параметром є концентрація.

На базі методів контролю концентрації газу створено широку класифікацію різних сенсорів, датчиків, газоаналізаторів і систем, які дають змогу вимірювати концентрацію тих чи інших газів і їх сполук в різних середовищах.

Серед газів, виявлення та контроль яких є дуже важливим, помітне місце посідає чадний газ. Це надзвичайно отруйний газ, який впливає на організм людини навіть у невеликих концентраціях. Він легко проходить крізь стіни та покриття і є одним з найбільш токсичних компонентів продуктів горіння, що входить до складу диму, і виділяється при тлінні та горінні майже всіх горючих речовин і матеріалів. Він може утворюватися, накопичуватися та поширюватися в побутових умовах, в котельних, газогенераторних, доменних, мартенівських і ливарних цехах, у вугільних шахтах, у транспортних засобах при включеному двигуні, кабінах літаків, гаражах, у хімічній промисловості під час синтезу деяких речовин тощо [1].

Таким чином, ефективне виявлення та, відповідно, реагування на появу чадного газу є Наукові праці ВНТУ, 2025, №3

надзвичайно важливою задачею. Це сприяє розвитку ефективних систем виявлення та раннього попередження про появу чадного газу. Серед таких є рішення, які поєднують сенсори з нейронними мережами чи алгоритмами машинного навчання, що дозволяє здійснювати надійне та інтелектуальне виявлення чадного газу через вимірювання його концентрації в динамічних умовах.

Нейронні мережі працюють краще у випадках, коли є набір спектрограм чи масивів даних з декількох сенсорів. Водночас для аналізу фізичних процесів вони є складними через нелінійну залежність, сенсорну деградацію, зміщення точки нуля, чутливість до різноманітних шумів та перешкод. Алгоритми машинного навчання краще та швидше працюють за обмежених обсягів тренувальних даних (до кількох тисяч точок), потребують менше часу на навчання і менш схильні до перенавчання. Наприклад, для випадку вимірювань з одного сенсора найкращим рішенням будуть методи машинного навчання, такі як RF або SVM [2, 3].

Існують різні сенсори концентрації газу, зокрема електрохімічні, каталітичні, оптико-електронні тощо. Серед них виділяються оптико-електронні сенсори завдяки високій чутливості, точності, надійності та стабільності, а також швидкій реакції, безконтактності вимірювань, стійкості до завад, можливості дистанційного моніторингу та мінімальним технічним обслуговуванням. Наведені характеристики особливо корисні у випадках використання цих сенсорів для контролю таких отруйних газів як чадний газ, оскільки забезпечують мінімальний вплив людини протягом довгого часу, що дозволяє вирішувати різноманітні задачі моніторингу, виявлення та раннього попередження про появу чадного газу.

Таким чином, в певному середовищі, яке може бути небезпечним для людини, розміщується сенсор, який дистанційно передає інформацію про концентрацію газу на комп'ютер, де за допомогою машинного навчання відбувається обробка отриманої інформації. Такі системи можуть виявляти чадний газ, шляхом вимірювання його концентрації з високою точністю за рахунок збору оптико-електронним сенсором даних у режимі реального часу. Ці дані в подальшому передаються на комп'ютер, де за допомогою машинного навчання відбувається їх обробка, що демонструє великий потенціал у виявленні чадного газу, вимірюванні його концентрації і, відповідно, раннього попередження про його появу.

Це створює перспективну основу для розгортання інтелектуальних систем виявлення та вимірювання концентрації чадного газу у реальних середовищах з поєднанням оптико-електронних сенсорів концентрації та методів машинного навчання.

Таким чином, **метою роботи** є підвищення точності виявлення чадного газу шляхом розробки моделі з використанням машинного навчання для системи виявлення чадного газу на основі бездротового оптико-електронного сенсора концентрації.

Бездротовий оптико-електронний сенсор концентрації чадного газу

Система виявлення чадного газу передбачає в своєму складі наявність оптико-електронного сенсора концентрації чадного газу, який перебуває в робочому середовищі та передає дані про концентрацію чадного газу на комп'ютер.

В якості такого сенсора обрано оптичний сенсор концентрації газу [4], який завдяки конструктивним особливостям вирізняється високою точністю та чутливістю, оскільки дозволяє знехтувати молярними масами та питомими показниками поглинання газів, густинами, тисками, температурами, товщиною шару газу та розсіювальними властивостями матеріалів, усунути нестабільність роботи й старіння фотоприймачів і світлодіодів. На рис. 1 наведена схема оптичного сенсора концентрації газу, що складається з трьох кювет – вимірювальної 1, в якій міститься газова суміш, кювети з чистим повітрям 2 та кювети з іншим чистим газом 3, наявність якого досліджується в газовій суміші.




Рис. 1. Схема оптичного сенсора концентрації газу: 1 – вимірювальна кювета; 2 – кювета з чистим повітрям; 3 – кювета з іншим чистим газом; 4 – діафрагма; 5, 6, 7 – джерела інфрачервоного випромінювання; 8, 9, 10 – приймачі інфрачервоного випромінювання; 11 – блок керування; 12 – підсилювач; 13 – комутатор; 14 – аналого-цифровий перетворювач; 15 – мікропроцесорний пристрій; 16 – індикаторне табло; 17, 17' – вхідні і вихідні оптичні системи, відповідно

Аналізована газова суміш прокачується через вхідний патрубок вимірювальної кювети 1. Потіки інфрачервоного випромінювання від джерел інфрачервоного випромінювання 5, 6, 7, які керуються блоком керування 11, проходить спочатку через вхідні оптичні системи 17 для розсіювання світлових потоків, а потім через вимірювальну кювету 1, де частково поглинаються аналізованою газовою сумішшю. Вона тисне на діафрагми 4 кювети з чистим повітрям 2 та кювети з іншим чистим газом 3, пропорційно його концентрації. Також потоки інфрачервоного випромінювання проходять через кювету з чистим повітрям 2 і кювету з іншим чистим газом 3 та потрапляють на вихідні оптичні системи 17' для збирання світлових потоків. Далі потоки інфрачервоного випромінювання, які пройшли через кювети 1, 2, 3, потрапляють на приймачі інфрачервоного випромінювання 8, 9, 10, на виході яких виникають електричні сигнали, які пропорційні концентрації аналізованої газової суміші, що знаходиться у вимірювальній кюветі 1, чистого повітря, що знаходиться в кюветі 2, та іншого чистого газу, що знаходиться в кюветі 3. Сигнали з приймачів інфрачервоного випромінювання 8, 9, 10 підсилюються за допомогою підсилювачів 12, об'єднуються за допомогою комутатора 13, і далі надходять до аналого-цифрового перетворювача 14, де аналоговий сигнал перетворюється в цифровий, і потрапляють через шину на вхід мікропроцесорного пристрою 15, який має обернений зв'язок з комутатором 13. Цифровий код, що пропорційний концентрації кожного з газів, обробляється в мікропроцесорному пристрої 15 і виводиться через шину на цифрове індикаторне табло 16 [5].

Аналізована газова суміш, яка прокачується через вимірювальну кювету, порівнюється з чистим повітрям та з іншим чистим газом, в якості якого використовується чадний газ, що перебувають у відповідних кюветах. Причому вимірювання концентрації чадного газу проводяться у відповідності до ДСТУ EN 14626:2018 [6].

Оптичний сенсор концентрації газу, який описано вище, можна модифікувати так, щоб замість комутатора, аналого-цифрового перетворювача, мікропроцесора та цифрового індикаторного табло використовувати модуль бездротового зв'язку. Він передає сигнали з приймачів на комп'ютер, де за рахунок машинного навчання буде відбуватися обробка цих даних, що дозволить здійснювати вимірювання концентрації чадного газу в аналізованій газовій суміші.

Методи машинного навчання у системах виявлення чадного газу

Сучасні методи машинного навчання, такі як методи дерева рішень (DT), опорних векторів (SVR), випадкового лісу (RF) тощо, довели свою ефективність у виявленні газів та вимірюванні їх концентрації на основі сенсорних даних. Це пов'язано з їхньою здатністю автоматично виявляти та моделювати нелінійний взаємозв'язок між оптичними властивостями газів та їх концентрацією.

В роботі [7] використовується метод дерева рішень, який створює одне дерево поділу даних за ознаками до встановленої глибини або до мінімальної кількості вимірювань. Метод простий в реалізації, забезпечує швидке виконання навіть за великих масивів даних, має інтуїтивно зрозумілу логіку рішень, забезпечує високу точність в умовах неоднорідних даних та складних нелінійностей. Недоліком методу є високий ризик до перенавчання на навчальних даних та порівняно з іншими методами машинного навчання, часто демонструє меншу точність, незважаючи на хорошу інтерпритованість.

В дослідженні [8] застосовувався метод опорних векторів, який будує регресію з максимальним допуском помилки та мінімізує вагу моделі. Метод має високу точність визначення концентрації газів на малих або середніх наборах даних та менш схильний до перенавчання при правильному налаштуванні функції ядра. Проте метод чутливий до кількості ознак, вимагаючи стандартизації даних, та має квадратичну складність і гіршу інтерпритованість порівняно з іншими методами машинного навчання.

В роботі [9] використовується метод випадкового лісу, який будує ансамбль рішень дерев із бутстреп-обраними підмножинами та випадковим вибором ознак, а результат агрегується як усереднення прогнозів дерев. Цей метод забезпечує високу точність в умовах неоднорідних даних та складних нелінійностей, добре працює з мінімальним тонким налаштуванням гіперпараметрів, має високу інтерпритованість, стійкість та гнучність і найбільше підходить для виявлення чадного газу.

В роботі [10] було досліджено калібрування портативних/стаціонарних сенсорних платформ у міських та промислових зонах. Система RAMP (платформа з ЕС-сенсорами CO, NO₂, O₃, CO₂) проходила польове калібрування у місті Піттсбург (США) поруч з стаціонарними станціями вимірювання якості повітря. В роботі порівнювали прості лінійні та ансамблеві моделі. Було показано, що RF-модель, використовуючи всі сенсорні сигнали, а також температуру та вологість, була більш точною та стабільною впродовж місяців. Проте модель є складною, оскільки використовує надмірну кількість параметрів.

В роботі [11] досліджено застосовування RF-моделі у шахтах та тунелях для прогнозу пожеж та рівня забруднення чадним газом на основі даних сенсорних мереж. Ця модель базується на модифікованому DV-Нор методі, характеризується простотою налаштування й стійкістю до розкиду характеристик сенсорів. Також вона забезпечує високу точність і надійність для промислового використання. Проте в роботі використовується лише один метод, який складно порівняти з іншими.

Таким чином, можна стверджувати, що наявні моделі на основі методів випадкового лісу показують високу точність, проте мають суттєві недоліки, що робить їх непридатними для використання у нашій системі. Тому виникає необхідність у розробці власної моделі виявлення чадного газу на основі випадкового лісу.

Запропонована модель виявлення чадного газу на основі випадкового лісу

В роботі запропоновано модель виявлення чадного газу на основі випадкового лісу, яка обробляє дані з вищенаведеного модифікованого оптичного сенсора концентрації чадного газу. Для навчання цієї моделі запропоновано ознаки, які розраховуються на основі трьох сигналів з приймачів інфрачервоного випромінювання, яке проходить через кювети з чистим повітрям (інтенсивність I_{air}), чадним газом (інтенсивність I_{ref}) і аналізованою газовою сумішшю (інтенсивність I_{sample}). З цих сигналів обчислюються ознаки, що характеризують

рівень поглинання та відносні зміни інтенсивності. Оскільки поглинання світла чадним газом залежить від його концентрації, то відношення між інтенсивностями I_{air} , I_{ref} та I_{sample} дозволяє виявити наявність і концентрацію чадного газу.

Для кожного з трьох сенсорів обчислюються три незалежні числові ознаки. Ознаки формуються наступним чином:

$$f1 = \frac{I_{air} - I_{sample}}{I_{ref} - I_{air} + \varepsilon}, \quad (1)$$

$$f2 = \frac{I_{sample} - I_{ref}}{I_{ref} - I_{air} + \varepsilon}, \quad (2)$$

$$f3 = \frac{I_{sample}}{I_{air} + \varepsilon}, \quad (3)$$

де ε – дуже мале значення, додане для уникнення ділення на нуль.

$f1$ показує наскільки інтенсивність для аналізованої газової суміші відхиляється від значення для чистого повітря до значення для чадного газу. Чим ближче I_{sample} до I_{ref} , тим більше значення, тому $f1$ найбільш чутлива до зміни концентрації чадного газу. $f2$ показує наскільки інтенсивність для аналізованої газової суміші менша або більша за I_{ref} . $f3$ – базова оптична характеристика поглинання випромінювання в аналізованій газовій суміші порівняно з чистим повітрям.

Ці ознаки дають можливість моделі працювати в реальному часі на основі сенсорних даних. Підготовка даних для запропонованої моделі випадкового лісу починається зі збору сигналів з приймачів інфрачервоного випромінювання. Після цього обчислюються числові ознаки, які описують зміну сигналу внаслідок порівняння інтенсивності випромінюванням через аналізовану газову суміш з аналогічним випромінюванням через чисті повітря та чадний газ. На основі обчислених ознак формується вектор ознак, у якому кожен рядок відповідає конкретній ознаці. Далі він нормалізується, що необхідно для стабільної роботи моделі та компенсації відмінностей між інтенсивностями. Після формування повного набору даних вони розбиваються на навчальну та перевірочну вибірки, що дозволяє оцінити узагальнюючу здатність моделі. Частка для початкової та перевірочної вибірки становить 75 % та 25 %, відповідно. Дані подаються до моделі випадкового лісу, яка окремо навчається на задачі класифікації для виявлення чадного газу. Була використана 10-кратна кросс-валідація. Навчання моделі проводилось на 2000 зразках. Цього достатньо для невеликої кількості ознак, оскільки модель застосовується в контрольованих умовах. Дані охоплюють широкий діапазон концентрації чадного газу близький до гранично допустимої концентрації (ГДК). Дані розподілені приблизно рівномірно між класами моделі.

Для систем виявлення чадного газу або раннього попередження, наприклад, у «розумному будинку» або виробничому середовищі оптимальним буде встановити поріг виявлення чадного газу на рівні, близьким до стандартів про ГДК [12]. В таблиці 1 показано концентрації, за якими модель виконує розподіл на класи: «немає», «незначна концентрація», «середня концентрація», «висока концентрація», «дуже висока концентрація».

Таблиця 1

Класи запропонованої моделі випадкового лісу

Номер класу	Назва	ppm	Коментар
0	Немає	0–0,5	Фонове значення у повітрі
1	Незначна концентрація	0,5–9	Допустимий рівень для дому та роботи
2	Середня концентрація	9–35	Перевищення в межах 1–8-годинної норми
3	Висока концентрація	35–100	Перевищення 1- годинної норми
4	Дуже висока концентрація	>100	Небезпечні значення, ризик тяжких отруєнь

Значення гіперпараметрів показано в таблиці 2.

Таблиця 2

Гіперпараметри запропонованої моделі випадкового лісу

Гіперпараметри	Значення
Максимальна кількість дерев	300
Максимальна глибина дерева	20
Мінімальна кількість зразків для поділу вузла	2
Мінімальна кількість зразків у листі	3
Кількість ознак при пошуку найкращого розподілу	'sqrt'
Бутстреп	Так
Метрика оцінки якості розподілу	Індекс Джині
Фіксація повторюваності результату	42

Основними показниками ефективності запропонованої моделі було обрано: точність, чутливість і F -оцінку [13]. Така модель може забезпечити ефективне вимірювання концентрації, а, отже, виявлення чадного газу за допомогою оптичного сенсора.

Дослідження запропонованої моделі випадкового лісу

Дослідження запропонованої моделі виявлення чадного газу на основі випадкового лісу було проведено шляхом моделювання, під час якого оцінювались точність навчання та перевірки моделі, чутливість, F -оцінка, ефективність, побудовано матрицю сплутаності за класами, а також дано оцінку важливості ознак. Для кожного з 5-ти класів модель демонструє високу ефективність, однак значення цих показників варіюється залежно від класу (таблиця 3).

Таблиця 3

Показники ефективності для класів запропонованої моделі випадкового лісу

Номер класу	Показники ефективності		
	Точність	Чутливість	F -оцінка
0	0,854	0,960	0,904
1	0,916	0,827	0,869
2	0,973	0,964	0,969
3	1,000	0,973	0,986
4	0,991	1,000	0,996

Як видно з таблиці 3, значення точності, чутливості та F -оцінки є досить значними, що вказує на високу ефективність запропонованої моделі випадкового лісу. У класах з малими значеннями концентрації точність дещо менша через більший вплив шумів та завад. Для класів 0 (відсутність чадного газу) та 1 (незначна концентрація) модель добре виявляє цей клас, але деякі з інших класів помилково відносить до нього. Для класів 2 (середня концентрація), 3 (висока концентрація) та 4 (дуже висока концентрація) відбувається втрата невеликої частини правильно виявлених випадків цього класу. Таким чином, модель краще виявляє чадний газ при зростанні значення його концентрації.

На рис. 2 показано побудовану матрицю сплутаності на основі передбачених і фактичних міток.




Рис. 2. Матриця сплутаності для моделі випадкових лісів за 5 класами

Як видно з рис. 2, найбільші помилки спостерігаються за малих концентрацій, що відповідає класам «немає» та «незначна». Це пов'язано з тим, що за малих значень більший вплив похибки сенсора. Найбільш точне виявлення чадного газу відбувається за великих значень концентрації. Загалом, матриця підтвердила, що для деяких класів (наприклад, плутання «немає» з «дуже висока») грубих помилок практично не спостерігається. Це свідчить про надійність моделі в умовах виявлення та вимірювання концентрації чадного газу у реальних середовищах.

На рис. 3 показано графіки навчання та перевірки моделі, які показують зміну її точності на навчальних і перевіірочних даних із зростанням кількості вимірювань.




Рис. 3. Графік точності навчання та перевірки моделі

Як видно з рис. 3, графік точності для навчальної вибірки є високим за менших обсягів даних, потім знижується, після чого відбувається корекція значень, що веде до певної стабілізації. Графік точності для перевіірочної вибірки поступово зростає наздоганяючи графік точності для навчальної вибірки на великих обсягах даних. Це показує, що модель добре узагальнює та не потребує значної кількості додаткових вимірювань для стабільного навчання.

На рис. 4 показано графік робочих характеристик моделі (ROC-кривих) та обчислені для кожного класу площі під графіком (AUC).




Рис. 4. Графік ROC-кривих моделі

Як видно з рис. 4, обчислені значення AUC дозволяють кількісно оцінити здатність моделі розрізняти зразки з та без відповідного рівня концентрації чадного газу. Усі побудовані криві знаходяться вище діагоналі випадкового класифікатора, що свідчить про хорошу якість моделі. Також наведено усереднене по класах значення AUC (macro-average AUC), яке складає 0,99, та усереднене значення AUC з врахуванням ваги кожного класу (micro-average AUC), яке складає 0,995. Вони показують загальну здатність моделі класифікувати дані з урахуванням балансу по класах. Високі значення цих метрик підтверджують ефективність запропонованої моделі виявлення чадного газу відповідно до класів його концентрації.

На рис. 5 показано гістограма важливостей ознак моделі.




Рис. 5. Гістограма важливостей ознак моделі

Як видно з рис. 5, було проаналізовано важливість ознак, які використовувались для навчання моделі. Кожна ознака – це числове значення отримане з розрахунків на основі зміни інтенсивностей випромінювання у чистому повітрі та чадному газі і аналізованій газовій суміші. Гістограма показала невелику різницю у важливості ознак, що свідчить про правильність їх вибору.

Таким чином, в процесі навчання та перевірки запропонованої моделі було отримано такі характеристики:

- середня точність виявлення чадного газу на перевіірочній вибірці склала близько 0,947;
- збалансованість класів забезпечена розподілом даних по 400 прикладах на кожен клас (всього 2000 прикладів);
- macro-average AUC склало близько 0,99;
- micro-average AUC склало близько 0,995;
- чутливість та F -оцінка склали близько 0,945;
- отримана матриця сплутаності показала, що більшість помилок виявлення чадного газу відбуваються на сусідніх класах за малих концентрацій, що ймовірно пов'язано з впливом завад на значення приймачів інфрачервоного випромінювання.

На основі отриманих характеристик було встановлено, що запропонована модель демонструє надійність і точність для задачі виявлення чадного газу на основі сенсорних даних. Окрім точності, модель продемонструвала хорошу стійкість до шумів та завад. Аналіз важливості ознак показав, що найбільш інформативними є ознаки, які пов'язані з відносним поглинанням випромінюванням між значеннями I_{sample} та I_{ref} .

Висновки

В роботі запропоновано модель з використанням випадкового лісу для системи виявлення чадного газу на основі бездротового оптико-електронного сенсора концентрації. Ця модель обробляє дані з бездротового оптико-електронного сенсора концентрації чадного газу. Для навчання цієї моделі запропоновано ознаки, що характеризують рівень поглинання та відносні зміни інтенсивності. Дослідження запропонованої моделі виявлення чадного газу на основі випадкового лісу було проведено шляхом моделювання, під час якого оцінювались точність навчання та перевірки моделі, чутливість, F -оцінка, ефективність, побудовано матрицю сплутаності за класами, а також дано оцінку важливості ознак. В процесі навчання та перевірки запропонованої моделі було отримано такі характеристики: середня точність виявлення чадного газу на перевіірочній вибірці склала близько 0,947; збалансованість класів забезпечена розподілом даних по 400 прикладах на кожен клас (всього 2000 прикладів); macro-average AUC склало близько 0,99; micro-average AUC склало близько 0,995; чутливість та F -оцінка склали близько 0,945; отримана матриця сплутаності показала, що більшість помилок виявлення чадного газу відбуваються на сусідніх класах за малих концентрацій, що ймовірно пов'язано з впливом завад на значення приймачів інфрачервоного випромінювання. На основі отриманих характеристик було встановлено, що запропонована модель демонструє надійність і точність для задачі виявлення чадного газу на основі сенсорних даних. Окрім точності, модель також продемонструвала хорошу стійкість до шумів.

СПИСОК ЛІТЕРАТУРИ

1. Небезпека отруєння чадним газом. URL: <https://www.bsmu.edu.ua/blog/1021-nebezpeka-otruennya-chadnim-gazom/> (дата звернення: 20.07.2025).
2. Qilong P., Fouzi H., Ying S. A comparison of machine learning methods for ozone pollution prediction. *Journal of Big Data*. 2023. Volume 10. P. 1–31. <https://doi.org/10.1186/s40537-023-00748-x>.
3. Quantitative and Qualitative Analysis of Multicomponent Gas Using Sensor Array / F. Shurui et al. *Sensors*. 2019. Volume 19. P. 1–12. <https://doi.org/10.3390/s19183917>.
4. Оптичний сенсор концентрації газу : пат. 68725 Україна : МПК G01N 21/01. № u201110898 ; заявл. 12.09.2011 ; опубл. 10.04.2012, Бюл. № 7.
5. Білінський Й. Й., Книш Б. П., Іоніна К. Ю. Інфрачервоний триканальний сенсор концентрації газу. *Вісник Хмельницького національного університету*. 2011. №6. С. 41–49.
6. ДСТУ EN 14626:2018 (EN 14626:2012, IDT). Атмосферне повітря. Стандартний метод вимірювання концентрації монооксиду вуглецю методом недисперсійної інфрачервоної спектроскопії. — [Чинний від 2019-01-01]. — Київ : УкрНДНЦ, 2018. — 91 с.

7. Prediction of atmospheric carbon monoxide concentration utilizing different machine learning algorithms: A case study in Kuala Lumpur, Malaysia / S. D. Latif et al. *Environmental Technology & Innovation*. 2023. Volume 32. P. 1–18. <https://doi.org/10.1016/j.eti.2023.103387>.
8. Alpan K., Sekeroglu B. Prediction of pollutant concentrations by meteorological data using machine learning algorithms. *5th International Conference on Smart City Applications*, [Turkey], 7–8 October 2020 / Virtual Safranbolu. - Turkey, 2020. P. 21–27. <https://doi.org/10.5194/isprs-archives-XLIV-4-W3-2020-21-2020>.
9. Research on the prediction model of coal spontaneous combustion temperature based on random forest algorithm / Z. Xuezhao et al. GONG-KUANG ZIDONGHUA. 2021. Volume 47, № 5. P. 58 – 54. <https://doi.org/10.13272/j.issn.1671-251x.17700>.
10. A machine learning calibration model using random forests to improve sensor performance for lower-cost air quality monitoring / N. Zimmerman et al. *Atmospheric Measurement Techniques*. 2018. Volume 11. P. 291 – 313. <https://doi.org/10.5194/amt-11-291-2018>.
11. Zameer ul Hassan H., Wang A., Mohi-ud-din G. A wireless sensor network for coal mine safety powered by modified localization algorithm. *Heliyon*. 2025. Volume 11. P. 1 – 19. <https://doi.org/10.1016/j.heliyon.2024.e41262>.
12. Carbon monoxide. URL: <https://www.healthcouncil.nl/binaries/healthcouncil/documenten/advisory-reports/2024/09/09/carbon-monoxide/Carbon-monoxide-advisory%2Breport.pdf> (дата звернення: 20.07.2025).
13. Juba B., Le H. S. Precision-recall versus accuracy and the role of large data sets. *Proceedings of the AAAI Conference on Artificial Intelligence*, [Washington] / AAAI. Washington D.C., 2019. Vol 33. P. 4039 – 4048. DOI: 10.1609/aaai.v33i01.33014039.

Стаття надійшла до редакції 23.09.2025.

Стаття пройшла рецензування 25.09.2025.

Книш Богдан Петрович – канд. техн. наук, доцент кафедри загальної фізики, e-mail: tutmos-3@i.ua.

Кулик Ярослав Анатолійович – канд. техн. наук, доцент кафедри автоматизації та інтелектуальних інформаційних технологій.

Вінницький національний технічний університет.