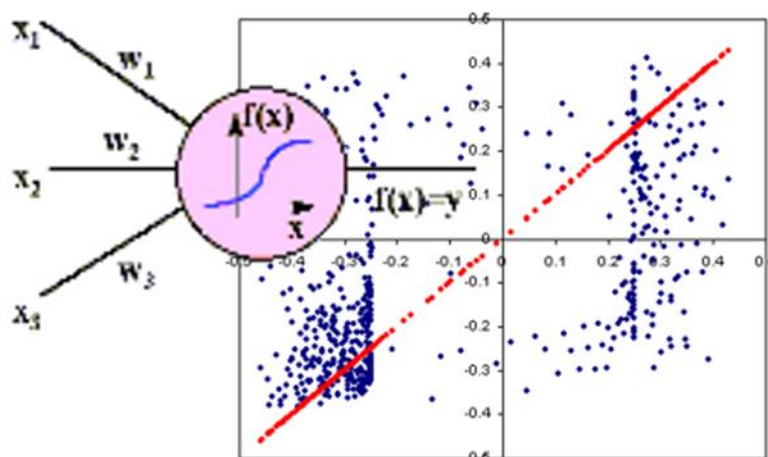


Ministry of Education and Science of Ukraine  
National Academy of Sciences of Ukraine  
National Academy of Sciences of Higher Education of Ukraine  
Institute of Artificial Intelligence Problems (Ukraine)  
Donbass State Engineering Academy (Ukraine)  
Vinnytsia National Technical University (Ukraine)  
Ternopil Ivan Puluj National Technical University (Ukraine)  
Engineering Academy of Serbia (IAS), Belgrade (Serbia)  
University of Szeged (Hungary)  
Apeiron University in Banja Luka (Bosnia and Herzegovina)  
DAAAM International Vienna  
Mechanical Engineering Faculty in Slavonski Brod, JJ Strossmayer University of Osijek  
(Croatia)  
University of Montenegro Faculty of Mechanical Engineering  
University of Zielona Góra (Poland)  
Vinnytsia National Agrarian University (Ukraine)  
Vinnytsia National Technical University (Ukraine)  
"American Journal Neural Network and Application" (USA)  
Problem Laboratory of Mobile Intelligent Technological Machines (Ukraine)




## COLLECTION OF SCIENTIFIC WORKS

XXIII International Scientific Conference

### «NEURAL NETWORK TECHNOLOGIES AND THEIR APPLICATIONS NNTA-2024»

Kramatorsk -Vinnytsia-Ternopil, Ukraine

Міністерство освіти і науки України  
Національна академія наук України  
Національна академія наук вищої освіти України  
Інститут проблем штучного інтелекту (Україна)  
Донбаська державна машинобудівна академія (Україна)  
Вінницький національний технічний університет (Україна)  
Тернопільський національний технічний університет імені Івана Пулюя (Україна)  
Engineering Academy of Serbia (IAS), Belgrade (Serbia)  
University of Szeged (Hungary)  
Apeiron University in Banja Luka (Bosnia and Herzegovina)  
DAAAM International Vienna  
Mechanical Engineering Faculty in Slavonski Brod, JJ Strossmayer University of Osijek  
(Croatia)  
University of Montenegro Faculty of Mechanical Engineering  
University of Zielona Góra (Poland)  
Вінницький національний аграрний університет (Україна)  
"American Journal Neural Network and Application" (США)  
Проблемна лабораторія мобільних інтелектуальних технологічних машин (Україна)



# **ЗБІРНИК НАУКОВИХ ПРАЦЬ**

## **XXIII Міжнародної наукової конференції**

### **«НЕЙРОМЕРЕЖНІ ТЕХНОЛОГІЇ ТА ЇХ ЗАСТОСУВАННЯ НМТЗ-2024»**

Краматорськ-Вінниця-Тернопіль, Україна

Слюсар В.І. (Центральний науково-дослідний інститут озброєння та військової техніки ЗС України)

## НЕЙРОМЕРЕЖНИЙ АНАЛІЗ СТРУКТУРИ ХМАР НА БОРТУ АВІАЦІЙНИХ ПЛАТФОРМ ДЛЯ ПРОГНОЗУВАННЯ МЕТЕОДАНИХ У ПРИЗЕМНОМУ СЕРЕДОВИЩІ

**Анотація:** Доповідь присвячена розробці системи нейромережного аналізу структури хмар для визначення метеорологічних даних під хмарами на основі зображень, отриманих із борта авіаційних платформ. Актуальність теми полягає у потребі підвищення точності прогнозів погоди у регіонах із обмеженою наземною інфраструктурою. Запропонований підхід передбачає інтеграцію методів комп'ютерного зору та нейронних мереж для вилучення характеристик хмар і визначення метеорологічних параметрів (атмосферний тиск, швидкість і напрямок вітру, тип та інтенсивність опадів). Архітектура системи складається з модуля вилучення ознак із використанням згорткових нейронних мереж (CNN) і регресійного блоку для прогнозування параметрів. Навчання моделі базується на датасеті, що включає зображення хмар різних типів, отримані з бортових камер авіаційних платформ, і відповідні метеодані, зібрані з наземних станцій. Наголошується на важливості забезпечення репрезентативності даних, врахуванні сезонних змін і географічних особливостей. Практичне значення роботи полягає в можливості використання системи для оперативного аналізу погодних умов у режимі реального часу. Це включає прогнозування погоди для авіації, оцінку кліматичних умов для енергетики та сільського господарства. Також розглядаються перспективи застосування великих мовних моделей та мультиагентних систем і узагальнення підходу для інших сфер, таких як моніторинг інфраструктури чи природних катастроф.

**Ключові слова:** нейромережний аналіз, структура хмар, метеорологічні дані, комп'ютерний зір, згорткові нейронні мережі, прогнозування погоди, авіаційні платформи,

**Abstract:** The paper is dedicated to the development of a neural network-based system for analyzing cloud structures to determine meteorological data beneath the clouds based on images captured from aviation platforms. The relevance of the topic lies in the need to improve weather forecast accuracy in regions with limited ground infrastructure. The proposed approach involves integrating computer vision methods and neural networks to extract cloud characteristics and determine meteorological parameters (atmospheric pressure, wind speed and direction, type, and intensity of precipitation). The system architecture consists of a feature extraction module utilizing convolutional neural networks (CNNs) and a regression block for parameter prediction. The model training is based on a dataset that includes images of various cloud types captured by onboard cameras of aviation platforms and corresponding meteorological data collected from ground stations. Emphasis is placed on ensuring the representativeness of the data, accounting for seasonal changes, and considering geographical features. The practical significance of the work lies in the possibility of using the system for real-time weather condition analysis. This includes weather forecasting for aviation, assessing climatic conditions for energy and agriculture. The prospects for applying large language models and multi-agent systems are also considered, as well as generalizing the approach to other areas such as infrastructure monitoring or natural disaster management.

**Keywords:** neural network analysis, cloud structure, meteorological data, computer vision, convolutional neural networks, weather forecasting, aviation platforms.

Сучасні задачі метеорології та кліматології вимагають високої точності прогнозів у реальному часі, особливо в умовах регіонів із обмеженою наземною інфраструктурою для збору даних. Традиційні методи аналізу погодних умов, які базуються на даних із наземних станцій, супутників або радарів, часто не забезпечують достатньої деталізації та оперативності. Водночас, розвиток авіаційних платформ, таких як безпілотні літальні апарати (БПЛА) та літаки, а також повітряних зондів, відкриває нові можливості для збору високоточних даних про хмарність безпосередньо з висоти польоту. Хмари є важливим елементом атмосфери, що прямо впливає на такі метеорологічні параметри, як опади, атмосферний тиск, швидкість і напрямок вітру. Їх структура, форма та динаміка можуть виступати індикаторами погодних змін. Однак аналіз хмар у реальному часі для оцінки приземних метеоданих залишається складним завданням через варіативність хмарності, сезонні зміни та вплив локальних факторів.

Мета роботи полягає у створенні концепції системи, яка здатна на основі зображень хмар, отриманих із борта авіаційних платформ, визначати ключові метеорологічні параметри

в приземному середовищі. Такий підхід вимагає інтеграції методів комп'ютерного зору, глибокого навчання та прогнозування часових рядів.

Дослідження хмарності та її впливу на атмосферні процеси є однією з ключових задач кліматології та метеорології. Вивчення структури хмар дозволяє не лише покращити прогнози погоди, а й сприяє розумінню глобальних кліматичних змін. Використання нейромереж для аналізу структури хмар з метою визначення параметрів приземних шарів атмосфери є новим підходом, що об'єднує дослідження атмосфери та штучного інтелекту, сприяючи розвитку міждисциплінарних напрямів. Практичне значення пропонованого підходу включає оперативний аналіз погодних умов для планування польотів авіації, оцінку регіонального клімату та прогнозування опадів для екології та сільського господарства, планування роботи відновлюваних джерел енергії в енергетиці, а також прогнозування екстремальних погодних явищ для запобігання катастрофам та організації евакуації населення. Розробка системи нейромережного аналізу хмарних покривів із використанням авіаційних платформ дозволить значно розширити доступ до оперативних і точних метеорологічних даних, забезпечуючи якісно новий рівень у вирішенні задач прогнозування та моніторингу погоди.

Аналіз останніх публікацій свідчить про зростаючий інтерес до використання штучних нейронних мереж для аналізу хмарності та прогнозування метеорологічних параметрів. Зокрема, дослідження [1] демонструє ефективність рекурентних нейронних мереж (RNN) та їх комбінацій у прогнозуванні температури навколишнього середовища, досягаючи похибки 14.22%. Це підкреслює потенціал нейронних мереж при вирішенні метеорологічних задач. Інші роботи [2 - 10] присвячені розробці нейромережних моделей для автоматичної класифікації хмарних структур на зображеннях переважно з наземних камер спостереження. Це важливо для розуміння атмосферних процесів та покращення прогнозів погоди. Для цього також використовуються зображення хмар з супутників [11, 12]. У статті [13] розглядається застосування ШІ для аналізу великих обсягів метеорологічних даних, що дозволяє швидко виявляти закономірності та підвищувати точність прогнозів. Ці та інші роботи закладають основу для подальших досліджень у сфері використання нейронних мереж для аналізу та прогнозування метеорологічних параметрів, підкреслюючи важливість інтеграції методів глибокого навчання у метеорологічну практику.

Ідея визначення погодних умов на землі, під хмарами, за допомогою аналізу зображень хмарного покриву, зроблених із літака, виглядає досить перспективною, особливо з урахуванням сучасних можливостей комп'ютерного зору та нейронних мереж [14 - 16]. Зовнішній вигляд суцільного хмарного шару, приклади якого наведено на рис. 1, 2, може надати корисну інформацію про погодні умови, оскільки форма, структура, висота та тип хмар пов'язані з процесами в атмосфері, включаючи опади, тиск і вітер. Це може бути особливо корисним у районах, де немає метеостанцій (рис. 1).



Рисунок 1. Приклад щільного хмарного покриву над Атлантичним океаном (фото автора).

Для реалізації такої ідеї необхідно врахувати кілька важливих етапів. По-перше, потрібно зібрати велику та якісну базу репрезентативних даних. Це мають бути зображення хмар, зроблені з різної висоти, під різними ракурсами і в різноманітних погодних умовах, а також відповідні метеорологічні дані із землі. Вказані дані мають охоплювати усі можливі типи хмарності, пори року, географічні зони та екстремальні погодні явища. Додатково, можна

інтегрувати зазначені дані з іншими джерелами, такими як супутникові зображення, показники атмосферного тиску на різних висотах, метеорадарні та лідарні дані тощо. Це дозволить моделі враховувати не лише вигляд хмар, але й інші важливі фактори, які впливають на погоду. Також доцільно запровадити механізми зворотного зв'язку, коли дані прогнозу, отримані моделлю, зіставляються з реальними спостереженнями, щоб покращити точність прогнозів і адаптивність системи. Наприклад, перспективним напрямом може бути використання подібної системи в реальному часі для авіації. Літак чи БПЛА має оснащуватися сенсорами та камерами, які в реальному часі передаватимуть дані в обчислювальний центр, наприклад, за допомогою стільникового зв'язку, де він є [17], або системи Starlink. Також можливий прийом на борту у вказані способи наземних метеоданих для проведення оперативного аналізу із прогнозуванням погодних умов під літаком. Це дозволить підвищити безпеку польотів, прогнозувати локалізацію зон турбулентності.




Рисунок 2. Пухкі хмари (фото автора).

По-друге, важливо створити модель нейронної мережі, яка могла б ефективно аналізувати зібрані дані. Для цього доцільно використовувати згорткові нейронні мережі (CNN) для обробки зображень, а також рекурентні мережі (RNN) або трансформери для обробки часових і послідовних даних.

Звісно, прогнозування параметрів погоди на землі під хмарами може мати певну похибку через складність атмосферних процесів. Тому на першому етапі доцільно обмежитися аналізом лише суцільних хмарних покривів, що має спростити встановлення закономірностей еволюції метеоданих. Для цього безпосередньому прогнозуванню атмосферних параметрів через аналіз динаміки візуальних процесів має передувати класифікація стану хмарних шарів. Вирішення даної задачі може бути здійснене аналогічно запропонованому в [18] підходу до класифікації сезонних умов із використанням згорткових нейронних мереж, який можна удосконалити та адаптувати для задач визначення суцільної хмарності. При цьому основою процесу ідентифікації суцільних хмарних станів є формування датасету, що включає зображення різних типів хмарності: суцільної, часткової або її відсутності. Як вже зазначалося, ці зображення отримуються з борта літаків або безпілотних апаратів на різних висотах. Важливо забезпечити різноманітність даних - знімки з різними рівнями освітлення, у різні пори року та з багатьох регіонів, що дозволить зробити модель більш універсальною.

Для класифікації типів хмарності можна використати апробовану в [18] архітектуру на основі MobileNetV2 [19] (рис. 3), попередньо навченої на датасеті ImageNet [20], яка зарекомендувала свою ефективність. Суттєво, що завдання класифікації може бути поєднане з сегментацією хмарного зображення на основі мережі U-Net. Перед аналізом усі зображення проходять попередню обробку, що охоплює зміну розмірів, нормалізацію кольорів і забезпечує уніфікацію даних. Після цього нейронна мережа починає аналізувати хмарне середовище. Вона визначає, чи присутня на зображенні суцільна хмарність, і, якщо так,

виділяє її межі. Крім того, в процесі сегментації можливо уточнити тип хмар - наприклад, перисті, купчасті чи шаруваті. Для досягнення найкращих результатів виконується оптимізація гіперпараметрів, таких як розмір батчу, крок навчання та кількість епох. Наприклад, зменшення розміру батчу показало себе в [18] як ефективний спосіб знизити вимоги до обчислювальних ресурсів, що може бути особливо важливим для умов із обмеженим обладнанням. Після цього модель проходить етап валідації. Як і у випадку класифікації сезонних умов [18], використовуються тренувальні, валідаційні та тестові вибірки. Точність моделі оцінюється за допомогою метрик, таких як Balanced Recall, що дозволяє визначити її ефективність. Завершальним етапом є реалізація системи у реальному часі. Навчена модель інтегрується у бортове програмне забезпечення авіаційних платформ, що дозволяє отримувати результати класифікації та використовувати їх для подальшого передбачення погодних умов.



Рисунок 3. Застосування попередньої класифікації хмарного покриву на вході нейромережі прогнозування приземних метеоданих.

Для безпосереднього визначення метеорологічних даних під суцільними хмарами може бути запропонована архітектура нейронної мережі, що базується на інтеграції сучасних технологій комп'ютерного зору та регресійних моделей. Вона складається з двох ключових компонентів: модуля для вилучення ознак із зображень хмар і модуля для перетворення цих ознак у метеорологічні параметри.

Перший компонент - модуль вилучення ознак, - використовує згорткову нейронну мережу, наприклад, MobileNetV3 або EfficientNetB0, яка оптимізована для роботи в умовах обмежених ресурсів. На вхід системи подаються зображення розміром  $224 \times 224 \times 3$ , які проходять через серію шарів згортки, об'єднання та нормалізації. На виході формується високорівневий набір ознак, що відображає основні характеристики хмарного середовища. Для стиснення цього багатовимірного представлення у компактний вектор використовується додатковий шар об'єднання, а для запобігання перенавчанню застосовується механізм Dropout.

Другий компонент, регресійний блок, складається з одного або кількох повнзв'язних шарів із функцією активації ReLU. Вихід моделі представлений кількома нейронами, кожен з яких відповідає за прогноз окремого параметра: атмосферного тиску, швидкості вітру, напрямку вітру або типу опадів. Для кількісних параметрів використовується функція активації Linear, тоді як для класифікаційних - Softmax.

Вхідні дані для моделі формуються із зображень хмар, які можуть бути попередньо оброблені для покращення контрасту, а також додаткових метаданих, наприклад, геолокації чи висоти польоту. Особливу увагу, знову ж таки, слід приділити сезонним варіаціям. Наприклад, зимові хмари часто здаються яскравішими через відбите від снігу світло, що може вплинути на прогноз. З урахуванням цих змін модель адаптується до різних умов. Вихідні дані представляють собою прогнозовані метеорологічні параметри як у вигляді регресійних значень (тиск, швидкість вітру), так і класифікаційних (тип опадів). Для підвищення стійкості

моделі до різноманітних умов застосовуються техніки аугментації, такі як обертання, зміна яскравості та перевернення зображень.

Навчання моделі базується на використанні функцій втрат Mean Squared Error для регресійних прогнозів і Categorical Cross-Entropy для класифікації. Гіперпараметри моделі включають розмір батчу, початковий крок навчання та оптимізатор. Реалізація архітектури може бути виконана за допомогою популярних фреймворків, таких як TensorFlow/Keras або PyTorch.

Для подальшого розвитку системи передбачено інтеграцію механізмів самонавчання, що дозволить адаптувати модель до нових типів хмарності чи метеорологічних умов. Додатково можливо впровадити модуль Explainable AI, який забезпечить прозорість прогнозів і покращить їх інтерпретованість. Ця архітектура є гнучкою, масштабованою та відкриває нові можливості для точного визначення метеорологічних даних за зображеннями хмар.

У запропонованій архітектурі метеодані при навчанні подаються на вихід, тобто вони виступають цільовими значеннями (targets) для оптимізації моделі, подібно до того, як це робиться в задачах регресії або класифікації. Вони не є вхідними даними, як це могло б бути в задачах, де модель використовує допоміжну інформацію для аналізу. На вхід подаються тільки зображення хмар. Це основні дані, з яких модель буде вчитися вилучати ознаки. На виході модель прогнозує набір метеорологічних параметрів, а саме: регресійні значення, наприклад, тиск, швидкість вітру; класифікаційні категорії (тип опадів, тип хмар, напрям вітру). Ці параметри порівнюються з еталонними значеннями (ground truth) за допомогою відповідних функцій втрат (loss functions).

Суттєво, що для кожного зображення хмар в навчальному наборі даних має бути відповідний набір цільових метеорологічних параметрів, зібраних із наземних метеостанцій або інших джерел (наприклад, супутників). Під час навчання мережа намагається мінімізувати різницю між прогнозованими і реальними значеннями метеорологічних параметрів. Такий підхід дозволяє навчити модель генерувати коректні прогнози метеоданих виключно на основі аналізу зображень хмар, без додаткових входів або потреби в сегментаційній масці.

В розглянутій задачі метеодані є компактними значеннями (набором чисел або класів) і не мають просторової прив'язки, як у сегментаційних задачах. Тому структура моделі скоріше нагадує архітектуру для багатозначного прогнозування (multi-output regression/classification), а не U-Net з сегментації зображень.

Разом з тим, в даному випадку відповідну нейромодель можна розглядати як різновид моделі Image-to-Text, але з адаптацією під специфіку задачі прогнозування числових та категоріальних метеорологічних даних. Як відомо, у задачах Image-to-Text модель аналізує зображення та генерує текстовий опис. У випадку, що розглядається, модель аналізує зображення хмар і генерує структуровані числові (регресійні) та текстові (класифікаційні) дані, що відповідають метеорологічним параметрам. Вихід моделі є узагальненим "текстом", тобто описом погодних умов у вигляді структурованого набору даних.

Як і в класичній Image-to-Text архітектурі, в описаній метеозадачі можливо використовувати сукупність енкодера та декодера. Енкодер (наприклад, MobileNetV3, EfficientNet) перетворює зображення у компактне представлення (feature vector), а декодер працює над цим представленням для генерації вихідних значень. У даному випадку це можуть бути окремі лінійні або класифікаційні шари для кожного параметра.

Вихідні метеодані можуть бути представлені в текстовій формі, наприклад, у форматі yaml, як показана на рис. 2. Генерація таких структурованих даних - це один з можливих результатів роботи моделі Image-to-Text, але тут виходи є чітко визначеними. Для більш універсального підходу можна задіяти Image-to-Text моделі типу CLIP або BLIP, які працюють на стику зображень і тексту. Вони можуть бути перенавчені на задачі "зображення хмар → опис метеоданих". Наприклад, модель генеруватиме текстовий опис: "Суцільні хмари, опади відсутні, швидкість вітру 10-15 км/год, напрямок північно-західний." Переваги такого Image-to-Text підходу полягають у тому, що модель стає більш універсальною і може бути легко адаптована для різних завдань.

Генерований вихід може використовуватися не лише як числові дані, а й як інтерпретований текстовий опис для оператора або системи. Для реалізації зазначених моделей використовуються сучасні фреймворки, такі як PyTorch, з адаптованими компонентами encoder-decoder. Можливе підключення великих мовних моделей (LLM) [21] до кінцевого етапу для генерації описів на природній мові. Цей підхід робить ідею ще більш масштабованою, дозволяючи інтеграцію в багатомодальні системи, де зображення і текст працюють як доповнюючі джерела інформації.

Зокрема раціональним вибором для описаної задачі є використання мультимодальних LLM [21], таких як LLaVa (Large Language and Vision Assistant) або Pixtral та ін. Ці моделі створені для багатомодальних задач і дозволяють безпосередньо працювати із зображеннями, генеруючи текстові або структуровані виходи на основі зорової інформації. Моделі LLaVa і Pixtral інтегрують аналіз зображень та генерацію тексту. Це дозволяє працювати з даними хмар як із вхідною інформацією і отримувати готовий текстовий або числовий опис метеоданих. При цьому немає потреби розробляти спеціальну регресійну модель, оскільки вказані моделі адаптовані до складних вхідних даних та генерації структурованих виходів. Pixtral також може інтегрувати генерацію категорійних (опади, тип хмар) і числових даних у текстовому форматі. З метою адаптації для конкретної задачі LLaVa має бути перенавчена (fine-tuned) на специфічних даних - зображеннях хмар із прив'язкою до метеоданих. Це дозволить адаптувати модель до унікальної задачі, для чого необхідно створити спеціалізований датасет з парами "зображення хмар → метеодані". Такий датасет, як вже зазначалося, має включати зображення хмарних шарів (супутникові, з БПЛА, з літака), а також відповідні дані про атмосферний тиск, вітер, опади, отримані з наземних метеостанцій чи супутникових сенсорів. Зображення подається на вхід моделі (LLaVa або Pixtral), а модель далі генерує текст із описом метеоданих. Вихідний результат може бути наданий як у вигляді готових текстових описів (наприклад, "швидкість вітру 10 м/с, опади відсутні"), так і у форматі JSON для подальшої обробки. LLaVa підтримує пояснення своїх прогнозів і може, наприклад, їх коментувати: "Зображення показує суцільні шаруваті хмари, які зазвичай пов'язані з атмосферним тиском 1005-1010 hPa і вітром у діапазоні 5-10 км/год." Тонке налаштування (fine-tuning) LLaVa дозволить перенавчити її на своєму наборі даних, щоб покращити точність прогнозів. Для Pixtral, враховуючи її значні розміри, замість fine-tuning можна використовувати техніку додавання спеціалізованих шарів для регресійних задач. В свою чергу, Pixtral може використовувати своє розширене розуміння зорової інформації для більш точного аналізу. Після донавчання слід перевірити ефективність LLM-моделі на нових зображеннях, оцінивши її точність, використовуючи метрики MSE для регресійних прогнозів і точність (accuracy) для класифікаційних. Після завершення процесу донавчання модель може бути розгорнута на сервері чи хмарній платформі для аналізу зображень у реальному часі.

Вказані LLM дозволяють автоматично генерувати текстові результати різними мовами, наприклад, українською чи англійською, що зручно для інтеграції в глобальні системи. З урахуванням зазначеного, LLaVa та Pixtral є важливими кандидатами для вирішення задачі "image-to-meteorology". Вони дозволяють використовувати готові потужні архітектури багатомодальних моделей, зводячи зусилля зі створення спеціалізованої системи до адаптації існуючих інструментів.

Подальше підвищення продуктивності, адаптивності і масштабованості пропонованого підходу забезпечується використанням мультиагентних систем (МАС) [21]. Як відомо, мультиагентний принцип дозволяє розподілити задачі між різними нейроагентами, кожен з яких спеціалізується на певному аспекті аналізу. Для вирішуваного завдання генерації метеоданих **мультиагентна система буде складатися з кількох взаємодіючих агентів, яких можна поділити на кілька категорій, наприклад:**

**агенти-збірники даних, що** отримують зображення хмар із різних джерел (супутників, БПЛА, літаків) та здійснюють їх попередню фільтрацію і обробку;

**агенти-аналітики, які** аналізують зображення та вилучають специфічні характеристики;



**агенти-прогнозисти** обчислюють метеодані на основі висновків агентів-аналітиків; **агенти-контекстуалізатори** уточнюють результати на основі поточної геолокації; **агенти-пояснювачі** формулюють результати у вигляді тексту або структурованого виходу.

Загальний принцип функціонування зазначеної МАС проілюстровано на рис. 4.




Рисунок 4. Принцип функціонування мультиагентної системи генерації метеоданих за зображеннями хмарних покривів.

Розглянемо більш детально типові ролі агентів. Цілком очевидно, що агент з попередньої обробки зображень повинен займатися нормалізацією яскравості та контрасту зображення, виділенням хмарного середовища (сегментація з використанням, наприклад, U-Net), оцінкою ступеня суцільності хмар. Агент-аналітик з класифікації хмар далі використовує попередньо навчену нейромережну модель, щоб визначити тип хмар (перисті, шаруваті, купчасті тощо) і передає результати агенту-прогнозисту для подальших обчислень.

Агент-прогнозист розраховує параметри атмосферного середовища, такі як тиск, швидкість вітру і його напрямок, тип опадів. Для генерації текстових описів він може використовувати регресійні та трансформерні моделі або LLM, такі як LLaVa чи Pixtral. Агент з контекстного аналізу використовує геолокацію та історичні дані для уточнення прогнозу. Наприклад, якщо типові за структурою та кольором хмари в певному регіоні влітку зазвичай пов'язані з дощем, а не з градом, цей агент уточнить результати агента-прогнозиста. Для пояснення результатів прогнозу генеруються текстові або графічні коментарі у зручному для користувача форматі, наприклад: "Суцільні шаруваті хмари на висоті 2 км. Атмосферний тиск під хмарами - 1012 hPa. Опади: дощ."

Процес взаємодії агентів забезпечується шляхом їх комунікації один з одним. При цьому агенти обмінюються даними через шину повідомлень або загальний сервер, використовуючи формат даних типу JSON. Для координації функціонування може бути виділений централізований агент-координатор або розподілена система прийняття рішень, яка забезпечує узгодженість дій. Для кожного агента використовуються окремі спеціалізовані моделі (наприклад, MobileNet для класифікації, LLaVa для генерації текстів). Розгортання агентів може бути здійснено окремо у хмарному сервісі, на сервері або на борту БПЛА залежно від їх функцій.

Перевагами застосування мультиагентних систем є масштабованість та гнучкість, до них можна легко додавати інших агентів для нових задач (наприклад, прогнозування гроз чи снігопадів). За допомогою МАС завдання виконуються ефективніше, оскільки кожен агент відповідає лише за свою частину роботи й може використовувати різні моделі або алгоритми, такі як нейронні мережі, мовні моделі та методи машинного навчання для контекстного аналізу.

Описана концепція спостереження за хмарністю дозволить досліджувати глобальні кліматичні зміни, вивчати процеси утворення хмар, вплив вітрових течій на розподіл вологи

та динаміку опадів. У підсумку, зазначена ідея може стати не лише інструментом для прогнозування погоди, але й важливою частиною системи моніторингу кліматичних змін. Це відкриває широкий спектр можливостей як для практичного, так і для наукового застосування, особливо в умовах зростання уваги до кліматичних і метеорологічних питань у світі.

На завершення слід вказати на можливі напрями узагальнення пропонованого підходу прогнозування часових рядів через аналіз динаміки візуальних процесів, особливо для вирішення задач, пов'язаних із безпекою та управлінням ризиками. Сутність ідеї полягає у використанні візуального аналізу для послідовності зображень чи відеопотоку з метою моделювання часових рядів, що відображають розвиток процесів у часі. Наприклад, це може бути розповсюдження вогню навколо цистерни для прогнозування критичних подій, як-от момент вибуху. При такому сценарії на вхід системи надходить відеопотік або серія зображень, а вихідними даними є точка у часі до очікуваної критичної події, наприклад вибуху чи моменту початку евакуації персоналу, коли протидія пожежі вже втрачає ефективність.

Розробка відповідної системи штучного інтелекту включає кілька ключових етапів. Починається все зі збору й анотації даних, що охоплюють реальні записи пожеж або інших аварійних ситуацій. Для навчання можуть також використовуватися синтетичні дані, створені на основі фізичних моделей. Далі йде попередній аналіз відео, під час якого сегментація дозволяє виділяти критичні області. Це можна виконувати за допомогою моделей на основі U-Net, які ефективно розділяють зображення на необхідні зони. Наступний крок - аналіз динаміки, який передбачає оцінку характеристик, таких як площа поширення вогню, яскравість чи інтенсивність. Для цього можна використовувати нейромережні моделі ResNet, Vision Transformers та інші. Після вилучення ознак візуальної сцени вони подаються у модель часових рядів, яка прогнозує подальший розвиток події. Тут підходять такі моделі, як LSTM, GRU чи трансформери, які добре працюють із часовими залежностями. На основі навчання вказаних моделей можна побудувати систему, здатну прогнозувати час до настання критичної події. Описаний процес також включає регресійні розрахунки для точного визначення залишкового часу та класифікацію станів, наприклад, нормального, небезпечного чи критичного.

Для реалізації подібної системи в реальному часі необхідно мати обладнання, що здатне обробляти відеопотік без значних затримок. Це можна досягти за допомогою спеціалізованих обчислювальних платформ, таких як NVIDIA TensorRT або OpenVINO. Постійний моніторинг дозволяє перераховувати залишковий час до критичної події і передавати попередження персоналу, що значно підвищує безпеку. Можливості застосування даного підходу надзвичайно широкі. У промисловості система може бути використана для моніторингу пожеж на об'єктах із небезпечними речовинами. Вона також може прогнозувати руйнування інфраструктурних об'єктів, таких як мости чи дамби, шляхом аналізу динаміки тріщин чи вібрацій, а у рятувальних службах – спрогнозувати час для евакуації під час природних катастроф. У медичній сфері подібний аналіз може застосовуватися для прогнозування кризових станів пацієнтів за динамікою зміни на моніторах фізіологічних параметрів, таких як серцебиття чи дихання.

Звісно, розробка подібних систем стикається з викликами, такими як дефіцит якісних даних, необхідність високої точності прогнозів та забезпечення роботи в реальному часі. Разом з тим, вирішення цих проблем відкриє нові перспективи для впровадження штучного інтелекту у прогнозування кризових ситуацій, що базуються на динаміці візуальних даних.

#### Список посилань.

1. *Гетьман, Ю. А. Солод, М. А. Держевецька. Дослідження застосування штучних нейронних мереж для підвищення точності прогнозування температури навколишнього середовища. Вісник Херсонського національного технічного університету, № 2 (89), 2024. [Онлайн]. Доступно: [https://journals.kntu.kherson.ua/index.php/visnyk\\_kntu/article/view/638](https://journals.kntu.kherson.ua/index.php/visnyk_kntu/article/view/638).*
2. *Малярчук, Р. В. Класифікація хмар на зображеннях за допомогою глибоких нейронних мереж : дипломна робота ... бакалавра : 124 Системний аналіз / Малярчук Роман Васильович. - Київ, Національний*

технічний університет України "Київський політехнічний інститут імені Ігоря Сікорського", 2020. 106 с.

3. Ye, L.; Cao, Z.; Xiao, Y.; Li, W. Ground-based cloud image categorization using deep convolutional visual features. In *Proceedings of the 2015 IEEE International Conference on Image Processing (ICIP), Quebec City, QC, Canada, 27–30 September 2015*; pp. 4808–4812.
4. Shi, C.; Wang, C.; Wang, Y.; Xiao, B. Deep convolutional activations-based features for ground-based cloud classification. *IEEE Geosci. Remote Sens. Lett.* 2017, 14, 816–820.
5. Zhang, J.; Liu, P.; Zhang, F.; Song, Q. CloudNet: Ground-based cloud classification with deep convolutional neural network. *Geophys. Res. Lett.* 2018, 45, 8665–8672.
6. Wang, M.; Zhou, S.; Yang, Z.; Liu, Z. CloudA: A Ground-Based Cloud Classification Method with a Convolutional Neural Network. *J. Atmos. Ocean. Technol.* 2020, 37, pp. 1661–1668.
7. Liu, S.; Duan, L.; Zhang, Z.; Cao, X.; Durrani, T.S. Multimodal ground-based remote sensing cloud classification via learning heterogeneous deep features. *IEEE Trans. Geosci. Remote Sens.* 2020, 58, pp. 7790–7800.
8. Liu, S.; Li, M.; Zhang, Z.; Xiao, B.; Cao, X. Multimodal ground-based cloud classification using joint fusion convolutional neural network. *Remote Sens.* 2018, 10, 822.
9. Liu, S.; Li, M.; Zhang, Z.; Xiao, B.; Durrani, T.S. Multi-evidence and multi-modal fusion network for ground-based cloud recognition. *Remote Sens.* 2020, 12, 464.
10. Lv, Q.; Li, Q.; Chen, K.; Lu, Y.; Wang, L. Classification of Ground-Based Cloud Images by Contrastive Self-Supervised Learning. *Remote Sens.* 2022, 14, 5821. DOI: 10.3390/rs14225821.
11. Yousaf, R.; Rehman, H.Z.U.; Khan, K.; Khan, Z.H.; Fazil, A.; Mahmood, Z.; Qaisar, S.M.; Siddiqui, A.J. Satellite Imagery-Based Cloud Classification Using Deep Learning. *Remote Sens.* 2023, 15, 5597. DOI: 10.3390/rs15235597.
12. Nilay S. Kapadia, Urmil Parikh, Dipti P. Rana. Weather Forecasting using Satellite Image Processing and Artificial Neural Networks. *International Journal of Computer Science and Information Security (IJCSIS), Vol. 14, No. 11, November 2016*, pp. 1069 – 1074.
13. Ігор Кібальчич. Штучний інтелект та нейронні мережі у метеорологічній практиці. 2023. [Онлайн]. Доступно: <https://www.meteoprog.com/ua/news/623350-stucnii-intelekt-ta-neironni-merezi-u-meteorologichniy-praktici.html>.
14. Vadym Slyusar, Mykhailo Protsenko, Anton Chernukha, Pavlo Kovalov, Pavlo Borodych, Serhii Shevchenko, Oleksandr Chernikov, Serhii Vazhynskyi, Oleg Bogatov, Kirill Khrustalev. Improvement of the object recognition model on aerophotos using deep conventional neural network. // *Eastern-European Journal of Enterprise Technologies.* - 2021, Vol. 5, No. 2 (113). Pp. 6 – 21. DOI: 10.15587/1729-4061.2021.243094.
15. Vadym Slyusar, Mykhailo Protsenko, Anton Chernukha, Vasyl Melkin, Oleh Biloborodov, Mykola Samoilenko, Olena Kravchenko, Galina Kalinichenko, Anton Rohovyi, Mykhaylo Soloshchuk. Improvement of the model for detecting objects on aerial photos and video in unmanned aerial systems. // *Eastern-European Journal of Enterprise Technologies.* - Vol. 1, No. 9(115). – 2022.- Pp.24 - 34. DOI: 10.15587/1729-4061.2022.252876.
16. Vadym Slyusar, Mykhailo Protsenko, Anton Chernukha, Stella Gornostal, Sergey Rudakov, Serhii Shevchenko, Oleksandr Chernikov, Nadiia Kolpachenko, Volodymyr Timofeyev, Roman Artiukh. Construction of an advanced method for recognizing monitored objects by a convolutional neural network using a discrete wavelet transform. // *Eastern-European Journal of Enterprise Technologies, Vol. 4 No. 9(112) (2021): Information and controlling system*, Pp. 65 - 77. DOI: 10.15587/1729-4061.2021.238601.
17. Andrii Zinchenko, Vadym Slyusar, Natalia Korolyuk, Elena Korshets. The Method of Open Space Selection of Signals for Radcom Systems. // *3rd International Conference on Advanced Information and Communications Technologies (AICT'2019).* – 2 - 6 July 2019. - Lviv Polytechnic National University, Lviv, Ukraine. - Pp. 404-408. - DOI: 10.1109/AIACT.2019.8847826.
18. Слюсар В.І., Слюсарь І.І. Класифікація зимового та літнього сезонів з борта БПЛА. // *Нейромережні технології та їх застосування НМТіЗ-2023: збірник наукових праць XXII-ї Міжнародної наукової конференції «Нейромережні технології та їх застосування НМТіЗ-2023», 13-14 грудня 2023 року, Краматорськ-Тернопіль, Україна.* - С. 134 -142.
19. Tsang S. Review: MobileNetV2 – Light Weight Model (Image Classification). URL: <https://towardsdatascience.com/review-mobilenetv2-light-weight-model-image-classification-8febb490e61c>. (дата звернення: 27.10.2023).
20. ImageNet. URL: <https://www.image-net.org>. (дата звернення: 27.10.2023).
21. Слюсар В.І. Локальні великі мовні моделі для обробки конфіденційної інформації. // *Озброєння та військова техніка, № 4(44), 2024.* – С. 79 – 91. DOI: 1034169/2414-0651.2024.4(44).79-91.

*Наукове видання*

За загальною редакцією  
д-ра техн. наук, професора

**КОВАЛЕВСЬКОГО Сергія Вадимовича**

**НЕЙРОМЕРЕЖНІ ТЕХНОЛОГІЇ  
ТА ЇХ ЗАСТОСУВАННЯ  
НМТіЗ-2024**

**Збірник наукових праць**

За авторським редагуванням

32/2016    Формат 60 x 84/16.    Ум. друк. арк. 20,2  
Обл.-вид. арк. 20,6. Тираж 100 прим. Зам. № 25

Видавець і виготівник  
Донбаська державна машинобудівна академія  
84313, м. Краматорськ, вул. Академічна, 72.  
Свідоцтво суб'єкта видавничої справи  
ДК № 1633 від 24.12.2003