

УДК 621.396.946:004.722.45

DOI: 10.31673/2412-9070.2023.010309

В. П. ЯКОВЕЦЬ, аспірант;

А. О. МАКАРЕНКО, доктор техн. наук;

Н. В. РУДЕНКО, канд. техн. наук;

В. В. СКРИПНИК, доктор філософії,

Державний університет телекомунікацій, Київ

ЗАСТОСУВАННЯ МАШИННОГО НАВЧАННЯ ПІД ЧАС ІНТЕГРАЦІЇ СУПУТНИКОВОГО ТА БПЛА-ЗВ'ЯЗКУ

Інтеграція супутникового та БПЛА-зв'язку — це перспективний напрям розвитку телекомунікацій. Завдяки низькій вартості та високій мобільності БПЛА можуть брати на себе велику кількість важливих завдань, включно з передаванням даних як між абонентами, так і між іншими БПЛА, при цьому мережі, що використовують БПЛА, легко та швидко розгортаються. Супутниковий зв'язок у багаторівневій системі застосовується як магістральний канал зв'язку для передавання великої кількості даних на великі відстані. Використання технологій штучного інтелекту дасть змогу покращити параметри передавання як супутникового, так і БПЛА-сегмента багаторівневої системи зв'язку, а також автоматизувати процес розподілення трафіку з мобільних станцій до БПЛА та супутникового сегмента. У статті досліджено методи виявлення завад та оптимізації супутникового зв'язку, а також моделі машинного навчання для БПЛА-зв'язку.

Ключові слова: БПЛА; супутниковий зв'язок; машинне навчання.

ВСТУП

Використання безпілотних летальних апаратів (БПЛА) як ретранслятори або пересувні базові станції — перспективний напрямок розвитку безпроводових телекомунікаційних мереж. До переваг БПЛА можна віднести їх порівняну дешевизну, швидкість розгортання та мобільність, що дає змогу вирішувати проблеми взаємодії наземної інфраструктури та користувачів.

Оскільки БПЛА можна застосовувати разом із неназемними мережами (*Non-Terrestrial Network*, NTN), наприклад угрупованням супутників на низькій навколосемній орбіті (*Low Earth Orbit*, LEO), то виникає потреба в інтеграції цих двох типів мереж. Загалом орієнтовані на райони з недостатнім обслуговуванням NTN також можуть бути використані для розширення можливостей з'єднання в містах, наприклад, коли оператор наземної мережі (*Terrestrial Network*, TN) іноді орендує спектр та інфраструктуру в оператора NTN. Поточні зусилля 3GPP з інтеграції TN-NTN дадуть змогу мобільним пристроям безперешкодно перемикатися з одного сегмента на інший.

БПЛА мають свої недоліки, які можна вирішити за допомогою технологій штучного інтелекту, а саме машинного навчання (*Machine Learning*, ML). Проблеми, пов'язані з БПЛА — малий час польоту, розгортання і керування роєм БПЛА та проблеми, пов'язані з безпекою передавання даних та втратою контролю над літальними апаратами.

Проблемами супутникового сегмента в інтегрованій мережі можна вважати завади, спричинені людськими помилками, та проблему розподілення

навантаження між користувачами. Саме ці питання будуть розглядатись у цій статті та вирішуватись за допомогою методів машинного навчання.

ОСНОВНА ЧАСТИНА

Моделі контрольованого машинного навчання

У контрольованому навчанні (*Supervised Learning*, SL) модель реалізує формулу відображення $y = f(x)$, використовуючи задокументовані дані, які надають зразки відношення введення-виведення ($x-y$). Така модель передбачає майбутнє виведення (y_0) для заданого пробного введення (x_0). Процес навчання виконується оцінюванням імовірності вибірок $p(y|x)$. Регресія та класифікація — дві основні прогностичні моделі на основі SL. Структури регресії використовують статистичні підходи для формулювання зв'язку між описовими змінними та реальними результатами.

Контрольоване навчання передбачає вихідні дані, застосовуючи або лінійну, або сигмоїдну апроксимацію функції. Проте моделі класифікації — це широко використовувані схеми машинного навчання, які розподіляють вибірки даних за одним із численних доступних класів. Строго кажучи, цей вид навчання складає вхідні дані до одного з можливих виведень. Звичайні моделі класифікації можуть бути використані для БПЛА-розгортань, такі як метод опорних векторів (*Support Vector Machine*, SVM), метод K -найближчих сусідів (*K-nearest Neighbor*, KNN) та дерево розв'язків (*Decision Tree*, DT). Крім того, нинішні вдосконалені конструкції графічних процесорів дають можливість створювати складніші штучні нейронні мережі (*Artificial Neural Net-*

work, ANN) для наборів даних величезних розмірів. Модель глибинного навчання (*Deep-NN*, DNN) може охоплювати згорткову нейронну мережу (*Convolutional Neural Network*, CNN), рекурентну нейронну мережу (*Recurring Neural Network*, RNN) та машину Больцмана, які використовувалися в багатьох недосліджених галузях безпроводових мереж. Важливі поняття деяких широко застосованих категорій можна визначити в такий спосіб:

- SVM: це модель бінарної класифікації, яка розрізняє два різні типи навчальних вибірок;

- KNN: загалом використовується для задач класифікації і задач регресії. У разі класифікації ми шукаємо K -ту найближчу прилеглу навчальну тестову вибірку x_0 , а потім класифікуємо за основною масою вибірок у найближчих сусідах K . Отже, конкретний суб'єкт перебуває в $K = 1$, де x_0 належить до класу найближчої вибірки з використанням будь-якої спеціально вибраної функції відстані, такої як норма Мінковського, відстань L_p тощо, результати класифікації із більшою чутливістю до шуму. Крім того, більші значення знижують чутливість до шуму з меншою точністю класів;

- DNN: одне з основних застосувань DNN – апроксимація функцій із використанням зважених сумішей доступних одиниць (нейронів) у ряді шарів (вхідних, прихованих та вихідних). Це схоже на оброблення мозку з усіма його деталями;

- RNN: це тип NN, призначений для формулювання послідовних даних. Поточний вихід мережі є функцією поточного введення та попереднього виведення через навчальні осередки пам'яті. Перевірка різних архітектур RNN є перспективною для вивчення даних тимчасових рядів у мобільних системах, а також їх використання в розпізнаванні мовлення та обробленні природної мови (*Natural Language Processing*, NLP);

- CNN: як випливає з назви, CNN можуть автоматично витягувати цінні ознаки з необроблених вхідних ознак, що вигідніше, ніж ручне оброблення. Цей тип нейронних мереж передбачає локально пов'язані фільтри, а не повністю пов'язані структури між шарами, для захоплення просторових кореляцій. CNN використовує дві операції, а саме: згортання та об'єднання. Згортання використовує кілька фільтрів для вилучення об'єктів із набору даних та збереження відповідної просторової інформації. Тим часом об'єднання (або підвибірка) застосовується для зниження розмірності карти ознак за допомогою об'єднання максимального або середнього значення.

Розгортання БПЛА-зв'язку з використанням методів машинного навчання

Ефективність розгортання інтегрованих систем, що використовують БПЛА-зв'язок, може

бути збільшена завдяки технології машинного навчання. У цьому розділі більш детально розглянуто етапи тренування моделі для БПЛА-БС, а також можливе застосування глибинного навчання та технології блокчейну. Описано проблеми, пов'язані з безпекою передавання даних, що вирішуються за допомогою представленого методу розгортання БПЛА-сегмента.

Машинне навчання. Однією з проблем БПЛА-БС, для розв'язання якої потрібний розумний підхід — малий час польоту. Алгоритми машинного навчання можуть відіграти життєво важливу роль у їхньому розгортанні, щоб забезпечити безперебійний безпроводовий зв'язок та менше енергоспоживання, оскільки вони залежать від попередньої поведінки системи. ML — це триетапний механізм, тобто попереднє оброблення, коли збирається кілька характеристик системи у формі набору даних. Після процесу навчання системи з використанням алгоритмів ML на основі одного з типів набору даних, тобто непозначеного (коли вхідні дані для моделі ML невизначено та вона має вчитися на цих даних) або позначеного (вхідні дані для моделі ML визначені, та в якому машина навчається на основі позначених ознак). На цьому етапі навчання ми вивчаємо матрицю невідповідностей, яка дає змогу визначити як помилки, допущені системою, так і ефективність моделі. Якщо у нас є неприпустимі помилки, то ми маємо повернутися до етапу попереднього оброблення та виправити наш процес вибору ознак. Нарешті, третій та останній крок — постоброблення. У ньому модель, отримана після етапу навчання, використовується для прийняття істотно важливих рішень/прогнозів для системи.

1. *Попереднє оброблення* починається через здобуття параметрів системи для побудови набору даних. Набір даних безпроводового зв'язку системи, що передбачається для нашого оцінювання, становлять такі ознаки:

- розташування кожної точки доступу (*Access Point*, AP) та її відстань від макростільникової БС;

- розташування пристрою користувача (*User Equipment*, UE), яке показує найближчу AP та відстань від інших AP;

- потужність сигналу, отриманого UE від кожної AP (залежить від двох умов, зазначених у моделі системи);

- UE, що заслуговує на прив'язку до AP, і його фактична прив'язка до AP у момент часу t (може відрізнитись, якщо задана AP вже обробляє свою максимальну межу підімкнення користувачів, тоді UE може бути підімкнено до іншої AP з найкращим з'єднанням);

- час покриття UE, тому як це демонструє його закономірність;

- вимоги до максимальної швидкості передавання UE в момент часу t ;

- навантаження AP в момент часу t (кількість користувачів, що потребують покриття, кількість користувачів, що перебувають у зоні покриття, та споживання смуги пропускання в момент часу t);

- втрати L під час приймання сигналу.

2. *Оброблення набору даних.* Згаданий набір даних обробляється за допомогою кількох алгоритмів машинного навчання, тобто алгоритму класифікації випадкового лісу, дискримінантного аналізу, дерев розв'язків, алгоритму KNN і SVM для інтелектуального прогнозування розгортання БПЛА-БС. Після оброблення набору даних із використанням цих алгоритмів ML можливо досягти найбільшої точності, застосовуючи модель квадратичної SVM, оскільки вона має параметр регуляризації для запобігання перенавчанню та ядрового трюку, що дає змогу користувачеві побудувати модель на експертному рівні зміною параметрів розміру ядра.

3. *Постоброблення.* Після навчання модель машинного навчання експортується у сценарії, де потрібно прогнозувати кількість БПЛА-БС, що розгортаються, з їх висотами, зоною покриття, часом покриття та кластерною інформацією.

Висота БПЛА-БС визначається такими параметрами, як кількість користувачів, поведінка щільності користувачів та потрібна швидкість передавання даних на ділянці. Це допомагає оптимізувати енергоспоживання БПЛА-БС завдяки його ефективному розгортанню тільки в тих районах і саме у той час, коли це необхідно; в іншому разі енергія резервується.

Глибинне навчання. Алгоритми машинного навчання допомагають у сценаріях, коли є великі набори даних, де є чітка межа поділу між кластерами. Однак проблема виникає там, де є невеликий набір даних або поведінка користувачів не розподіляється кластеризацією. Ця проблема постає, коли модель спілкування користувача різко змінюється з часом. Для розв'язання цієї проблеми алгоритм послідовного глибинного навчання (*Deep Learning, DL*) з часовими рядами може принести максимальну користь, оскільки послідовне навчання часових рядів дає змогу системі навчатися в реальному часі. Численні послідовні алгоритми часових рядів допомагають прогнозувати події, що залежать від часу. Інтелектуальна LSTM-модель (*Long Short-Term Memory* — довготривала короткочасна пам'ять) використовується для прогнозування розгортання БПЛА-БС, оскільки це модель навчання на основі зворотного зв'язку, яка використовується у сценаріях у реальному часі. LSTM зазвичай складається з комірки та трьох регуляторів, так званих «вентилів», присутніх для потоку інформації: вхідний вентиль, вихідний вентиль та

забувальний вентиль. Він порівнює вихідні дані моделі з реальним значенням, коригує нейрони в шарах DL та прогнозує інші вихідні дані. Цей механізм здійснюється з метою самокорекції.

Блокчейн. Хоча зазначені методи забезпечують інтелектуальне розгортання БПЛА-БС, існують деякі проблеми безпеки передавання, які потрібно розв'язати, зокрема, глушіння, підслуховування, викрадення, GPS-спуфінг та DoS-атаки. Для боротьби з такими загрозами потрібний децентралізований підхід, заснований на консенсусі, який може ефективно забезпечити цілісність параметрів, пов'язаних із БПЛА-БС, зокрема його домашня адреса, регіон розгортання та доступна частота для повторного використання частот, чорний список та час розгортання. Блокчейн може допомогти нам забезпечити цілісність згаданих раніше функцій БПЛА-БС, оскільки блокчейн є розподіленим реєстром, який може усувати проблеми безпеки в мережі БПЛА-БС. У запропонованому нами підході всі параметри БПЛА-БС подано в реєстрі блокчейну. Зазвичай існує два основних типи блокчейну: загальнодоступна мережа та приватна мережа.

Публічний блокчейн — це механізм консенсусу, що не потребує дозволів, в якому будь-який вузол може брати участь у процесі майнінгу, щоб схвалити транзакцію. Для видобутку блока, в якому потрібно вирішити складну головоломку, потрібна висока обчислювальна потужність.

Водночас приватний блокчейн — це дозволений блокчейн, в якому вузли дозволені лише певних транзакцій під впливом повноважень. У БПЛА-БС вбудовано невеликий комп'ютер, що обмежує його обчислювальні можливості. Отже, механізм консенсусу, який потребує великих обчислень, менш практичний.

Також повноваженням БПЛА-БС є оператор або його власник, який має намір розмістити їх у районі для надання послуг.

Загрози безпеки, які успішно долає запропонована система, описано далі.

- *Заглушення:* БПЛА-БС, заглушені за допомогою електромагнітної гармати, можна врятувати, надавши частоті повторного використання частоти за їх ідентифікатором в блокчейні, щоб зв'язок можна було знову відновити.

- *Підслуховування:* обмін пакетами між БПЛА-БС може бути вразливим для підслуховування. Щоб вирішити цю проблему, всі пакети даних кодуються за допомогою різних схем кодування з випадковою поведінкою. Приймальні БПЛА-БС можуть знайти метод кодування, що застосовується, переглядаючи довжину даних, а також біти, які додаються до бітів даних. Кожен БПЛА-БС у мережі має таблицю, за якою може шукати використовувану схему кодування.

• **Викрадення:** щоб захистити БПЛА-ВС від такої атаки, інструкції з керування роботою БПЛА-ВС зберігаються разом з його ідентифікатором у блокчейні. Він має дотримуватися цих інструкцій у разі втрати зв'язку з Адміністрацією.

• **GPS-спуфінг:** ця атака автоматично мінімізується завдяки збереженню домашньої адреси БПЛА-ВС замість їх ідентифікаторів у блокчейні.

• **Відмова в обслуговуванні (Denial of Service, DoS):** ця атака зводиться до мінімуму за допомогою штучного інтелекту (ШІ). Об'єкт, що надсилає багато запитів у такий спосіб, щоб жоден запит іншого об'єкта не міг бути оброблений, проходить через цикл триступеневого механізму блокування. Цей механізм спостерігає за об'єктом протягом деякого часу m , потім блокує його на великий період часу n , після чого знову піднімає його, щоб перевірити, чи він генерує такий самий високий трафік. Механізм знову спостерігає за поведінкою об'єкта протягом часу $m - (m/2)$, і якщо поведінка об'єкта не перешкоджає виділенню місця для інших пакетів, то він блокується на час $n + (n/2)$. Аналогічно для третього циклу, після якого об'єкт блокується назавжди.

У гіршому випадку, якщо відбувається атака дуже високого ступеня, БПЛА-ВС шукає свою домашню адресу, що відповідає його ідентифікатору в блокчейні, і благополучно дістається додому.

Методи машинного навчання для керування завадами в супутниковому зв'язку

Для підтримання високої якості обслуговування та зручності використання в супутникових мережах ретельно відстежуються та зводяться до мінімуму завади. Виявлення завад зазвичай виконується в реактивному режимі, а не у випереджальному режимі. З огляду на те, що переважно супутники просто ретранслюють сигнали, які надходять із Землі, сигнали, що заважають, присутні здебільшого у всіх діапазонах частот. Можливість перекласти суто людську задачу, зокрема перевірку густини спектра потужності, на автоматизовану систему, здатну виявляти наявність небажаних сигналів, є привабливою перспективою з погляду поліпшення керування спектром та запобігання інцидентам із клієнтами.

Більшість завад, які є сьогодні, спричинені людськими помилками — або через неправильне наведення антени (крос-поляризація або сусідній супутник), або через неправильне налаштування обладнання (внесення шуму, інтермодуляція тощо). Ці параметри охоплюють 70-80% усіх випадків завад і не пов'язані з наземними мережами. Якщо є перекриття носійних, це, наприклад, може означати, що носійна цифрового відеомовлення (Digital Video Broadcasting, DVB) перекриває іншу носійну DVB або передавання супутни-

кового модема, включно із трафіком терміналу з дуже малою апертурою (*Very Small Aperture Terminal, VSAT*) під час множинного доступу з тимчасовим поділом каналів (*Time Division Multiple Access, TDMA*).

Щоб пом'якшити їх вплив, є кілька методів, які можуть допомогти зменшити рівні завад. Однак у багатьох випадках упоратися з ними, як і раніше, складно. Нині єдиний спосіб подолання завад — це втручання людини та проведення вичерпного аналізу, на вирішення якого може піти кілька днів. Інакше кажучи, є кваліфікований персонал, зосереджений на виявленні завад через перевірку таких показників, як спектр, аномальне збільшення коефіцієнта помилок або погіршення досвіду користувача.

Для зазначеної проблеми виявлення завад ми покладаємося на неконтрольовану модель машинного навчання, яку називають автокодувальником. Цей метод дає змогу відтворювати вхідні дані з огляду на його попереднє навчання.

Якщо вхідні дані аналогічні навчальному набору даних, здобуті вихідні дані містять ту саму статистику.

Однак, якщо вхідні дані значно відрізняються від навчальних, статистика отриманих вихідних даних повністю відрізнятиметься від вихідної.

Отже, можна виявити флуктуації сигналу, які змінюють вихідну статистику, вимірюванням помилки між вхідним і вихідним сигналами.

У нашому разі автокодувальник складається з кодувальної згорткової нейронної мережі (*Convolutional Neural Network, CNN*) і декодувальної CNN, розміщених послідовно. Кодувальник стискає блоки даних та зменшує розмірність уведення. Дані передаються декодеру, який збільшує розмірність та відновлює вихідну розмірність. Шар активації використовує функцію гіперболічного тангенсу (\tanh). CNN спеціально призначені для вхідних даних фіксованого розміру та здатні витягувати приховані шаблони з даних. Пропонована автокодувальна нейронна мережа (*Autoencoding Neural Network, ANN*) має кілька шарів згортки і проріджування, розташованих послідовно (рис. 1) (триплети — це вимір даних між кожним шаром). Аналогічна структура може використовуватися для декодування наземних сигналів.

Якщо вхідний сигнал не містить завад, і статистика не змінюється, відновлений сигнал дуже близький до вхідного сигналу. Навпаки, якщо вхідний сигнал містить завади, що змінили початкову статистику, відновлений сигнал помітно відрізняється. Отже, на виході моделі ми обчислюємо середньоквадратичну помилку (*Mean Squared Error, MSE*) між входом та виходом. Цей процес повторюється для кожного LL сегмента взятого сигналу.

Набір відліків MSE є сигналом, значення якого завжди позитивні і зменшуються, якщо на вході немає завад і збільшуються, якщо вхід містить завади. Крім того, цей набір відображає властивості залежно від статистики введення. Отже, якщо статистика введення модифікується, це відображається у статистиці MSE. Це буде використано нашим підходом.




Рис. 1. Автокодувальник із використанням згорткової нейронної мережі для виявлення завад

Що стосується методів підрахунку, застосовуватимемо різні характеристики вислідної помилки, а саме, суму нормалізованого відхилення моменту $SS1$ та коефіцієнта кореляції Пірсона між функцією густини ймовірності (*Probability Density Function*, PDF) MSE із завадами та без них $SS2$.

Щоб викликати завади, ми використовуємо попередні оцінки для встановлення різних порогів, $TT1$ і $TT2$. Перша оцінка, $SS1$, визначає відхилення порядків статистики від оригіналу.

Набори даних складаються з кількох захоплень різних подій (міжполярні завади, завади від сусідніх супутників тощо), вихідну помилку MSE яких наведено на рис. 2 за допомогою MSE для випадку, коли ми не маємо завад. Як й очікувалось, вислідна PDF відрізняється майже для кожної події. За допомогою простого візуального огляду можна повідомити супутникового оператора, що в якомусь місці сигнал має завади. Зауважимо, що для кожного сценарію завад утворюються різні статистичні дані про помилки. Значення PDF та MSE відповідають нормалізованим радіочастотним сигналам та ймовірності.

Отримана продуктивність справжніх спрацьовувань становить 81%, тоді як решта 19% спричинені помилковими спрацьовуваннями. Важливо, що значення оцінювань можуть бути скориговані

для зміни цих результатів. Наскільки ми розуміємо, у разі виявлення завад краще звести до мінімуму хибнонегативні результати за рахунок хибнопозитивних результатів.




Рис. 2. Густина ймовірності середньоквадратичної помилки між вхідним та вихідним сигналами, що використовуються в автокодувальнику

На основі наших експериментів ми порівняли запропоноване рішення з наявними детекторами енергії. З одного боку, у разі, коли сигнал, що заважає, потрапляє в ту саму смугу частот, що і корисний сигнал, і його енергія нижча, ніж енергія корисного сигналу, детектор енергії не здатний виявляти будь-які завади і стає марним. З другого боку, навпаки, запропоноване нами рішення здатне виявляти більшість завад. У наших експериментах детектор енергії видає 34% хибних спрацьовувань.

Модель машинного навчання для гнучкої оптимізації корисного навантаження

Людський підхід. Майбутні супутники, оснащені гнучким корисним навантаженням, зможуть розподіляти свої ресурси відповідно до тимчасових змін сценарію, таких як динамічні запити трафіку та небажані завади. Ресурси супутника, які потрібно налаштувати, містять діаграму напрямленості, потужність передавання та розподіл частот. Наскільки відомо, ця конфігурація має виконуватися оператором за допомогою графічного інструменту. Тобто оператор надає координати Землі, щоб змінити покриття супутника.

Щодо розподілу частоти та потужності використовується та сама ідея. Беручи це до уваги, за наявності події оператор має вручну обчислити найкращу вислідну конфігурацію корисного навантаження. Ідея задуманої моделі ML полягає в тому, щоб допомогти і, зрештою, усунути втручання людини в реконфігурацію корисного навантаження. Це знизить експлуатаційні витрати, зменшить час реакції на системні події, що зумовить покращення QoS клієнта. Загалом вислідну модель машинного навчання спрямовано на надання відповідної конфігурації корисного наван-

таження, яка може допомогти оператору в роботі зі створення нової конфігурації корисного навантаження.

Оптимізація за допомогою глибинного навчання. Тут розглядається зворотний канал гео-стаціонарної багатопроменевої супутникової системи, що працює в K_u -діапазоні за наявності небажаних завад. Супутник обслуговує всього N_u стаціонарних супутникових терміналів. Кожен термінал формує запит трафіку J_i біт/с для $i = 1, \dots, N_u$. Нехай h_i буде посиленням переданого сигналу i -го терміналу і приймається наземною станцією.

Для зворотного каналу супутник має доступний набір N_{ch} підносійних. Ми вважаємо, що кожен користувацький термінал може обслуговуватися тільки підмножиною частотних підносійних (тобто два різні користувацькі термінали не можуть використовувати ту саму підносійну). Передавання зворотним каналом відбувається за наявності зовнішніх завад у певному географічному місці. Ми вважаємо, що потужність передавання завад дорівнює P_{int} , а еквівалентний їй канал подано як h_i . Також передбачається, що місцезнаходження завад відомо, і розробник системи може змінити зону покриття супутника, щоб відхилити завади, що приймаються з коефіцієнтом μ . Передбачається, що цей коефіцієнт дорівнює $-6, -10, -15$ та -18 дБ, а смуга частот, займана завадами, є підмножиною каналів N_{ch} .

Мета полягає в тому, щоб розподілити ресурси в такий спосіб, щоб кожному терміналу користувача пропонувалася пропускна здатність R_i , максимально близька до запитаної пропускної здатності J_i . Зокрема, ми розглядаємо оптимізацію невикористаної потужності УС, яка визначається як середньоквадратична різниця між запитованою потужністю і запропонованою потужністю. Підсумовуючи, задумана модель має здійснювати відображення між користувацькими терміналами і підносійними з огляду на сценарій h_i, J_i і характеристики завад. Дійсно, ML-модель як вхідні дані має інформацію про стан каналу, запитану пропускну здатність і значення потужності завад на різних підносійних. За допомогою цієї інформації модель може обчислити конфігурацію супутника з погляду розподілу каналів (тобто зіставлення між підносійними терміналами користувача).

ВИСНОВКИ

Методи машинного навчання дають змогу поліпшити показники передавання в багаторівневих систем зв'язку, що використовують БПЛА та ЛЕО-супутники як ретранслятори. У статті висвітлено методи, що дають можливість оптимізувати енергоспоживання БПЛА-БС, а також розв'язати такі проблеми безпеки передавання даних, як глушін-

ня, підслуховування, викрадення, GPS-спуфінг та DoS-атаки. Також досліджено методи зменшення впливу завад у супутниковому сегменті багаторівневої системи зв'язку за допомогою автокодувальника. Модель автокодувальника, розглянута в статті, видає 34% хибних спрацьовувань. Також було освітлено способи розподілу ресурсів між терміналами користувачів із допомогою глибинного навчання для гнучкої оптимізації корисного навантаження. Можливим напрямком майбутнього аналізу може бути дослідження методів маршрутизації між наземним (БС та РС), наземним (БПЛА та НАР) та космічним (ЛЕО) сегментами багаторівневої системи зв'язку з використанням машинного навчання.

Список використаної літератури

1. *Machine Learning-Based Methods for Enhancement of UAV-NOMA and D2D Cooperative Networks* / L. Tsipis [et al.]. 2023. URL: <https://doi.org/10.3390/s23063014>.
2. *Performance of Hybrid Satellite-UAV NOMA Systems* / C. Gamal [et al.]. 2022. URL: <https://doi.org/10.36227/techrxiv.19614810>
3. *Prospects of using UAV-repeaters in integrated TN and NTN-networks* / V. Yakovets [et al.] // *Telecommunication and Information Technologies*. 2022. Vol. 74, no. 1. URL: <https://doi.org/10.31673/2412-4338.2022.013646>
4. *Machine Learning for Satellite Communications Operations* / M. Vazquez [et al.] // *IEEE Communications Magazine*. 2021. 59. P. 22–27. URL: <https://doi.org/10.1109/MCOM.001.2000367>.
5. *Spatial Modulation of Signals Using Polarization Methods for Wireless Communication Systems in the Optical and Radio Bands* / Y. Kremenetskaia [et al.] // *IEEE 41st International Conference on Electronics and Nanotechnology (ELNANO), Kyiv, Ukraine, 10–14 October 2022. Kyiv, 2022*. URL: <https://doi.org/10.1109/elnano54667.2022.9927077>
6. *A Novel Access and Handover Authentication Scheme in UAV-Aided Satellite-Terrestrial Integration Networks Enabling 5G* / R. Xiongpeng [et al.] // *IEEE Transactions on Network and Service Management*. 2023. P. 1–1. URL: <https://doi.org/10.1109/TNSM.2023.3246732>.
7. *Load Balancing Routing Algorithm of Low-Orbit Communication Satellite Network Traffic Based on Machine Learning* / L. Tie [et al.] // *Wireless Communications and Mobile Computing*. 2021. P. 1–14. URL: <https://doi.org/10.1155/2021/3234390>.

V. P. Yakovets, A. O. Makarenko, N. V. Rudenko, V. V. Skrypnyk
**APPLICATION OF MACHINE LEARNING IN THE INTEGRATION OF SATELLITE
AND UAV COMMUNICATION**

The integration of satellite and UAV communication is a promising direction of telecommunications development. Due to their low cost and high mobility, UAVs can take on a large number of important tasks, including the transmission of data both between subscribers and between other UAVs, while networks using UAVs are easily and quickly deployed. Unmanned aerial vehicles as mobile base stations may be deployed along with non-terrestrial networks, such as Low Earth Orbit satellite constellations, which is why the integration is necessary. Satellite communication in a multi-level system is used as a trunk communication channel to transmit large amounts of data over long distances. It is mostly used in areas with low coverage levels but NTN could also be used for coverage improvement in cities when TN operator rents the spectrum and infrastructure from NTN operator. The use of artificial intelligence technologies will improve the transmission parameters of both the satellite and UAV segment of the multi-level communication system, as well as automate the process of distributing traffic from mobile stations to the UAV and satellite segment. UAVs have their shortcomings, which can be solved with the help of artificial intelligence technologies, namely machine learning. Challenges related to UAVs — short flight time, deployment and management of a swarm of UAVs, and issues related to data security and loss of control of aircraft. Problems of the satellite segment in an integrated network can be considered as such: interference caused by human errors and the problem of load distribution among users. The article examines methods of reducing the influence of interference in the satellite segment of a multi-level communication system using an autoencoder and optimizing satellite communication, as well as machine learning models for UAV communication.

Keywords: UAV; satellite communication; machine learning.

