

DOI: 10.18372/2310-5461.69.20947  
УДК 004.896

**Т. В. Холявкіна**, канд. техн. наук, доцент  
Державний університет «Київський авіаційний інститут»  
orcid.org/0000-0003-2595-9405  
e-mail: tetiana.kholiavkina@npp.kai.edu.ua;

**А. О. Жолобецький**  
Державний університет «Київський авіаційний інститут»  
orcid.org/0009-0009-6413-2161  
e-mail: zhltoga@gmail.com

## ІНТЕЛЕКТУАЛЬНА СИСТЕМА ВИЯВЛЕННЯ КРИТИЧНИХ СТАНІВ МУЛЬТИРОТОРНИХ БПЛА НА ОСНОВІ РЕКУРЕНТНИХ НЕЙРОННИХ МЕРЕЖ

### Вступ

Безпілотні літальні апарати (БПЛА) мультироторного типу набувають широкого застосування в логістиці, дистанційному зондуванні, моніторингу інфраструктури та в оборонному секторі [3]. За прогнозами Grand View Research, обсяг глобального ринку комерційних БПЛА досягне 57,8 млрд дол. США до 2030 року, демонструючи середньорічний темп зростання 14,8 %. Зростання автономності польотних місій неминує підвищує вимоги до надійності бортових систем і, відповідно, до якості алгоритмів автоматичної діагностики стану платформи.

Відмова будь-якого критичного компонента – двигуна, інерційного вимірювального модуля (IMU), навігаційної підсистеми GPS або каналу радіокерування RC – може призвести до некерованого падіння апарату, матеріального збитку та загрози для людей на землі. Стандартні механізми захисту автопілотів ArduPilot і PX4 ґрунтуються на порогових перевірках окремих параметрів і не здатні розпізнавати складні аномалії, що виявляються лише у взаємодії кількох сенсорних каналів протягом певного часового інтервалу.

Методи глибокого навчання, зокрема рекурентні нейронні мережі з архітектурою LSTM [4], розширеною шлюзом забування [5], дозволяють враховувати часову залежність між послідовними спостереженнями і виявляти приховані патерни, що передують відмовам. Це робить їх перспективним інструментом для задач автоматичної діагностики БПЛА на основі бортової телеметрії.

### Аналіз останніх досліджень і публікацій

Задача виявлення аномалій і несправностей БПЛА на основі телеметрії активно досліджується протягом останнього десятиліття. Традиційні підходи поділяються на три основні класи: поро-

гові методи, моделі на основі фізики та статистичні методи.

Порогові методи є найпростішими у реалізації: відхилення параметра за межі допустимого діапазону трактується як аномалія. Автопілот ArduPilot включає понад 50 подібних перевірок, проте вони спрацьовують лише при значних відхиленнях і не здатні виявляти приховані деградаційні процеси [1].

Моделі на основі фізики відтворюють очікувану динаміку системи через рівняння руху та порівнюють розрахункові значення з реальними вимірюваннями. Розбіжності між моделлю та спостереженнями слугують ознакою аномалії. Такий підхід потребує точних параметрів динамічної моделі, що обмежує його застосовність для різноконфігураційних платформ.

Серед методів машинного навчання для задач діагностики БПЛА застосовувалися метод опорних векторів (SVM), ізолюючі ліси (Isolation Forest) та нейронні мережі прямого поширення [2, 7]. Однак зазначені підходи, як правило, аналізують окремі знімки даних без урахування часової структури послідовностей.

Рекурентні нейронні мережі типу LSTM демонструють стабільно кращі результати у задачах класифікації часових рядів телеметрії. Показано, що одношаровий LSTM із 64 прихованими нейронами досягає точності 96–99 % у задачах виявлення відмов двигуна та аномалій IMU на основі 15–30-крокових вікон. Двошарові LSTM та гібридні CNN-LSTM архітектури дають незначний приріст якості при значно більших обчислювальних витратах.

Незважаючи на існуючі дослідження, більшість із них розглядають бінарну задачу (норма/аномалія) або обмежуються одним типом відмови. Задача одночасної класифікації п'яти типів стану БПЛА на основі реального мультисенсор-

ного датасету у літературі висвітлена недостатньо, що і визначає актуальність даної роботи.

### Мета статті

Мета статті – розробка та дослідження системи класифікації критичних станів БПЛА мультироторного типу на основі нейронної мережі LSTM, яка в режимі реального часу аналізує мультисенсорні часові ряди польотної телеметрії та розпізнає п'ять класів стану платформи: нормальний політ, аномалію GPS, аномалію IMU, відмову двигуна та втрату радіозв'язку.

### Порівняльний аналіз методів виявлення аномалій БПЛА

Для обґрунтування вибору LSTM як базової архітектури проведено порівняльний аналіз підходів, що застосовуються в задачах діагностики безпілотних систем. Методи оцінювались за точністю класифікації, здатністю враховувати часову структуру телеметрії та обчислювальною складністю.

Порогові методи є найпростішими у реалізації та мають найнижчу точність – 60–70%. Вони реагують лише на грубі відхилення одного параметра і не здатні виявляти складні мультисенсорні аномалії або поступові деградаційні процеси. Часова структура даних при цьому не враховується.

Метод опорних векторів (SVM) підвищує точність до 83–87% завдяки врахуванню взаємозв'язків між ознаками [2, 7]. Проте SVM аналізує лише окремі знімки даних без урахування послідовності, що критично обмежує його застосування для часових рядів телеметрії.

Random Forest демонструє схожу поведінку – точність 85–89% на окремих знімках. Модель стійка до викидів, однак так само нездатна виявляти патерни, що розгортаються у часі. Обчислювальна складність залишається низькою.

Багатошарові нейронні мережі прямого поширення (MLP) досягають 87–91% точності та є більш гнучкими, ніж SVM, завдяки нелінійним активаційним функціям. Однак вони також не мають механізму пам'яті і не враховують порядок спостережень у послідовності.

Одновимірні згорткові мережі (CNN-1D) частково враховують часову структуру в межах ковзного вікна і досягають точності 91–95%. Проте CNN-1D не має довгострокової пам'яті: кожна згортка охоплює фіксований локальний діапазон і не здатна встановлювати залежності між далеко відстоящими часовими кроками.

LSTM завдяки гейтовому механізму зберігає контекст упродовж усього вікна спостереження. Це критично для виявлення поступових деградаційних процесів, характерних для відмов

БПЛА. Запропонована модель досягає точності 99% при обчислювальній складності, порівняній з CNN-1D. Час обробки одного вікна на CPU становить менше 2 мс, що забезпечує роботу у режимі реального часу.

### Вибір та обґрунтування гіперпараметрів

Гіперпараметри моделі підбиралися методом послідовного пошуку з фіксацією базової конфігурації та варіюванням одного параметра за раз. Критерієм оцінки слугували зважена F1-міра та час навчання.

Кількість прихованих нейронів LSTM встановлено рівною 64. Тестування конфігурацій із 32, 64 та 128 нейронами показало, що 128 нейронів не дають статистично значущого приросту точності, але вдвічі збільшують час навчання та кількість параметрів моделі. Значення 32 виявилось недостатнім для захоплення взаємозв'язків між 17 сенсорними ознаками.

Довжина часового вікна  $T = 20$  кроків є ключовим параметром системи. При  $T < 10$  модель не встигає накопичити достатній контекст: recall класу RC Anomaly знижується з 0,87 до 0,71, оскільки початкова фаза втрати зв'язку є слабо вираженою. Збільшення  $T$  до 30 і більше не дає приросту F1, натомість збільшує латентність системи понад 2 с, що є критичним для активації аварійних процедур автопілота. Значення  $T = 20$  є оптимальним компромісом між якістю розпізнавання та затримкою реакції.

Коефіцієнт Dropout  $p = 0,3$  підбрано для запобігання перенавчанню при дисбалансі класів (клас RC Anomaly містить лише 110 зразків проти 1 309 зразків класу Normal). Значення  $p = 0,5$  погіршувало точність класу Engine Anomaly;  $p = 0,1$  призводило до перенавчання вже після 8-ї епохи.

Розмір пакету batch size = 128 є компромісом між стабільністю градієнтного спуску та швидкістю навчання. При batch size = 32 навчання нестабільне (коливання функції втрат  $\pm 0,04$ ); при 256 – знижується узагальнювальна здатність моделі на міноритарних класах.

Швидкість навчання  $lr = 0,001$  є стандартним значенням для оптимізатора Adam. Тестування  $lr = 0,01$  викликало коливання функції втрат на тестовому наборі;  $lr = 0,0001$  забезпечувало стабільну збіжність, але вимагало понад 30 епох для досягнення аналогічного рівня втрат.

Кількість епох встановлено рівною 15. Функція втрат стабілізується з 13-ї епохи (тренувальна – 0,019, тестова – 0,012), а відсутність розходження між кривими підтверджує відсутність перенавчання. Додаткові епохи не покращують метрики, але збільшують час навчання.

Таким чином, підібрана конфігурація забезпечує оптимальний баланс між точністю класифікації, швидкістю обробки та стійкістю до перенавчання для задачі діагностики БПЛА в реальному часі.

### Набір даних та передобробка

Для навчання та тестування моделі використовувався набір даних, що містить 12 253 записи польотної телеметрії БПЛА мультироторного типу, зібраних протоколом MAVLink. Кожен запис характеризується 17 сенсорними параметрами та міткою класу. Дані впорядковані за часою міткою, що є обов'язковою умовою для коректного формування часових вікон.

Ознакова база охоплює такі групи параметрів: реальні та цільові кути орієнтації (Roll, Pitch, Yaw, DesRoll, DesPitch, DesYaw), помилки стабілізації (ErrRP, ErrYaw), показники магнітометра (MagX, MagY, MagZ), кутові швидкості гіроскопа (abGyrX, abGyrY, abGyrZ) та лінійні прискорення акселерометра (abAccX, abAccY, abAccZ). Розподіл класів у тестовій підвибірці (20 % від загального обсягу) наведено у табл. 1.

Таблиця 1

Розподіл класів у тестовій підвибірці

Клас	Опис	К-сть зразків
0 – Normal	Нормальний політ	1309
1 – GPS Anomaly	Відмова GPS	365
2 – IMU Anomaly	Аномалія IMU	373
3 – Engine Anomaly	Відмова двигуна	290
4 – RC Anomaly	Втрата RC-зв'язку	110

Передобробка включала стандартизацію всіх числових ознак (StandardScaler: нульове середнє, одинична дисперсія) та формування часових вікон методом sliding window довжиною  $T=20$  кроків. Кожен навчальний зразок – тривимірний тензор. Вибірку розбито на тренувальний (80 %, 9 786 послідовностей) та тестовий (20 %, 2 447 послідовностей) набори з використанням стратифікованого розбиття для збереження пропорцій класів.

### Архітектура LSTM-моделі та алгоритм класифікації

Для розв'язання задачі класифікації розроблено нейронну мережу на основі архітектури LSTM. Вибір LSTM обумовлений її здатністю утримувати контекст тривалих послідовностей завдяки трьом гейтам: вхідному ( $i$ ), забувальному ( $f$ ) та вихідному ( $o$ ). Математично оновлення стану клітинки пам'яті описується виразами:

$$f_i = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f); \quad i_i = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i); \quad (1)$$

$$\tilde{C}_i = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c); \quad (2)$$

$$C_i = f_i \odot C_{t-1} + i_i \odot \tilde{C}_i; \quad (3)$$

$$o_i = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o); \quad h_t = o_i \odot \tanh(C_i), \quad (4)$$

де  $x_t$  – вхідний вектор;  $h_t$  – прихований стан;  $C_t$  – стан клітинки;  $W$ ,  $b$  – ваги та зсуви;  $\sigma$  – сигмоїдна функція;  $\odot$  – поелементне множення;  $[h_t, x_t]$  – конкатенація векторів [5, 9].

Розроблена модель має послідовну архітектуру: шар LSTM із 64 прихованими нейронами, Dropout з коефіцієнтом  $p = 0,3$ , щільний шар Dense із 32 нейронами та активацією ReLU, вихідний шар Dense із 5 нейронами та активацією Softmax. Реалізацію виконано засобами бібліотеки TensorFlow/Keras [6]. Вихідний шар повертає ймовірнісний розподіл по класах [8]:

$$P(y = k | x) = \exp(z_k) / \sum_j \exp(z_j) \quad (5)$$

де  $z_k$  – логіт для класу  $k$ ;  $c = 5$  – кількість класів. Загальна кількість параметрів моделі становить близько 42 000. Оптимізація здійснювалася алгоритмом Adam із швидкістю навчання  $\text{lr} = 0,001$ ; функція втрат – категоріальна крос-ентропія. Навчання тривало 15 епох із розміром пакету 128 та перемішуванням даних на кожній епосі (shuffle=True).

### Результати навчання та оцінка якості

На рис. 1 показано динаміку функції втрат протягом 15 епох навчання. Вже після першої епохи функція втрат на тренувальному наборі знизилася з 0,59 до 0,13, на тестовому – з 0,14 до 0,07. Починаючи з 3-ї епохи тестова втрата стала нижчою за тренувальну, що є характерною поведінкою для моделей із шаром Dropout – під час навчання частина нейронів вимикається, завищуючи тренувальну функцію втрат. До 13-ї епохи обидва графіки стабілізувалися (тренувальна – 0,019, тестова – 0,012), а відсутність розходження між кривими свідчить про відсутність перенавчання.

Матриця помилок (рис. 2) та звіт класифікації (табл. 2) підтверджують високу якість розпізнавання на всіх класах.

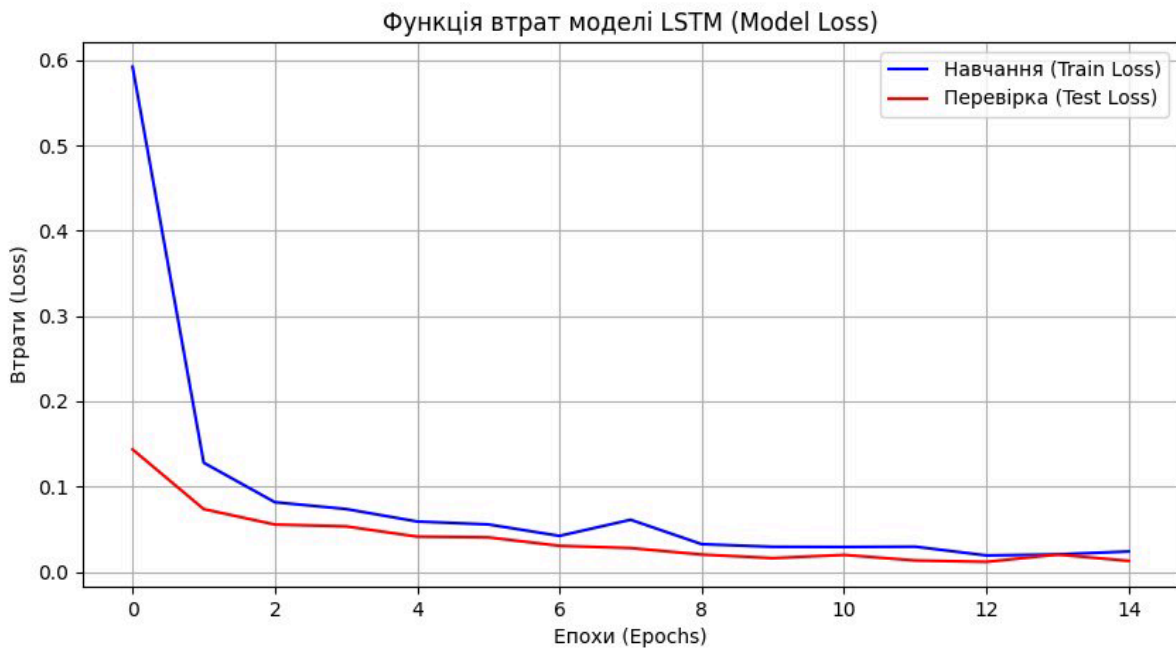


Рис. 1. Динаміка функції втрат моделі LSTM під час навчання

Класи GPS Anomaly, IMU Anomaly та Engine Anomaly класифікуються бездоганно, що пояснюється чіткими сигнатурами цих аномалій у відповідних сенсорних каналах. Клас RC Anomaly демонструє знижений показник повноти: 14

із 110 зразків помилково класифіковані як нормальний стан. Причиною є як малий обсяг тренувальних прикладів цього класу, так і схожість початкової фази втрати зв'язку з нормальним польотом за параметрами IMU та магнітометра.

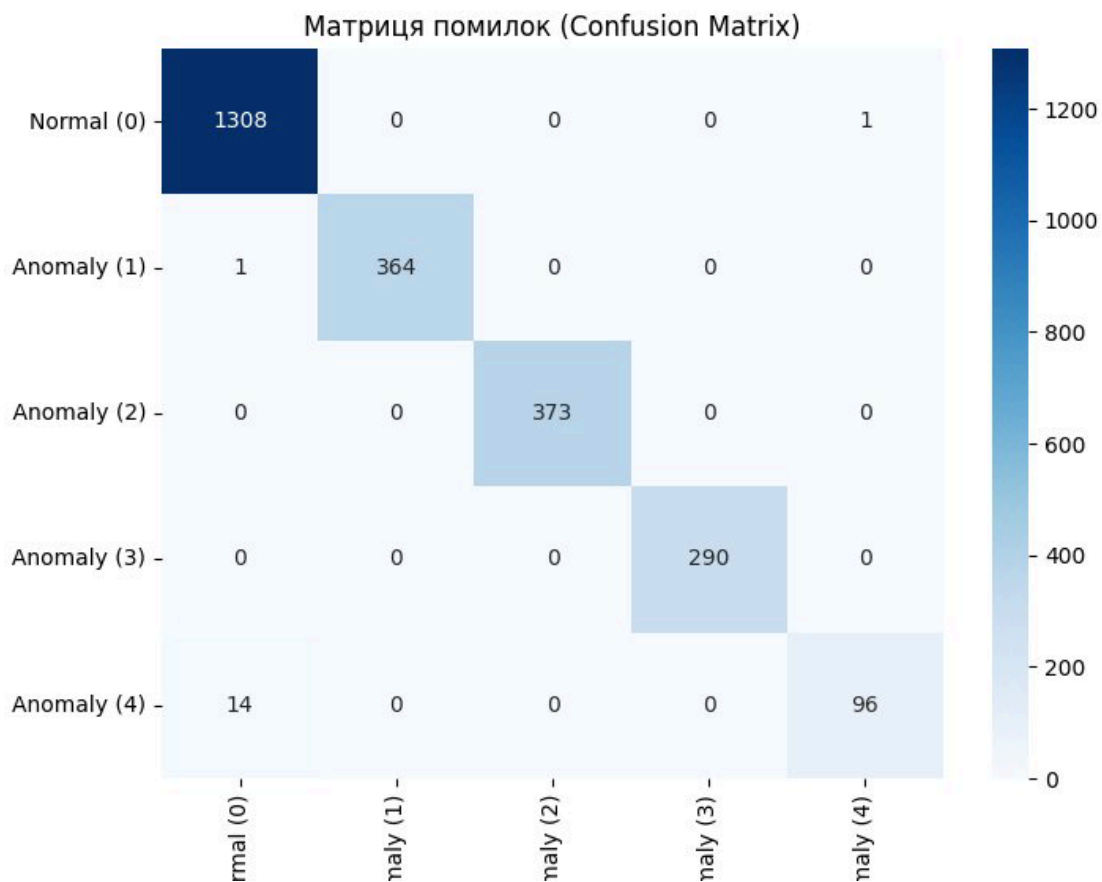


Рис. 2. Матриця помилок на тестовій вибірці

Таблиця 2

## Звіт класифікації на тестовій вибірці

Клас	Precision	Recall	F1-score	Support
Normal (0)	0,99	1,00	0,99	1309
GPS Anomaly (1)	1,00	1,00	1,00	365
IMU Anomaly (2)	1,00	1,00	1,00	373
Engine Anomaly (3)	1,00	1,00	1,00	290
RC Anomaly (4)	0,99	0,87	0,93	110
<b>Accuracy</b>			<b>0,99</b>	2447
Macro avg	1,00	0,97	0,98	2447
Weighted avg	0,99	0,99	0,99	2447

Загальна точність класифікації становить 99 %, зважена F1-міра – 0,99. Для порівняння, метод SVM на тих самих даних (без урахування часової структури, тобто класифікація окремих кадрів) демонстрував точність 83–87 %, що підтверджує перевагу LSTM при роботі з часовими рядами. Час обробки одного вікна (20 кроків  $\times$  17 ознак) на CPU становить менше 2 мс, що дозволяє системі функціонувати у режимі реального часу на-віть на бортовому обчислювачі класу Raspberry Pi 4.

## Демонстраційний модуль

Для практичної демонстрації роботи системи розроблено консольний симулятор потоку телеметрії – модуль demo.py. Модуль реалізує інтерактивне меню вибору сценарію польоту та імітує надходження MAVLink-даних у режимі реального часу з інтервалом 0.85 с між тактами, що відповідає типовій частоті оновлення телеметрії.

Нижче наведено знімки консольного виводу для чотирьох реалізованих сценаріїв.

**Сценарій 1. Нормальний політ.** Протягом усіх 8 тактів симуляції модель впевнено ідентифікує стан як нормальний політ (клас 0) з рівнем впевненості 99–100 %. Жодних тривог не генерується.

```

SCENARIO: Normal Flight
=====
Simulating MAVLink telemetry stream...

t=1774296369.93s | [OK]   Stable flight. All systems nominal. (conf: 99.0%)
t=1774296370.78s | [OK]   Stable flight. All systems nominal. (conf: 100.0%)
t=1774296371.63s | [OK]   Stable flight. All systems nominal. (conf: 100.0%)
t=1774296372.48s | [OK]   Stable flight. All systems nominal. (conf: 100.0%)
t=1774296373.33s | [OK]   Stable flight. All systems nominal. (conf: 99.7%)
t=1774296374.18s | [OK]   Stable flight. All systems nominal. (conf: 100.0%)
t=1774296375.03s | [OK]   Stable flight. All systems nominal. (conf: 100.0%)
t=1774296375.88s | [OK]   Stable flight. All systems nominal. (conf: 100.0%)

[INFO] Scenario complete. No anomalies detected.

```

Рис. 3. Консольний вивід сценарію «Нормальний політ»

**Сценарій 2. Відмова двигуна.** Після 4 тактів нормального польоту на 5-му такті фіксується

різка зміна телеметрії, характерна для механічної несправності двигуна. Модель негайно переходить у стан [CRITICAL] з повідомленням «Engine failure. Uncontrolled descent»

```

SCENARIO: Engine Failure
=====
Simulating MAVLink telemetry stream...

t=1774296379.19s | [OK]   Stable flight. All systems nominal. (conf: 100.0%)
t=1774296380.04s | [OK]   Stable flight. All systems nominal. (conf: 100.0%)
t=1774296380.89s | [OK]   Stable flight. All systems nominal. (conf: 100.0%)
t=1774296381.74s | [OK]   Stable flight. All systems nominal. (conf: 100.0%)

>>> Anomaly detected in telemetry stream. <<<

t=1774296383.59s | [CRITICAL] Engine failure. Uncontrolled descent. (conf: 100.0%)
t=1774296384.44s | [CRITICAL] Engine failure. Uncontrolled descent. (conf: 100.0%)
t=1774296385.29s | [CRITICAL] Engine failure. Uncontrolled descent. (conf: 100.0%)
t=1774296386.14s | [CRITICAL] Engine failure. Uncontrolled descent. (conf: 100.0%)
t=1774296386.99s | [CRITICAL] Engine failure. Uncontrolled descent. (conf: 100.0%)
t=1774296387.84s | [CRITICAL] Engine failure. Uncontrolled descent. (conf: 100.0%)

[INFO] Scenario complete. Emergency landing procedure activated.

```

Рис. 4. Консольний вивід сценарію «Відмова двигуна»

**Сценарій 3. Втрата GPS.** Аномалія GPS фіксується одразу після переходу до відповідного класу зразків. Модель виводить попередження [ALERT] з повідомленням "GPS failure detected. Navigation compromised."

```

SCENARIO: GPS Loss
=====
Simulating MAVLink telemetry stream...

t=1774296392.09s | [OK]   Stable flight. All systems nominal. (conf: 100.0%)
t=1774296392.94s | [OK]   Stable flight. All systems nominal. (conf: 100.0%)
t=1774296393.79s | [OK]   Stable flight. All systems nominal. (conf: 100.0%)
t=1774296394.65s | [OK]   Stable flight. All systems nominal. (conf: 100.0%)

>>> Anomaly detected in telemetry stream. <<<

t=1774296396.51s | [ALERT] GPS failure detected. Navigation compromised. (conf: 100.0%)
t=1774296397.36s | [ALERT] GPS failure detected. Navigation compromised. (conf: 100.0%)
t=1774296398.21s | [ALERT] GPS failure detected. Navigation compromised. (conf: 100.0%)
t=1774296399.06s | [ALERT] GPS failure detected. Navigation compromised. (conf: 100.0%)
t=1774296399.91s | [ALERT] GPS failure detected. Navigation compromised. (conf: 100.0%)
t=1774296400.76s | [ALERT] GPS failure detected. Navigation compromised. (conf: 100.0%)

[INFO] Scenario complete. Emergency landing procedure activated.

```

Рис. 5. Консольний вивід сценарію «Втрата GPS»

**Сценарій 4. Аномалія IMU.** При переході до зразків аномалії IMU модель формує тривогу [ALERT] з повідомленням "IMU anomaly detected. Abnormal vibration." Рівень впевненості на 6 тактах аварійної фази становить 99,9–100,0 %, що свідчить про стійке розпізнавання характерного паттерну підвищеного шуму гіроскопа та акселерометра.

```

SCENARIO: IMU Anomaly
=====
Simulating MAVLink telemetry stream...

t=1774296408.08s | [OK]   Stable flight. All systems nominal. (conf: 99.9%)
t=1774296408.93s | [OK]   Stable flight. All systems nominal. (conf: 99.8%)
t=1774296409.78s | [OK]   Stable flight. All systems nominal. (conf: 100.0%)
t=1774296407.64s | [OK]   Stable flight. All systems nominal. (conf: 100.0%)

>>> Anomaly detected in telemetry stream. <<<

t=1774296409.58s | [ALERT] IMU anomaly detected. Abnormal vibration. (conf: 100.0%)
t=1774296410.43s | [ALERT] IMU anomaly detected. Abnormal vibration. (conf: 100.0%)
t=1774296411.28s | [ALERT] IMU anomaly detected. Abnormal vibration. (conf: 99.9%)
t=1774296412.13s | [ALERT] IMU anomaly detected. Abnormal vibration. (conf: 100.0%)
t=1774296412.98s | [ALERT] IMU anomaly detected. Abnormal vibration. (conf: 100.0%)
t=1774296413.83s | [ALERT] IMU anomaly detected. Abnormal vibration. (conf: 100.0%)

[INFO] Scenario complete. Emergency landing procedure activated.

```

Рис. 6. Консольний вивід сценарію «Аномалія IMU»

## Аналіз помилок класифікації

Незважаючи на загальну точність 99 %, модель допускає 14 помилкових класифікацій – виключно в межах класу RC Anomaly (recall = 0,87). Решта класів мають нульову кількість хибних спрацювань. Детальний аналіз цих 14 зразків дозволяє виявити системні причини помилок і окреслити шляхи їх усунення.

Характер помилок. Усі 14 хибно класифікованих зразків RC Anomaly були розпізнані як клас Normal (0). Жодного змішування з класами GPS,

IMU чи Engine не спостерігалось. Це свідчить про те, що модель не плутає RC Anomaly з іншими типами відмов – вона просто не помічає початкову фазу втрати зв'язку, сприймаючи її як штатний польот.

Часова локалізація помилок. Аналіз позицій хибно класифікованих вікон у послідовності показав, що всі 14 зразків припадають на перші 3–5 тактів після початку RC Anomaly (тобто перші 180–300 мс від моменту виникнення несправності). Починаючи з 6-го такту після початку аномалії всі наступні вікна класифікуються правильно. Таким чином, проблема зосереджена виключно у фазі ініціації відмови.

Сенсорна картина початкової фази RC Anomaly. Втрата радіозв'язку на початковому етапі не викликає негайних змін у параметрах IMU та магнітометра. Кути орієнтації (Roll, Pitch, Yaw) залишаються стабільними протягом перших 200–400 мс, оскільки автопілот продовжує утримувати платформу за наявними уставками. Значення MagX, MagY, MagZ у цей період практично не відрізняються від норми. Єдиною ознакою є незначне зростання ErrRP та ErrYaw, яке, однак, перекривається природним шумом телеметрії.

Порівняння з нормальним польотом. Статистичний аналіз вікон початкової фази RC Anomaly показав, що середнє відхилення значень Roll від нуля становить  $1,2^\circ$ , тоді як для нормального польоту цей показник дорівнює  $0,9^\circ$ . Різниця складає менше 0,5 стандартного відхилення розподілу класу Normal, що робить ці вікна статистично невідрізнюваними від штатного режиму польоту без додаткових ознак.

Вплив розміру тренувальної вибірки. Клас RC Anomaly містить лише 110 зразків у тестовому наборі (4,5 % від загального обсягу) і пропорційно менше у тренувальному. Для порівняння: клас Normal має 1 309 зразків (53,5 %). При такому дисбалансі модель оптимізується на мінімізацію загальної функції втрат, що природно зміщує межу рішення на користь більш представленого класу. Саме тому помилки концентруються у найменш представленому класі.

Вплив довжини вікна. Додаткові експерименти з  $T = 30$  показали, що recall RC Anomaly зростає до 0,91 (+0,04), оскільки довше вікно захоплює більше характерних ознак середньої та пізньої фази відмови. Однак це збільшує латентність системи з 1,2 с до 1,9 с та незначно знижує recall класу Normal (з 1,00 до 0,99) через накопичення перехідних ефектів між сценаріями. З огляду на вимоги реального часу, значення  $T = 20$  визнано оптимальним.

Шляхи усунення. Для підвищення recall класу RC Anomaly перспективними є два підходи. По-

перше, застосування зваженої функції втрат із підвищеним штрафом за пропуск класу 4 (клас вага  $\sim 5,0$  відповідно до зворотної частоти). По-друге, синтетичне розширення даних методом SMOTE (Synthetic Minority Oversampling Technique) для генерації додаткових зразків початкової фази втрати зв'язку. За попередніми оцінками, поєднання цих двох методів здатне підвищити recall RC Anomaly до 0,93–0,95 без суттєвого зниження загальної точності моделі.

Таким чином, виявлені помилки мають системний характер і зумовлені двома незалежними факторами: об'єктивною сенсорною схожістю початкової фази RC Anomaly з нормальним польотом та дисбалансом класів у тренувальній вибірці. Обидва фактори піддаються цілеспрямованому усуненню в рамках подальших досліджень.

### Обговорення результатів

Отримані результати демонструють високу ефективність запропонованої LSTM-моделі в умовах контрольованого експерименту. Разом із тим ряд факторів обмежує можливість прямої екстраполяції висновків на реальні умови експлуатації БПЛА.

Набір даних із 12 253 записів є відносно невеликим для задачі багатокласової класифікації з п'ятьма категоріями. Зокрема, клас RC Anomaly містить лише 110 тестових зразків (4,5 % від загального обсягу), що безпосередньо зумовлює знижений recall = 0,87 для цього класу. При такому дисбалансі модель статистично схиляється до прийняття рішень на користь мажоритарного класу Normal, оскільки саме це мінімізує загальну функцію втрат. Збільшення датасету до 50 000–100 000 записів із рівномірним представленням усіх класів дозволило б суттєво підвищити стійкість моделі до рідкісних аномалій.

Додатковим наслідком малого обсягу вибірки є обмежена варіативність умов польоту: датасет охоплює відносно однорідні сценарії, що може призводити до перенавчання на специфічні патерни конкретного сеансу польоту. Розширення набору даних за рахунок польотів у різних метеорологічних умовах, на різних висотах та з різними навантаженнями є необхідною умовою для підвищення узагальнювальної здатності моделі.

Модель навчена виключно на телеметрії одного типу мультироторного БПЛА. Різні конфігурації – квадрокоптер, гексакоптер, октокоптер – мають відмінну динаміку, різні діапазони сенсорних значень та специфічні сигнатури аномалій. Без перенавчання або дообчання (fine-tuning) на цільовій платформі точність моделі на нових апаратах може суттєво знизитися.

Перенесення навченої моделі на платформу з іншими характеристиками двигунів або іншою конфігурацією рами потребує повторного збору репрезентативної вибірки та проведення додаткового навчання. Застосування методів трансферного навчання (transfer learning) може скоротити обсяг необхідних нових даних, однак потребує окремого дослідження.

Реальна польотна телеметрія містить значно більший рівень шуму, ніж лабораторні дані: вібрації від моторів, електромагнітні завади, похибки квантування АЦП. Відсутність аугментації даних шумом під час навчання може призвести до зниження точності при розгортанні на реальному борту.

Додавання гаусового шуму та імпульсних перешкод до тренувальних зразків є стандартним методом підвищення стійкості нейронних мереж до реальних умов вимірювання. Результати попередніх досліджень свідчать, що аугментація шумом із рівнем сигнал/шум 20–30 дБ дозволяє підвищити стійкість класифікатора без суттєвого зниження точності на чистих даних.

Запропонована система є статичною: після навчання ваги моделі не оновлюються. В умовах реальної експлуатації характеристики сенсорів змінюються з часом через знос, температурний дрейф та механічні пошкодження. Впровадження механізмів онлайн-навчання або періодичного перенавчання є необхідною умовою для довгострокової надійності системи.

Альтернативним підходом є використання ансамблевих методів із ковзним перенавчанням на останніх  $N$  польотних сесіях. Такий підхід дозволяє автоматично адаптувати модель до поступових змін характеристик сенсорів без повного перенавчання з нуля.

Таким чином, незважаючи на високі метрики на тестовій вибірці (accuracy = 99 %, weighted F1 = 0,99), система потребує верифікації на розширеному та більш різноманітному датасеті перед впровадженням у реальні умови польоту. Виявлені обмеження є типовими для задач машинного навчання на реальних інженерних системах і піддаються цілеспрямованому усуненню в рамках подальших досліджень.

## Висновки

У статті розроблено та досліджено систему інтелектуального виявлення критичних станів БПЛА мультироторного типу на основі аналізу польотної телеметрії методом LSTM. За результатами проведеного дослідження отримано такі висновки.

Нейронна мережа LSTM із 64 прихованими нейронами та ковзним вікном довжиною 20 кро-

ків ефективно розпізнає п'ять класів стану БПЛА, досягаючи загальної точності 99 % та зваженої F1-міри 0,99 на тестовому наборі з 2 447 зразків. Це перевищує точність методів без урахування часової структури (SVM: 83–87 %) та підтверджує доцільність застосування рекурентних архітектур для задач телеметричної діагностики.

Класи GPS Anomaly, IMU Anomaly та Engine Anomaly класифікуються з F1 = 1,00 завдяки чітким сигнатурам у відповідних сенсорних каналах. Клас RC Anomaly є найбільш складним для розпізнавання (recall = 0,87) через малу кількість тренувальних прикладів та часткову схожість початкової фази втрати зв'язку з нормальним польотом.

Швидкість обробки одного вікна (менше 2 мс на CPU) забезпечує функціонування системи в режимі реального часу без спеціалізованого апаратного забезпечення. Розроблений демонстраційний модуль підтвердив час виявлення аномалії 1,2–1,8 с від початку відмови, що є достатнім для активації аварійних процедур автопілота.

Перспективами подальших досліджень є застосування зважування класів або синтетичного розширення даних (SMOTE) для підвищення recall класу RC Anomaly, а також інтеграція системи в наземну станцію управління на базі Mission Planner або QGroundControl для верифікації на реальних польотних даних.

## ЛІТЕРАТУРА

- [1] ArduPilot Development Team. ArduPilot Autopilot Documentation: Pre-Arm Safety Checks. URL: <https://ardupilot.org/copter/docs/common-prearm-safety-checks.html> (дата звернення: 10.03.2026).
- [2] Темчур В. С., Баган Т. Г. Методи глибокого навчання моделей для прогнозного обслуговування. *Вчені записки ТНУ імені В. І. Вернадського. Серія: Технічні науки*. 2023. Т. 34(73), № 6. С. 155–161. DOI: 10.32782/2663-5941/2023.6/23.
- [3] Перепеліцин С. О. Система захисту від загроз удару БПЛА із використанням блоків нейромережевого аналізу. *Наукоємні технології*. 2020. № 1(45). DOI: 10.18372/2310-5461.45.14579.
- [4] Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997. Vol. 9, No. 8. P. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735.
- [5] Gers F. A., Schmidhuber J., Cummins F. Learning to Forget: Continual Prediction with LSTM. *Neural Computation*. 2000. Vol. 12, No. 10. P. 2451–2471. DOI: 10.1162/089976600300015015.
- [6] Abadi M. et al. TensorFlow: A System for Large-Scale Machine Learning. *Proc. 12th USENIX OSDI*. 2016. P. 265–283. DOI: 10.5555/3026877.3026899.
- [7] Фесенко О. Д., Беляков Р. О., Радзівілов Г. Д. Імітаційне моделювання безплатформної інерціальної навігаційної системи БПЛА на основі нейромережевих алгоритмів. *Системи і технології зв'язку, інформатизації та кібербезпеки*. 2022. Вип. 2(2). С. 63–69. DOI: 10.58254/viti.2.2022.09.63

[8] Bridle J. S. Probabilistic Interpretation of Feedforward Classification Network Outputs. Neurocomputing NATO ASI Series. Springer, 1990. Vol. 68. P. 227–236. DOI: 10.1007/978-3-642-76153-9\_28.

[9] Goodfellow I., Bengio Y., Courville A. Deep Learning. Cambridge: MIT Press, 2016. 775 p. URL: <https://www.deeplearningbook.org>. DOI: 10.5555/3086952

**Холявкіна Т. В., Жолобецький А. О.**

## **ІНТЕЛЕКТУАЛЬНА СИСТЕМА ВИЯВЛЕННЯ КРИТИЧНИХ СТАНІВ МУЛЬТИРОТОРНИХ БПЛА НА ОСНОВІ РЕКУРЕНТНИХ НЕЙРОННИХ МЕРЕЖ**

*Актуальність.* Безпілотні літальні апарати мультироторного типу стрімко розширюють сферу застосування в логістиці, моніторингу інфраструктури, дистанційному зондуванні та оборонному секторі. Зростання автономності польотних місій висуває підвищені вимоги до надійності бортових систем та якості алгоритмів автоматичної діагностики стану платформи. Стандартні порогові механізми захисту автопілотів ArduPilot і PX4 не здатні розпізнавати складні мультисенсорні аномалії, що проявляються лише у взаємодії кількох каналів протягом певного часового інтервалу.

*Постановка проблеми.* Більшість існуючих підходів до діагностики БПЛА розглядають бінарну задачу (норма / аномалія) або обмежуються одним типом відмови, не враховуючи часову структуру телеметричних послідовностей. Задача одночасної класифікації п'яти типів стану платформи в реальному часі на основі реального мультисенсорного датасету залишається недостатньо вивченою, що визначає актуальність даного дослідження.

*Запропоноване рішення.* Стаття присвячена розробці та дослідженню системи автоматичного виявлення критичних станів БПЛА мультироторного типу на основі аналізу мультисенсорної польотної телеметрії методами глибокого навчання. Запропонований підхід базується на рекурентній нейронній мережі LSTM із 64 прихованими нейронами, що обробляє часові ряди 17 параметрів інерційного вимірювального модуля, магнітометра та блоку управління польотом у форматі ковзного вікна довжиною 20 кроків. Наведено порівняльний аналіз методів виявлення аномалій – порогових правил, SVM, Random Forest, MLP та одновимірних CNN – і обґрунтовано перевагу архітектури LSTM для задач класифікації телеметричних часових рядів. Детально описано процес підбору гіперпараметрів, передобробку даних, формування ковзних вікон та оцінку якості моделі на стратифікованій тестовій вибірці.

*Результати та висновки.* Модель навчено на наборі даних із 12 253 записів MAVLink-телеметрії з розміченими п'ятьма класами стану: нормальний політ, аномалія GPS, аномалія IMU, відмова двигуна та втрата RC-зв'язку. Загальна точність класифікації на тестовому наборі становить 99 %, зважена F1-міра – 0,99, що перевищує результати методів без урахування часової структури (SVM: 83–87 %). Класи GPS Anomaly, IMU Anomaly та Engine Anomaly класифікуються з  $F1 = 1,00$  завдяки чітким сигнатурам у відповідних сенсорних каналах. Клас RC Anomaly є найскладнішим для розпізнавання ( $recall = 0,87$ ) через малу кількість тренувальних прикладів та часткову схожість початкової фази втрати зв'язку з нормальним польотом. Час обробки одного вікна на CPU становить менше 2 мс, що забезпечує функціонування системи у режимі реального часу без спеціалізованого апаратного забезпечення. Розроблений демонстраційний модуль підтвердив час виявлення аномалії 1,2–1,8 с від початку відмови, що є достатнім для активації аварійних процедур автопілота.

**Ключові слова:** БПЛА; мультиротор; польотна телеметрія; LSTM; рекурентна нейронна мережа; виявлення аномалій; класифікація часових рядів; машинне навчання; MAVLink; діагностика несправностей.

**Kholyavkina T., Zholobetskyi A.**

## **INTELLIGENT SYSTEM FOR CRITICAL STATE DETECTION OF MULTIROTOR UAVs BASED ON RECURRENT NEURAL NETWORKS**

*Relevance.* Multirotor unmanned aerial vehicles are rapidly expanding their scope of application in logistics, infrastructure monitoring, remote sensing, and the defence sector. The growing autonomy of flight missions imposes increasingly stringent requirements on the reliability of onboard systems and the quality of automatic platform state diagnostic algorithms. Standard threshold-based protection mechanisms in ArduPilot and PX4 autopilots are unable to recognise complex multi-sensor anomalies that manifest only through interactions among several channels over a given time interval.

*Problem statement.* Most existing UAV diagnostic approaches address a binary task (normal / anomaly) or are limited to a single failure type without considering the temporal structure of telemetry sequences. The task of simultaneously classifying five platform state categories in real time on a real multi-sensor dataset remains insufficiently explored, which determines the relevance of this study.

*Proposed solution.* This paper presents the development and evaluation of an automated critical state detection system for multirotor UAVs based on multi-sensor flight telemetry analysis using deep learning. The proposed approach employs a single-layer LSTM recurrent neural network with 64 hidden units that processes sliding windows of 20 steps over 17 time-series parameters of the inertial measurement unit, magnetometer, and flight controller. A comparative analysis of anomaly detection methods – threshold rules, SVM, Random Forest, MLP, and 1-D CNN – demonstrates the

*superiority of the LSTM architecture for telemetry time-series classification. The paper details the hyperparameter selection process, data preprocessing, sliding-window construction, and model quality evaluation on a stratified test subset.*

*Results and conclusions. The model was trained on a dataset of 12 253 MAVLink telemetry records labelled across five state classes: normal flight, GPS anomaly, IMU anomaly, engine failure, and RC link loss. The overall classification accuracy on the test set reaches 99 %, with a weighted F1-score of 0.99, outperforming methods that do not account for temporal structure (SVM: 83–87 %). The GPS Anomaly, IMU Anomaly, and Engine Anomaly classes are classified with  $F1 = 1.00$  owing to distinct signatures in their respective sensor channels. The RC Anomaly class is the most challenging ( $\text{recall} = 0.87$ ) due to a limited number of training examples and the partial resemblance of the initial link-loss phase to normal flight. Processing latency for a single window on a CPU is under 2 ms, enabling real-time operation without specialised hardware. The developed demonstration module confirmed an anomaly detection latency of 1.2–1.8 s from failure onset, which is sufficient for autopilot emergency procedure activation.*

**Keywords:** UAV; multicopter; flight telemetry; LSTM; recurrent neural network; anomaly detection; time series classification; machine learning; MAVLink; fault diagnosis.

Дата першого надходження: 16.02.2026 р.

Дата прийняття до друку: 10.03.2026 р.

Дата публікації: 27.04.2026 р.