



„AGENCI SZTUCZNEJ INTELIGENCJI W AUTOMATYZACJI ZŁOŻONYCH ZADAŃ”

mgr inż. ppor. Damian Szymański

dr inż. płk. Rafał Kasprzyk

Wojskowa Akademia Techniczna im. Jarosława Dąbrowskiego

Plan wystąpienia

- | | | | |
|----------|---------------------------|----------|--|
| 1 | Cel i główne założenia | 4 | Zbiorcze wyniki analizy |
| 2 | Metodyka i kryteria oceny | 5 | Wnioski i rekomendacje |
| 3 | Kluczowe odkrycia | 6 | Ograniczenia i kierunki dalszych badań |
-

Cel i główne założenia

CEL PROJEKTU

Autonomiczny, wieloagentowy system zarządzania flotą dronów wspierany przez LLM, realizowany w środowisku AirSim.



KLUCZOWA IDEA

LLM podejmuje decyzje operacyjne, a Java egzekwuje bezpieczeństwo i wykonanie zadań.

GŁÓWNE ZAŁOŻENIA PROJEKTU

- **Autonomiczne zarządzanie misjami**
LLM planuje i reaguje na zdarzenia.
- **Architektura wieloagentowa**
Agenci współpracują asynchronicznie.
- **Bezpieczeństwo priorytetem**
Geofencing, kontrola baterii, walidacja zadań.
- **Autonomiczne wykonanie lotu**
Planowanie trasy i zbieranie danych.
- **Inteligentna analiza danych**
AI analizuje zdjęcia i metryki.
- **Automatyczne raportowanie**
Raport PDF z wynikami misji.

ŚRODOWISKO

AirSim

FLOTA

1–4 drony

LLM

GPT-4o-mini

IMPLEMENTACJA


Java 17 + Python

RAPORTOWANIE



PDF

Autorska architektura systemu agentowego

Czytelny podział na warstwy: decyzje LLM, kontrola agentów, wykonanie misji i raportowanie.



METODYKA BADAWCZA



KRYTERIA OCENY SYSTEMU

	Skuteczność realizacji misji	METRYKA % zadań wykonanych
	Bezpieczeństwo operacji	METRYKA Liczba naruszeń = 0
	Efektywność energetyczna	METRYKA Średni poziom baterii [%]
	Czas realizacji misji	METRYKA Czas całkowity [mm:ss]
	Jakość analizy danych	METRYKA Dokładność detekcji [%]



Celem metodologii jest ocena systemu agentowego pod kątem **skuteczności**, **bezpieczeństwa**, **efektywności** oraz **jakości analizy danych** w realistycznym środowisku symulacyjnym.

Sześć najważniejszych wniosków z projektu systemu agentowego do autonomicznych misji dronów

1 LLM jako decyzje

Najpierw plan, potem wykonanie

Model językowy sprawdza kontekst, rozkłada zadanie na kroki i reaguje na zdarzenia zamiast sterować niskopoziomowo.

Polecenie

Plan

Reakcja

2 Warstwy agentowe

System łatwiejszy do kontroli

Architektura rozdziela decyzje, koordynację, wykonanie i symulację, dzięki czemu komponenty można niezależnie testować.

LLM

Java

AirSim

3 Analiza AI i raport

Dane kończą się wynikiem

Zdjęcia i metryki z misji są porządkowane, analizowane przez AI i zapisywane w raporcie PDF do oceny.

Dane

AI

PDF

4 Bezpieczeństwo

Walidacja przed ruchem

Geofencing, bateria, wykrywanie utknięcia i kontrola zadań tworzą warstwę ochronną przed niebezpiecznym wykonaniem misji.

Granice

Bateria

Walidacja

5 Autonomiczna misja

Pętla działania drona

Dron planuje trasę, wykonuje lot, zbiera dane i aktualizuje stan misji bez ręcznego prowadzenia na każdym kroku.

Trasa

Lot

Dane

6 Raport jako produkt

Wynik czytelny dla odbiorcy

Końcowy rezultat to uporządkowany raport: przebieg misji, zdjęcia, metryki, problemy i wnioski z analizy.

Zdjęcia

Metryki

Wnioski

Myśl przewodnia: autonomiczność działa tylko wtedy, gdy decyzje AI są ograniczone jasnymi warstwami kontroli i mierzalnymi kryteriami oceny.

Podsumowanie eksperymentów oraz porównanie czasu działania i kroków decyzyjnych

16/16

przebiegów

zakończonych poprawnie

3–5

kroków

decyzyjnych w sesjach

PDF

raporty


generowane poprawnie

OK

ciągłość

zachowana między sesjami

Zestawienie eksperymentów				
#	Eksperyment	Śr. kroki	Czas sesji [min / max]	Sukces
1	Monitoring	3,5	12 513 / 53 167 ms	100%
2	EVENT_REACT	3,25	4 097 / 5 260 ms	100%
3	Raport PDF	3,75	16 141 / 127 082 ms	100%
4	Pamięć kontekstowa	4,0 / 2,75	17 916 / 126 912 ms	100%



Wniosek: wszystkie przebiegi zakończyły się sukcesem, a największe różnice czasowe wynikają z raportowania PDF i pracy z pamięcią kontekstową.



WNIOSEK GŁÓWNY

Cel projektu został osiągnięty poprzez opracowanie i zweryfikowanie autonomicznego, wieloagentowego systemu zarządzania flotą dronów wspieranego przez model językowy LLM. System skutecznie realizował misje monitoringowe, reagował na zdarzenia krytyczne, generował raporty PDF oraz wykorzystywał pamięć kontekstową w środowisku symulacyjnym **AirSim**.

SYSTEM




skutecznie realizował
Misje monitoringowe



reagował na
Zdarzenia krytyczne



generował
Raporty PDF



wykorzystywał
Pamięć kontekstowa



działał poprawnie w
Środowisko AirSim

Cel dalszych prac: zwiększenie stabilności, bezpieczeństwa i skalowalności systemu oraz jego gotowości operacyjnej.

OGRANICZENIA

Środowisko symulacyjne

Testy prowadzone w AirSim, bez pełnego środowiska rzeczywistego.

Niedeterministyczny model LLM

Wyniki mogą się różnić przy podobnych poleceniach.

Zależność od usług zewnętrznych

Dostępność, limity i opóźnienia usług wpływają na system.

Testy półautomatyczne

Część scenariuszy wymagała ręcznej kontroli wyników.

Ograniczona konfiguracja sprzętowa

Prototyp testowany w ograniczonym zakresie parametrów.

Bezpieczeństwo wersji prototypowej

Mechanizmy ochrony wymagają dalszego wzmocnienia.



KIERUNEK DALSZYCH BADAŃ I ROZWOJU

Zwiększenie stabilności planowania

Ograniczenie losowości decyzji i lepsza kontrola ścieżek.

Rozbudowa testów i automatyzacji

Więcej scenariuszy testowych i automatyczne walidacje.

Automatyzacja CI/CD

Stałe testowanie, budowanie i wdrażanie kolejnych wersji.

Bardziej realistyczne środowisko

Scenariusze bliższe warunkom operacyjnym.

Skalowanie systemu

Obsługa większej liczby agentów, misji i dronów.

Wzmocnienie bezpieczeństwa

Dodatkowa walidacja zadań, geofencing i kontrola błędów.

Najważniejszy kierunek: przejście od prototypu do stabilnego i bezpiecznego systemu gotowego do szerszych testów.

Dziękuję za uwagę!
