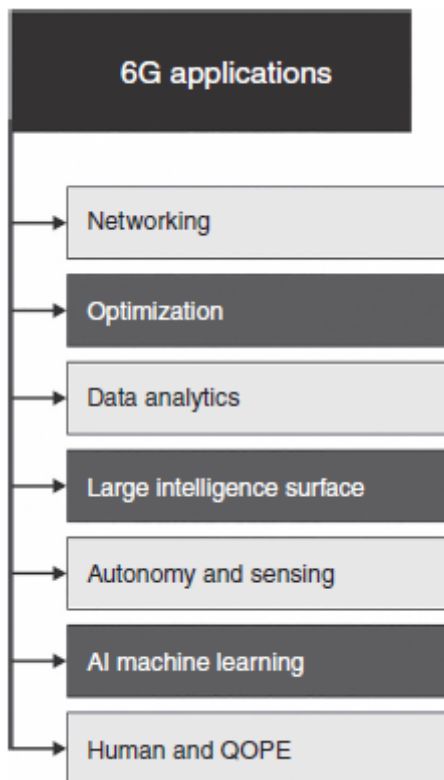


## Wstęp

Sieć bezprzewodowa szóstej generacji (6G) to rozwijająca się na całym świecie technologia sieciowa, która zapewni wszechobecną dostępność. Tę powstającą innowację opisuje kilka cech kontrastujących z wcześniejszymi osiągnięciami w zakresie sieci, takimi jak głęboka korespondencja holograficzna, sztuczna inteligencja (AI), komunikacja w świetle widzialnym, krawędź włączenia 3D oraz naziemne i eteryczne bezprzewodowe punkty skupienia dla użyteczności chmury. Jedną z najważniejszych cech jest całkowite uzależnienie od sztucznej inteligencji z jej różnymi udoskonaleniami w celu kontrolowania tak ogromnej inżynierii sieciowej. Rysunek przedstawia obszar zastosowań sieci 6G.



W ostatnich latach struktury korespondencji bezprzewodowej uległy znacznemu postępowi. Wraz z szybkim postępowaniem normalizacji etapu 2 3GPP 5G, organizacja biznesowa aplikacji 5G wysyłanych na cały świat nie jest w stanie całkowicie uporać się z trudnościami wynikającymi z szybkiego wzrostu ruchu i ciągłego warunku administracji. Z tego względu przemysł i świat naukowy uczą się obecnie i badają ramy korespondencji szóstej ery (6G). Inteligencja komputerowa, będąca cechą sztucznej inteligencji, obejmuje zachęcanie maszyn do swobodnego wykonywania zadań opartych na dokonywaniu wyborów opartych na informacjach. Inteligencja stworzona przez człowieka może precyzyjnie oceniać różne granice i wspierać inteligentny, niezależny kierunek. Badane są trudności napotymane w stosowaniu strategii sztucznej inteligencji w sieciach bezprzewodowych 6G. Wykorzystanie metod sztucznej inteligencji w ramach korespondencji bezprzewodowej 6G jest tematem, który cieszy się ostatnio dużym zainteresowaniem. Węzeł bezzałogowego statku powietrznego (UAV) składa się ze słuchawki radiowej (pełniącej rolę nadajnika i odbiorcy), mikrokontrolera oraz obwodu elektronicznego współpracującego z powiązаныmi czujnikami i źródłem energii (zwykle baterią lub zainstalowanym typem gromadzenia energii). W kilku zastosowaniach węzeł czujników żąda samoasocjacji jako konsekwencji arbitralności istniejącej w niedeterministycznych, niekontrolowanych lokalizacjach geograficznych. W zależności od koncepcji zastosowań, różne klasy węzłów czujnikowych są przystosowane do obserwacji granic, takich jak

wilgoć, temperatura, ruch artykułów i dźwięk. Ogólnie rzecz biorąc, sieci czujników rekompensują wysiłki człowieka na zablokowanych terytoriach i przedstawiają przyjemniejsze, jaśniejsze obrazy klimatu. W nowej przyszłości sieci czujników zastąpią podstawowy element ludzkiej egzystencji i sprawią, że obecny komputer PC, określone wszechstronne gadżety i reszta gadżetów rejestrujących staną się mniej znane. Żywotność sieci czujników jest ściśle zależna od zużycia energii, zwłaszcza gdy nie ma przygotowania na wejście człowieka do skomplikowanych węzłów sensorycznych. W związku z tym zaproponowano wiele technik ograniczających wykorzystanie energii w UAV. Z tego punktu widzenia projektowanie sieci UAV nastęca wiele trudności. Zarządzanie topologią jest postrzegane jako odpowiednia metoda gwarantująca stabilne, niezawodne, niezawodne i produktywne podstawy sieci w zaimprovizowanych sieciach, takich jak UAV. Klastrowanie jest jedną z najbardziej znanych metod obsługi topologii UAV. Metoda grupowania organizuje węzły w grupę skupień zwaną klastrem w świetle grupy z góry określonych środków, na przykład wspierających jakość usług (QoS), zaawansowane wykorzystanie zasobów i dostosowywanie obciążenia sieci. Klaster ma co najmniej jedną głowicę klastra (CH), który zbiera informacje z odrębnych węzłów w klastrze zwanym indywidualnym i bezpośrednio przekazuje (połączone) informacje do sygnałów binarnych (BS) lub, w domyśle, wykorzystując różne węzły zwane węzłami brokerów. Dzięki tym metodom grupowania węzeł wykorzystujący zasoby nie musi wysyłać informacji do przejść, które (zatapiają się) mogą powodować wyczerpanie energii, brak wykorzystania zasobów i przeszkody. Arafat i Moh zaprezentowali lokalizację inspirowaną biologią (BIL) i schemat grupowania (BIC) dla sieci UAV w celu wykrywania i monitorowania pożarów. Przede wszystkim opracowano hybrydowy optymalizator szarego wilka (HGWO) z energooszczędnym dwuwymiarowym schematem BIL w zależności od HGWO, aby zmniejszyć błąd lokalizacji i zwiększyć dokładność. Ma i inni zaproponowali optymalizator oparty na współrzędnych, integrujący algorytm genetyczny (GA) i podejście klastrowe w celu rozwiązywania procesów alokacji wielu zadań i planowania ścieżki. Efektywnie oblicza liczbę UAV spełniających ograniczenia i wyznacza optymalną trasę lotu w sieci UAV. Model grupowania został zaprojektowany w celu przyspieszenia mowy, przy której zbiegała się formacja wielu UAV. Biorąc pod uwagę współczynnik kontroli lotu w celu poprawy zbieżności wielu UAV, UAV tworzy stado. Aby zapewnić bezpieczną transmisję danych, opracowano hierarchiczny model wirtualnego pierścienia komunikacyjnego (HVCR). W tym badaniu przedstawiono metaheurystyczny algorytm optymalizacji płomienia ćmy na potrzeby techniki energooszczędnego klastrowania (MMFO-EEC) dla sieci UAV obsługujących 6G. Zaprezentowana technika MMFO-EEC wykorzystuje głównie algorytm MFO do skutecznego wybierania odpowiednich UAV jako kanałów CH w sieci. Poza tym technika MMFO-EEC wyprowadza funkcję dopasowania obejmującą różne parametry wejściowe w celu uzyskania lepszej wydajności sieci. Przeprowadzono szeroki zakres symulacji, aby podkreślić udoskonalenia techniki MMFOEEC, a wartości eksperymentalne sprawdzono za pomocą kilku mierników.

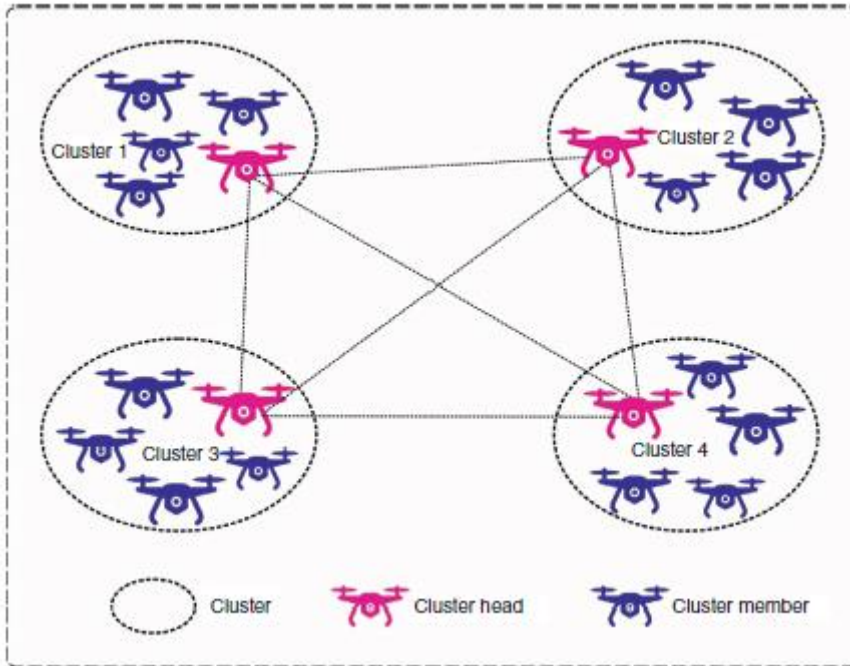
### **Proponowany model**

W tym badaniu opracowano nową technikę MMFO-EEC w celu sprawnego wyboru CH i organizacji klastrów w sieciach UAV obsługujących 6G. W prezentowanej technice MMFO-EEC zastosowano algorytm MFO w celu skutecznego wybrania odpowiednich UAV jako kanałów CH w sieci. Poza tym technika MMFO-EEC wyprowadza funkcję dopasowania obejmującą różne parametry wejściowe w celu uzyskania lepszej wydajności sieci.

### **Model sieciowy**

Założmy, że sieć UAV zawiera różne UAV. UAV wykorzystuje mniejsze i średnie drony. Co więcej, w celu uniknięcia kolizji wykorzystywana jest prosta metoda kolizyjna, polegająca na modyfikacji wysokości UAV. Ponadto UAV porusza się z prędkością 30 m/s. Każdy UAV opiera się na elemencie świadomym pozycji, a cechy metody świadomej pozycji umożliwiają dokładną i efektywną procedurę grupowania.

Ogólnie rzecz biorąc, dane o pozycji, które można uzyskać z systemu zewnętrznego, obejmują usługę globalnego pozycjonowania (GPS). Należy tutaj zauważyć, że bezwładnościowa jednostka pomiarowa i GPS służą do wykrywania lokalizacji i ruchu UAV. Każdy UAV zna swoją pozycję, pozycję stacji naziemnej i pozycję sąsiedniego UAV. Dodatkowo UAV uzbrojony jest w krótszą i dłuższą transmisję w technologii 6G. Poprzednia służy do przesyłania informacji w obrębie klastra, zwana transmisją wewnątrzklastrową, natomiast ostatnia służy do przesyłania informacji pomiędzy stacją naziemną a stacjami CH. Poza tym w transmisji mobilnej związanej z UAV celem jest wyraźna szybkość transmisji danych  $R_b$  przy wcześniej określonym podejściu modulacyjnym i kwadraturowym kluczowaniu z przesunięciem fazowym (QPSK). Rysunek przedstawia przegląd sieci UAV.



### Procedura algorytmiczna algorytmu MFO

Podejście MFO to model metaheurystyczny oparty na populacji, który symuluje zachowanie ćmy w nocy wokół płomienia. Płomień i ćmy są głównymi elementami podejścia MFO. W nocy ćma lata wokół płomienia pod pewnym kątem. Kiedy ćma zobaczy źródło światła, kontynuuje lot po linii prostej w stronę źródła światła. Kiedy ćma zbliża się do źródła światła, porusza się wokół źródła światła po spiralnej ścieżce. Ćma jest czynnikiem poszukiwawczym, a płomień jest optymalną lokalizacją ustaloną do tej pory. Zatem dla każdej populacji rozwiązaniem jest lokalizacja. Można to wyrazić w następujący sposób:

$$M = \begin{bmatrix} M_{1,1} & M_{1,d} \\ \vdots & \vdots \\ M_{n,1} & M_{n,d} \end{bmatrix} \quad (1.1)$$

Gdzie  $n$  oznacza liczbę ćmy, a  $d$  oznacza liczbę parametrów problematycznych. Macierz  $OM$  to inna macierz zapisująca wartość przydatności rozwiązania, która ilustruje poziom jakości rozwiązania

$$OM = [OM_1 \quad OM_2 \quad \dots \quad OM_n]^T \quad (1.2)$$

Co więcej, płomień jest kolejnym elementem podejścia MFO. Macierz  $F$  reprezentująca płomień jest pokazana w następujący sposób:

$$F = \begin{pmatrix} F_{1,1} & F_{1,d} \\ \vdots & \vdots \\ F_{n,1} & F_{n,d} \end{pmatrix} \quad (1.3)$$

Tutaj  $n$  charakteryzuje liczbę ciem (lub płomieni), a  $d$  wskazuje wymiar lub ilość parametrów problemu. Należy zauważyć, że wymiary macierzy  $M$  i  $F$  są sobie równoważne. Macierz  $OF$  ma wartość przydatności dla płomienia:

$$OF = [OF_1 \quad OF_2 \quad \dots \quad OF_n]^T \quad (1.4)$$

W rzeczywistości płomień i ćmy są rozwiązaniem. Wszystkie ćmy przeszukują przestrzeń wokół płomienia i wszystkie iteracje znajdują optymalne rozwiązanie, a płomień ilustruje optymalne rozwiązanie. Proces MFO wykorzystuje trzy funkcje do inicjowania dowolnych lokalizacji ćmy ( $I$ ), przesuwa ćmę w przestrzeni poszukiwań ( $P$ ) i kończy warunek wyszukiwania ( $T$ ) w następujący sposób:

$$MFO = (I, P, T) \quad (1.5)$$

Gdzie  $I$  reprezentuje funkcję inicjującą inicjalizację populacji ćmy.

$$I : \emptyset \rightarrow \{M, OM\} \quad (1.6)$$

Ponadto  $P$  reprezentuje funkcję poruszającą ćmę zgodnie z równaniem. (1.6):

$$P : M \rightarrow M \quad (1.7)$$

Ostatnią wykorzystywaną funkcją jest funkcja  $T$ . Gdy spełnione są kryteria końcowe,  $T$  zwraca True, a gdy warunek końcowy nie jest spełniony,  $T$  zwraca False w następujący sposób:

$$T : M \rightarrow \{\text{true}, \text{false}\} \quad (1.8)$$

Płomień i ćmy to elementy składowe podejścia MFO. Ćma lata po szukającej przestrzeni, a płomień wskazuje optymalną lokalizację. Ćma lata wokół płomienia i ulepsza pozycję, odkrywając optymalną lokalizację.

### Projektowanie techniki MMFO-EEC

Celem techniki MMFO-EEC jest rozdzielenie  $n$  węzłów UAV na ustaloną lub optymalną liczbę klastrów Copt. Podczas procesu grupowania sąsiedni węzeł jest przydzielany do CH poprzez odległość euklidesową, co zapewnia minimalny zasięg transmisji prowadzący do zmniejszenia energii wykorzystania. Jednak w sytuacji ekstremalnie mobilnej trudno jest znaleźć odległość. Aby rozwiązać ten problem, odległość do sąsiedniego UAV jest określana przy użyciu techniki MMFO-EEC. Aby wybrać CH i utworzyć klaster, technika MMFO-EEC traktuje problem jako problem maksymalizacji i wyprowadza funkcje przystosowania, w tym średnią odległość do sąsiednich UAV (DTN), stopień UAV (DEG) i poziom energii resztkowej (REL).

$$F(i) = \alpha \times REL + \beta \times ADTN + \gamma \times DEG, \quad (1.9)$$

Gdzie  $\alpha + \beta + \gamma = 1$ . Rozwinięcie UAV(x) w k-bitowych danych w celu otrzymania UAY(y) jest umiejscowione w odległości d w następujący sposób:

$$REL = E - (E_T(k, d) + E_{R(k)}) \quad (1.10)$$

Gdzie E oznacza istniejącą poziom energii UAV, a ET pokazuje energię zużytą na przesłanie informacji.

$$E_T(k, d) = kE_e + KE_a d^2 \quad (1.11)$$

Tutaj  $E_e$  oznacza energię elektronu,  $E_a$  oznacza ważną wzmocnioną energię, a  $E_{R(k)}$  pokazuje energię wydatkowaną na odbiór danych w następujący sposób:

$$E_{R(k)} = kE_e \quad (1.12)$$

Ponadto zaawansowana sieć tolerująca depay (ADTN) oznacza normalną wartość odległości sąsiednich UAV w zasięgu transmisji 1-skoku

$$ADTN = \frac{\sum_{j=1}^{NB_i} dist(i, nb_j)}{NB_i}, \quad (1.13)$$

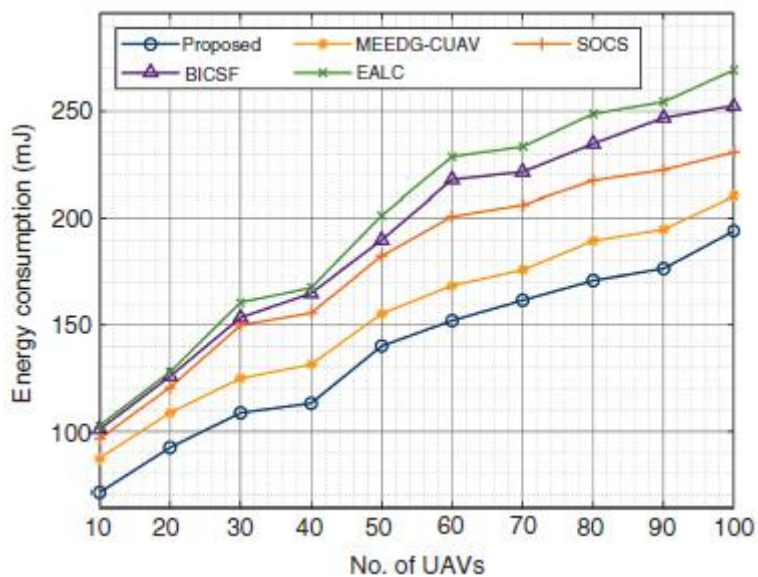
Natomiast  $dist(i, nb_j)$  pokazuje odległość od UAV do bliższego j-tego UAV. W czasie t DEG charakteryzuje stopień UAV wskazując ilość sąsiadujących węzłów istniejących dla UAV,

$$DEG = |N(x)| \quad (1.14)$$


Tutaj  $N(x) = \{ny/dist(x, y) < trans_{range}\}x \neq y$ , a  $dist(x, y)$  oznacza odległość między dwoma UAV  $n_x$  i  $n_y$ ,  $trans_{range}$  oznacza zasięg nadawania UAV.

### Walidacja eksperymentalna

Analiza wyników eksperymentalnych modelu MMFO-EEC została sprawdzona przy różnej liczbie UAV. Rysunek przedstawia analizę porównawczą modelu MMFO-EEC z najnowszymi metodami w różnych UAV. Wyniki wykazały, że model MMFO-EEC osiągnął model najmniejszego wychwytywania energii (ECM) w porównaniu z istniejącymi podejściami. Na przykład przy 10 UAV model MMFO-EEC uzyskał minimalną ECM wynoszącą 71,21 mJ, podczas gdy modele MEEDG-CUAV, SOCS, BICSF i EALC osiągnęły maksymalną ECM odpowiednio 87,32, 96,47, 96,47 i 100,87 mJ. Co więcej, przy 20 UAV model MMFO-EEC osiągnął niższy ECM wynoszący 92,32 mJ, podczas gdy modele MEEDG-CUAV, SOCS, BICSF i EALC osiągnęły wyższą ECM wynoszącą odpowiednio 108,68, 120,63, 125,81 i 127,82 mJ. Co więcej, przy 100 UAV model MMFO-EEC uzyskał najmniejszą ECM wynoszącą 194,13 mJ, podczas gdy modele MEEDG-CUAV, SOCS, BICSF i EALC osiągnęły zwiększoną ECM odpowiednio 210, 230,63, 252,57 i 269,40 mJ.

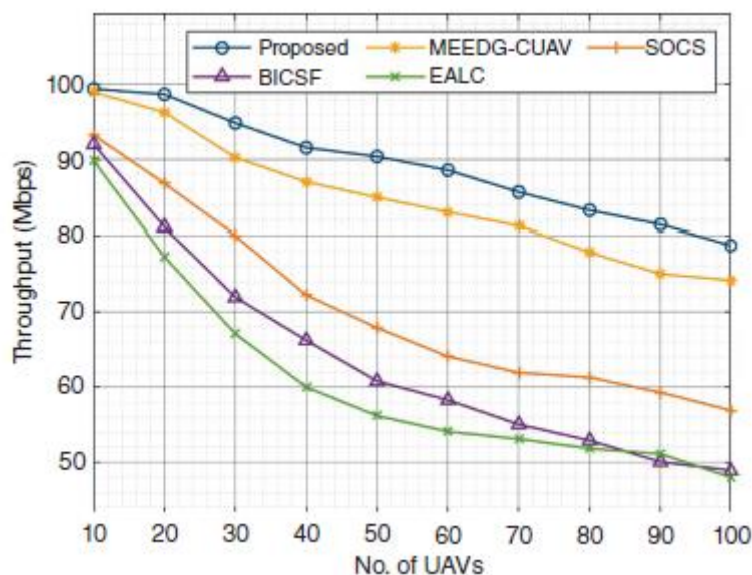


Rysunek przedstawia kompleksowe badanie NWLT MMFO-EEC z istniejącymi technikami w różnych UAV. Wartości eksperymentalne wykazały, że model MMFO-EEC zaowocował ulepszonym NWLT w porównaniu z istniejącymi podejściami. Na przykład w przypadku 10 UAV model MMFO-EEC wykazał zwiększony NWLT wynoszący 5990 naboju, podczas gdy modele MEEDG-CUAV, SOCS, BICSF i EALC uzyskały zmniejszony NWLT wynoszący odpowiednio 5920, 5570, 5520 i 5330 naboju. Poza tym, przy 20 UAV, model MMFO-EEC osiągnął zwiększony NWLT wynoszący 5960 naboju, podczas gdy modele MEEDG-CUAV, SOCS, BICSF i EALC osiągnęły zmniejszony NWLT wynoszący odpowiednio 5810, 5520, 5290 i 5150 naboju. Dodatkowo, przy 100 UAV, model MMFO-EEC uzyskał ulepszony NWLT wynoszący 4520 naboju, podczas gdy modele MEEDG-CUAV, SOCS, BICSF i EALC zaowocowały ulepszonym NWLT wynoszącym odpowiednio 4160, 3550, 3380 i 3280 naboju. Tabela 1 i Rysunek ilustrują szczegółowe badanie terapeutyczne (THRP) modelu MMFO-EEC z wykorzystaniem istniejących technik w różnych UAV.





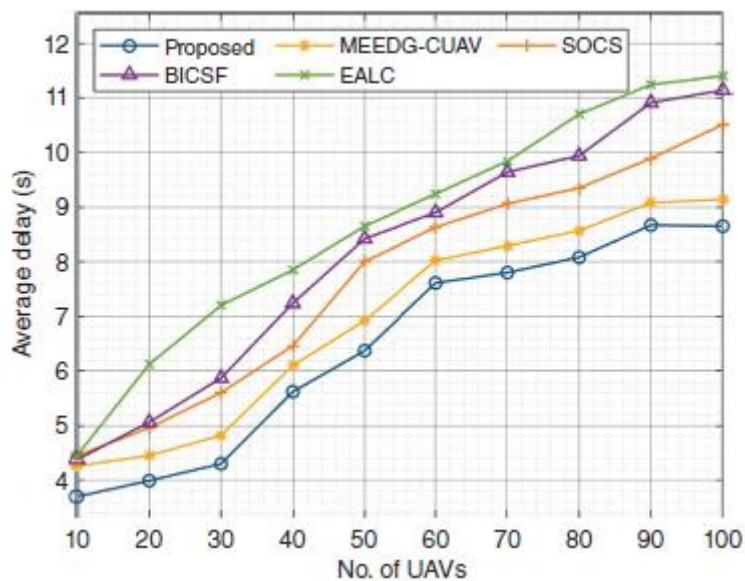
No. of UAVs	Throughput (Mbps)				
	Proposed	MEEDG-CUAV	SOCS	BICSF	EALC
10	99.33	98.90	93.21	91.98	89.81
20	98.61	96.21	86.80	81.09	77.22
30	94.81	90.24	79.98	71.92	67.09
40	91.54	87.02	72.20	66.22	60.00
50	90.36	84.95	67.88	60.80	56.20
60	88.56	83.04	64.08	58.29	54.11
70	85.66	81.22	61.93	55.06	53.11
80	83.26	77.82	61.29	52.92	51.86
90	81.40	74.98	59.30	50.08	51.14
100	78.73	74.14	56.90	48.93	48.01



Wartości eksperymentalne wykazały, że model MMFO-EEC zaowocował zwiększonym THRP w porównaniu z istniejącymi podejściami. Na przykład w przypadku 10 UAV model MMFO-EEC wykazał zwiększoną THRP o 99,33 Mb/s, podczas gdy modele MEEDG-CUAV, SOCS, BICSF i EALC uzyskały obniżoną THRP o odpowiednio 98,90, 93,21, 91,98 i 89,81 Mb/s. Poza tym, przy 20 UAV, model MMFO-EEC osiągnął zwiększoną THRP o 98,61 Mb/s, podczas gdy modele MEEDG-CUAV, SOCS, BICSF i EALC osiągnęły obniżoną THRP o odpowiednio 96,21, 86,80, 81,09 i 77,22 Mb/s. Dodatkowo, przy 100 UAV, model MMFO-EEC uzyskał lepszą THRP wynoszącą 78,73 Mb/s, podczas gdy modele MEEDG-CUAV, SOCS, BICSF i EALC zaowocowały zwiększoną THRP wynoszącą odpowiednio 74,14, 56,90, 48,93 i 48,01 Mb/s. Tabela 2 i rysunek przedstawiają badanie porównawcze średniego opóźnienia (ADE) modelu MMFO-EEC z najnowszymi metodami w różnych UAV. Wyniki wykazały, że model MMFO-EEC osiągnął najmniej ADE w porównaniu z istniejącymi podejściami. Na przykład przy 10 UAV model MMFO-EEC uzyskał minimalny ADE wynoszący 3,70 sekundy, podczas gdy modele MEEDG-CUAV, SOCS, BICSF i EALC mają osiągnął maksymalny ADE wynoszący odpowiednio 4,26, 4,45, 4,38 i 4,46 sekundy. Co więcej, przy 20 UAV model MMFO-EEC osiągnął niższy ADE wynoszący 3,99 sekundy, podczas gdy

modele MEEDG-CUAV, SOCS, BICSF i EALC osiągnęły wyższy ADE wynoszący odpowiednio 4,45, 4,96, 5,06 i 6,12 sekundy. Co więcej, przy 100 UAV model MMFOEEC uzyskał najmniejszy ADE wynoszący 8,65 sekundy, podczas gdy modele MEEDG-CUAV, SOCS, BICSF i EALC osiągnęły zwiększone ADE odpowiednio o 9,14, 10,51, 11,14 i 11,40 sekundy.

No. of UAVs	Average delay (s)				
	Proposed	MEEDG-CUAV	SOCS	BICSF	EALC
10	3.70	4.26	4.45	4.38	4.46
20	3.99	4.45	4.96	5.06	6.12
30	4.30	4.82	5.60	5.87	7.20
40	5.62	6.10	6.46	7.24	7.85
50	6.37	6.92	8.00	8.42	8.65
60	7.61	8.02	8.63	8.90	9.24
70	7.80	8.29	9.06	9.64	9.84
80	8.08	8.57	9.35	9.94	10.70
90	8.67	9.08	9.89	10.91	11.24
100	8.65	9.14	10.51	11.14	11.40



## Wniosek

W tym badaniu opracowano nową technikę MMFO-EEC w celu sprawnego wyboru CH i organizacji klastrów w UAV obsługującym sieci 6G. W prezentowanej technice MMFO-EEC zastosowano algorytm MFO w celu skutecznego wybrania odpowiednich UAV jako CH w sieci. Poza tym technika MMFO-EEC wyprowadza funkcję dopasowania składającą się z odrębnych parametrów wejściowych w celu osiągnięcia lepszej wydajności sieci. Przeprowadzono szeroki zakres symulacji, aby podkreślić ulepszenia techniki MMFO-EEC, a wartości eksperymentalne wykazały lepszą wydajność techniki MMFO-EEC w porównaniu z najnowszymi podejściami. Dlatego technikę MMFO-EEC można



zastosować jako sprawne narzędzie w sieciach UAV obsługujących 6G. W przyszłości w kanałach CH można będzie uwzględnić schematy agregacji danych w celu poprawy wydajności sieci.