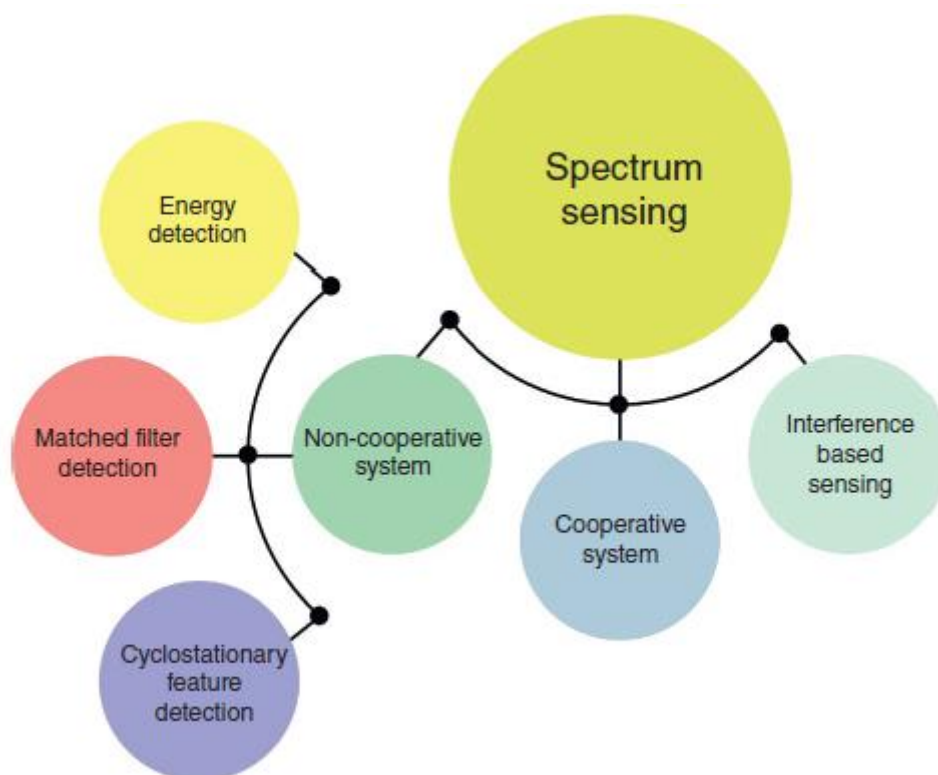


## Efektywna optymalizacja polowań na jelenie .Metoda wykrywania widma oparta na algorytmie w sieciach komunikacyjnych 6G

### Wstęp

Generacja technologii w komunikacji bezprzewodowej odgrywa ważną rolę w zapewnieniu użytkownikom minimalnych opóźnień i dużej szybkości transmisji danych . Oczekuje się, że rozwój 5G w dużym stopniu wpłynie na nadzór widma, bezpieczeństwo publiczne, wysokie szybkości transmisji danych i efektywność energetyczną . Internet rzeczy (IoT) jest centrum technik 5G i 6G. Dlatego też urządzenia oparte na IoT odgrywają główną rolę w ramach systemów sieciowych 5G i 6G . Przewiduje się, że system 6G rozwiąże ograniczenia sieci 5G. Umożliwiają użytkownikom realizację żądań przy niskim opóźnieniu, dużej przepustowości i dużej pojemności. Sieć 6G wymaga efektywnego wykorzystania widma w celu zaspokojenia potrzeb użytkowników. Dlatego sieć 6G musi wykorzystywać nowe techniki, takie jak radia kognitywne (CR). Zatem ogromny rozwój technologii bezprzewodowej i liczba urządzeń żądają nowych usług bezprzewodowych w niewykorzystanych i wykorzystywanych częściach widma radiowego. W tym kontekście wykrywanie widma (SS) zostało zalegalizowane przez Federalną Komisję ds. Komunikacji (FCC) [5]. Wykorzystanie CR w transmisji bezprzewodowej zapewnia wystarczający intelekt przy efektywnym wykorzystaniu widma radiowego, który dostosowuje i uczy się parametrów urządzenia transmisyjnego [6]. Użytkownik główny (PU) jest upoważniony w kognitywnej sieci radiowej (CRN) do dostępu do widma, natomiast użytkownik dodatkowy (SU) jest oportunistą w zakresie dostępu do widma PU. SU musi ewakuować widmo po przybyciu PU, aby zapobiec interwencji z prawdziwym PU. Niepewność w sieci bezprzewodowej, tj. problem z ukrytym terminalem, blaknięciem i cieniowaniem, ogranicza wydajność zmysłów użytkownika. Rysunek przedstawia klasyfikację metod SS.



Jako potencjalne rozwiązanie problemu brane jest pod uwagę wspólne wykrywanie widma (CSS). W CSS użytkownik zgłasza i przekazuje odkrycie do centrum syntezy jądrowej (FC) . Jednak kluczowym

wyzwaniem w decyzji CSS jest zidentyfikowanie raportu złych użytkowników (MU), w ramach którego FC przekazuje fałszywe dane w związku z przejęciem decyzji FC. Wraz z popularyzacją mobilnych urządzeń przenośnych użytkownicy PU i CR (SU) mają nieograniczone możliwości korzystania z urządzeń stacjonarnych. W wielu przypadkach główny użytkownik ma mobilność, a mianowicie miejskie mobilne stacje bazowe i pojazdy kognitywne, przy czym konwencjonalne systemy SS nie sprawdzają się dobrze. Mobilność PU powoduje zmianę położenia. W konsekwencji zdolność wyczuwania PU różni się w czasie. Mobilność PU prowadzi do błędnych informacji odczytowych. Aby wykryć mobilny PU, SU musi przejść do zasięgu sygnału PU, który powinien zależeć od zmierzonej siły odbieranego sygnału (RSS). Niewiele CR śledzi PU za pomocą techniki pozycjonowania innej firmy. Do rozwiązania tego problemu wykorzystuje się wiele skutecznych podejść, teorię gier, uczenie maszynowe (ML) i optymalizację wypukłą. Alternatywą jest inteligencja roju (SI), zestaw sztucznej inteligencji (AI), który był szeroko i ostatnio stosowany z niezwykłą wydajnością. Optymalne wykorzystanie i organizacja dostępnego widma są ważne dla zwiększenia wydajności sieci. Dlatego w artykule przedstawiono nowatorskie, wydajne podejście do optymalizacji polowań na jelenie oparte na algorytmie wykrywania widma (EDHO-SSA) dla sieci komunikacyjnych 6G. Zaprezentowana technika EDHO-SSA ma na celu głównie zarządzanie dostępnością widm występujących w sieciach 6G. Technika EDHO-SSA opiera się na łowickim charakterze jeleniowatych. Wyprowadza również funkcję celu określającą wydajność SS, w tym różne parametry, takie jak energia i przepustowość. Przeprowadza się analizę wyników eksperymentalnych techniki EDHO-SSA, a wyniki ocenia się w oparciu o różne mierniki.

### **Powiązane prace**

W pracy Eappena i Shankara zaprezentowano nowe, wielocelowe podejście do zmodyfikowanego optymalizatora szarego wilka (MOMGWO) w celu rozwiązania wielocelowego zoptymalizowanego problemu z domeny SS z CRN, który jest istotnym paradygmatem technologii komunikacji bezprzewodowej. Modyfikację w GWO przeprowadzono w celu zrównoważenia kompromisu pomiędzy procedurą poszukiwawczą i eksploatacyjną w stosunku do konwencjonalnego GWO w celu uzyskania globalnego maksimum. Chena i inni zbadali nową metodę zwaną agentem CSS opartym na optymalizacji roju cząstek (PSO). Podczas tej metody może wykorzystywać kilka agentów mobilnych rozproszonych w sieciach, dla CSS, a nie SU. Każdy agent jest przenoszony w oparciu o najnowszy globalny optymalny agent o równoważnym docelowym PU z funkcją przystosowania (FF) obliczoną przez zmodyfikowany PSO. W Tekbiyik i inni, przedstawiono metodę konwolucyjnej sieci neuronowej (CNN) wykorzystującą funkcję korelacji widmowej (SCF), czyli efektywną klasyfikację właściwości cyklostacjonarności, bezprzewodowej SS i tożsamości sygnału. Przedstawiona technika klasyfikuje sygnał bezprzewodowy bez wcześniejszych danych i może być stosowana z dwóch różnych ustawień, nazwanych CASE1 i CASE2. Sheng i inni zaproponowali skuteczny ślad macierzy kowariancji i wariancji kwadratowej macierzy kowariancji z podejściem maszyny wektorów nośnych (TCVQ-SVM) zależnym od ML do wąskopasmowego SS. Przede wszystkim wyodrębniono ślad macierzy kowariancji i wariancji kwadratowej macierzy kowariancji (TCVQ) jako wektor cech i zintegrowano z wyszkoloną instancją SS. Następnie metodę klasyfikacji osiągnięto poprzez szkolenie instancji zależnych od SVM, które pozwala uniknąć ustawiania progu i zmiany hiperpłaszczyzny klasyfikatora poprzez jego zdolności do samouczenia się. Chena i inni przedstawili metodę łączenia z maksymalnym współczynnikiem łączenia/formowania wiązki z wymuszeniem zerowym (MRC/ZFB) obsługiwaną przez przełącznik, aby zagwarantować tajną wydajność komunikacji krótkich pakietów z podwójnym przeskokiem z kognitywnego Internetu Rzeczy. W tej pracy zbadano średnią przepustowość modelu w zakresie poufności i zbadano dwie asymptotyczne sytuacje z wyższymi reżimami stosunku sygnału do szumu (SNR) i nieskończoną długością bloku. Eappen i inni wykorzystali niewykorzystane widmo przełącznika CR obsługiwanego przez przełącznik CR. Komunikacja między urządzeniami (D2D) ma na celu

zwiększenie przepustowości sieci (szybkości transmisji danych) sprzętu użytkownika (UE)/licencjonowanego użytkownika (LU), czyli obszaru blokady sieci do sieci bezprzewodowej. system zdalnego monitorowania pacjenta (PMS). CR dopuszczony przez zmodyfikowany algorytm optymalizacji wieloryba (WOA) (MWOA) został przedstawiony efektywnemu SS.

### Proponowany model

W artykule opracowano nową technikę EDHO-SSA dla optymalnego SS w sieciach komunikacyjnych G. Zaprezentowana technika EDHO-SSA prawidłowo zarządza dostępnością widm występujących w sieciach 6G. Technika EDHO-SSA opiera się na łowickim charakterze jelenia. Wyprowadza również funkcję celu określającą wydajność SS, w tym różne parametry, takie jak energia i przepustowość. Metaheurystyczne podejście DHO inicjuje zbiór zwany myśliwym, czyli zbiór dowolnych populacji, wyznaczany przez:

$$Z = \{y_1, y_2, \dots, y_n\}, \quad 1 < j \leq n, \quad (7.1)$$

Gdzie rodzaje rozwiązań lub liczba myśliwych są reprezentowane jako n. Z oznacza również ogólną populację myśliwych. Następna faza obejmuje ilościowe określenie głównego składnika, kąta wiatru i lokalizacji jelenia. Przestrzeń jest brana pod uwagę jako okrąg. Zatem kąt wiatru jest przeformułowany jako:

$$\theta_j = 2\pi\alpha, \quad (7.2)$$

Gdzie  $\alpha$  oznacza dowolną liczbę w  $\{0, 1\}$ , a j określa istniejącą iterację. Podobnie kąt ustawienia jelenia jest określony przez:

$$\phi_j = \pi + \beta. \quad (7.3)$$

W tym wzorze  $\beta$  wskazuje kąt wiatru. W początkowej iteracji znalezienie optymalnego rozwiązania dla danego podejścia może być generalnie niemożliwe. Jednak po utworzeniu dowolnej liczby i wyznaczeniu z niej funkcji kosztu, jako optymalne rozwiązanie bierze się pod uwagę liczbę optymalną. Rozważmy teraz dwie zmienne, obejmujące lokalizację następcy (Z) jako następną pozycję myśliwego i lokalizację lidera (Z) jako pierwszą optymalną pozycję myśliwego. Aby uzyskać optymalne miejsce przy powtórzeniu pierwotnym, cała populacja stara się osiągnąć optymalne miejsce, ulepszając pozycję:

$$Z_{j+1} = Z_L - k \times S^w \times |L \times Z_L - Z_j|. \quad (7.4)$$

Teraz  $Z_j$  i  $Z_{j+1}$  wskazują istniejące i późniejsze pozycje,  $S^w$  wskazuje dowolną liczbę zależną od prędkości wiatru w granicach  $[0, 2]$ , a wektor współczynników jest reprezentowany jako L i k:

$$k = 0.25 \times \log \left( I + \frac{1}{I_{\max}} \right) \gamma, \quad (7.5)$$

$$L = 2 \times \delta, \quad (7.6)$$

Gdzie  $I_{\max}$  oznacza szczyt powtórzenia w obrębie  $[-1, 1]$ , a  $\gamma$  oznacza element dowolny.  $\delta$  oznacza dowolną liczbę z zakresu od 0 do 1. W przypadku ulepszenia lokalizacji  $Z^*$ , gdzie (Z, Y) wskazuje główną pozycję myśliwego, która jest ulepszana w zależności od pozycji ofiary. Podwyższony status byłby trwały do osiągnięcia stanu optymalnego ( $Z^*, Y^*$ ) zgodnie z L i K. Myśliwy udaje się do miejsca, w którym znajduje się przywódca. Gdy ruchy lidera nie przyniosły skutku, myśliwy pozostaje w poprzedniej

lokalizacji. Ulepszanie lokalizacji opiera się na równaniu. (7.6), jeśli  $S^w < 1$ . W rzeczywistości myśliwy porusza się w każdym kierunku, niezależnie od kąta położenia. W związku z tym, w oparciu o równania. (7.6) i (7.7) myśliwy ulepsza lokalizację we wszystkich dowolnych lokalizacjach. Rozszerz także przestrzeń metody rozwiązywania, przyjmując kąt położenia. Obliczenie kąta jest istotne dla określenia lokalizacji myśliwego. Dlatego skuteczny atak nie powinien być zauważalny dla ofiary. Wizualizacja równania kąta jelenia (ofiary) jest podana w następujący sposób:

$$u_j = \frac{1}{8} \times \pi \times \alpha. \quad (7.7)$$

Ze względu na różnicę między kątem wiatru a kątem, pod którym widzi się ofiarę,  $u$  oznacza zmienną braną pod uwagę przy aktualizacji kąta położenia:

$$C_j = \beta_j - u_j, \quad (7.8)$$

gdzie  $\beta$  oznacza kąt wiejącego wiatru. Następnie, aby zaktualizować zmienną kąta lokalizacji,

$$\phi_{j+1} = \phi_j + C_j. \quad (7.9)$$

Po osiągnięciu kąta położenia szacuje się nowe położenie przez:

$$Z_{j+1} = Z_j - S^w \times \left| \cos(\phi_{j+1}) \times Z_l - Z_i \right|. \quad (7.10)$$

Ofiara nie widzi myśliwego ze względu na kąt widzenia. Aby wykorzystać eksplorację, prawdopodobnie zmieni się  $L$  podczas wykonywania okrążenia. Na podstawie arbitralnych poszukiwań liczba wektorów  $L$  nie mogła być uznana za większą niż 1.

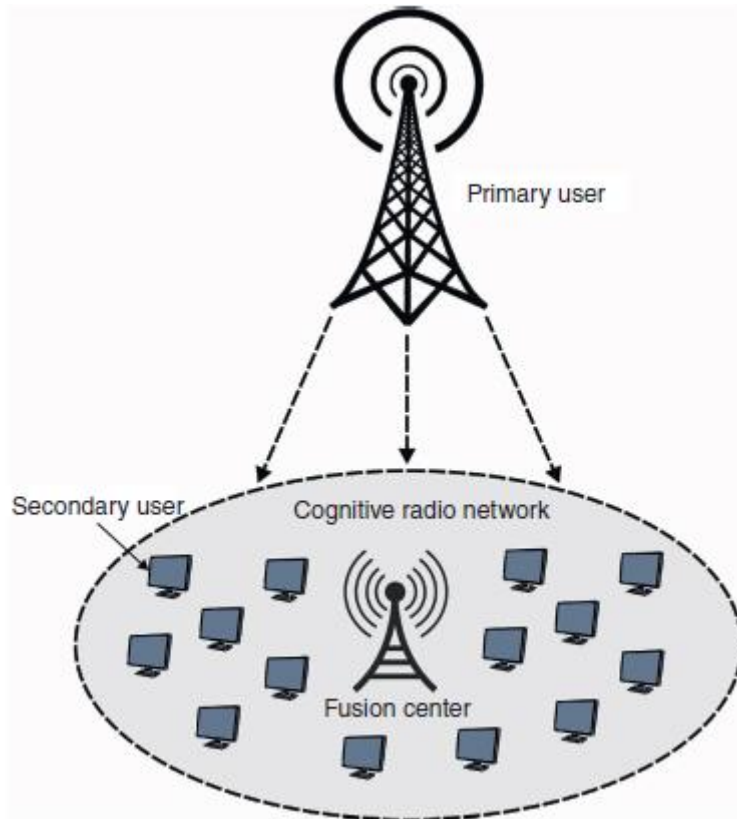
$$Z_{j+1} = Z_s - k \times S^w \times |L \times Z_L - Z_j|, \quad (7.11)$$

Gdzie  $Z_s$  oznacza następcę myśliwego w dowolnym momencie. Tutaj pozycja myśliwego jest poprawiana poprzez optymalne rozwiązanie we wszystkich powtórzeniach. Optymalne rozwiązanie uzyskuje się, gdy  $L \geq 1$ . Gdy  $L < 1$ , jeden z łowców jest wybierany arbitralnie. Technika ta generuje przełącznik  $L$ , który może dostosować sposób podejścia pomiędzy fazami eksploatacji i eksploracji. CRN obejmuje SU obecne w podobnym położeniu geograficznym i ma podobne spektrum [19]. Ramka czasowa ( $T^p$ ) CRN jest podzielona na dwie szczeliny czasowe w następujący sposób: Pierwsza szczelina czasowa to SS reprezentowana jako  $t^s$ , a następną to transmisja danych scharakteryzowana przez  $t^p$ . Hipotezy dla problemu SS przy  $j=1, \dots, n^s$  liczbie użytkowników wtórnych,  $t = 1, \dots, n^{sc}$  liczbie podnośnych i indeksie czasu  $i = 1, 2, \dots, k_j$  wyraża się następująco:

$$H_{10}: y_{j,i}(i) = w_{j,i}(i) \{Hypotheses 0 (PU Absent)\} \quad (7.12)$$

$$H_{11}: y_{j,i}(i) = S_{j,i}(i) + w_{j,i}(i) \{Hypotheses 1 (PU Present)\}$$

Rysunek ilustruje SS w CRN.



Teraz  $H_{10}$  oznacza Hipotezę 0 dla  $l$ -tej podnośnej, która reprezentuje nieobecność sygnału PU, a  $H_{11}$  przedstawia Hipotezę 1 dla  $l$ -tej podnośnej wskazującą na istnienie PU;  $w_{j,l}$  oznacza biały szum mający rozkład Gaussa przy użyciu średniego zera i wariancji  $\sigma_{j,l}^2$ .  $S_{j,l}$  oznacza główną sygnalizację analogiczną do stacjonarnej procedury arbitralnej ze średnią zerową i wariancją  $\sigma_{S_{j,l}}^2$ . Częstotliwość próbkowania i czas wykrywania dla  $j$ -tego SU są oznaczone odpowiednio przez  $f_j^s$  i  $t_j^s$ ; wówczas liczbę instancji można przedstawić za pomocą  $k_j = f_j^s t_j^s$ . Regułę decyzyjną dotyczącą struktury Neymana-Pearsona opartą na detekcji energii dla  $j$ -tego SU na  $l$ -tej podnośnej oszacowano za pomocą:

$$E_{j,l}^n = \frac{1}{k_j} \sum_{i=1}^{k_j} |y_{j,l}(i)|^2 \quad | 2H_{11} > \lambda_{j,l} < H_{10} \quad (7.13)$$

$$E_{j,l}^n | H_{lr} \sim N\left(\mu_{j,l|r}, \sigma_{j,l|r}^2 / k_j\right) \quad (7.14)$$

gdzie  $r = 0, 1$  w oparciu o hipotezę i wykrycie energii dla odrębnej hipotezy i większej wartości  $k_j$  ma rozkład standardowy ze średnią i wariancją odpowiednio jako  $\mu_{j,l|r}, \sigma_{j,l|r}^2$ .

$$\mu_{j,l|r} = \begin{cases} \sigma_{j,l}^2 & \text{if } r = 0 \\ \sigma_{S_{j,l}}^2 + \sigma_{j,l}^2 & \text{if } r = 1 \end{cases} \quad (7.15)$$

i

$$\sigma_{j,l|r}^2 = \begin{cases} \sigma_{j,l}^4 & \text{for } r = 0 \\ E|S_{j,l}|^4 + 2\sigma_{j,l}^2 - (\sigma_{S_{j,l}}^2 - \sigma_{j,l}^2)^2 & \text{for } r = 1 \end{cases} \quad (7.16)$$

Biorąc pod uwagę sygnał PU jako gaussowski, powyższe równanie zostaje przeformułowane w następujący sposób:

$$\sigma_{j,l|r}^2 = \begin{cases} \sigma_{j,l|r}^4 & \text{for } r = 0 \\ (\sigma_{S,j}^2 + \sigma_{j,l}^2) & \text{for } r = 1 \end{cases} \quad (7.17)$$

biorąc pod uwagę powyższe, prawdopodobieństwo wykrycia i prawdopodobieństwo fałszywego alarmu szacuje się poprzez:

$$\text{prob } f_{j,l}(\lambda_{j,l}, t_j^s) = Q\left(\sqrt{t_j^{sfs}} \frac{\lambda_{j,l} - \mu_{j,l|0}}{\sigma_{j,l|0}}\right) \quad (7.18)$$

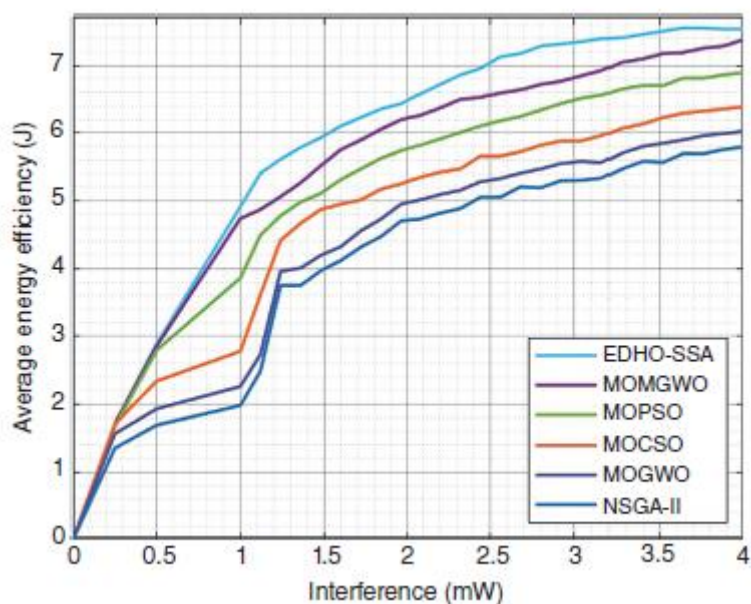
$$\text{prob } d_{j,l}(\lambda_{j,l}, t_j^s) = Q\left(\sqrt{t_j^{sfs}} \frac{\lambda_{j,l} - \mu_{j,l|1}}{\sigma_{j,l|1}}\right) \quad (7.19)$$

### Walidacja eksperymentalna

W tej sekcji dokonano sprawdzenia walidacji działania techniki EDHO-SSA w porównaniu z innymi istniejącymi technikami. Tabela i Rysunek przedstawiają średnią efektywność energetyczną (AEE) techniki EDHO-SSA z innymi metodami przy różnym poziomie zakłóceń.

Average energy efficiency ( $\eta$ )

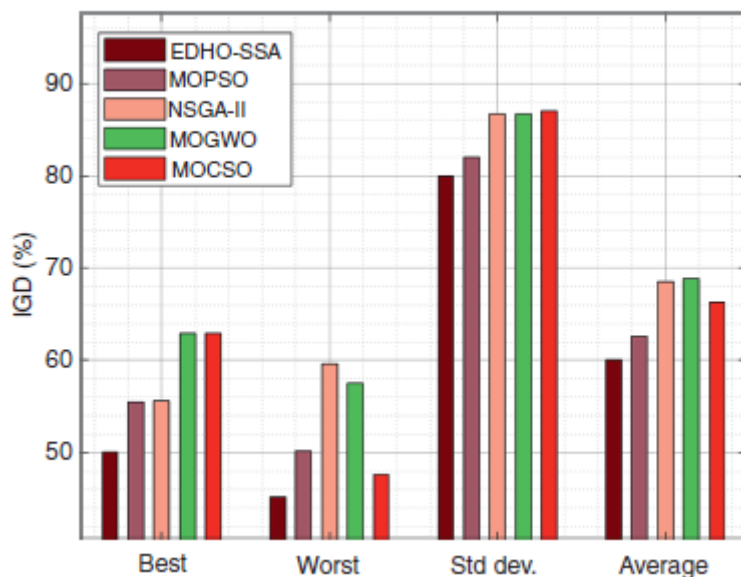
| Interference (mW) | EDHO-SSA | MOMGWO | MOPSO  | MOCSSO | MOGWO  | NSGA-II |
|-------------------|----------|--------|--------|--------|--------|---------|
| 0                 | 0.0000   | 0.0000 | 0.0000 | 0.0000 | 0.0000 | 0.0000  |
| 0.25              | 1.6923   | 1.7081 | 1.6766 | 1.7081 | 1.5663 | 1.3513  |
| 0.50              | 2.8893   | 2.8578 | 2.7948 | 2.3381 | 1.9286 | 1.6906  |
| 1.00              | 4.9130   | 4.7398 | 3.8610 | 2.7790 | 2.2593 | 1.9783  |
| 1.12              | 5.4092   | 4.8737 | 4.4957 | 3.6138 | 2.7318 | 2.4848  |
| 1.24              | 5.6139   | 5.0627 | 4.7792 | 4.4170 | 3.9602 | 3.7512  |
| 1.36              | 5.7872   | 5.2675 | 4.9840 | 4.6690 | 4.0075 | 3.7515  |
| 1.48              | 5.9289   | 5.5194 | 5.1100 | 4.8737 | 4.1965 | 3.9675  |
| 1.60              | 6.1022   | 5.7557 | 5.3147 | 4.9525 | 4.3225 | 4.1195  |
| 1.72              | 6.2282   | 5.8974 | 5.4722 | 5.0155 | 4.5587 | 4.3177  |
| 1.84              | 6.3542   | 6.0549 | 5.6297 | 5.1730 | 4.7320 | 4.4730  |
| 1.96              | 6.4329   | 6.1967 | 5.7399 | 5.2517 | 4.9525 | 4.7035  |
| 2.08              | 6.5747   | 6.2597 | 5.8187 | 5.3462 | 5.0155 | 4.7325  |
| 2.20              | 6.7164   | 6.3699 | 5.9132 | 5.4249 | 5.0942 | 4.8202  |
| 2.32              | 6.8581   | 6.4959 | 6.0077 | 5.4722 | 5.1572 | 4.8862  |
| 2.44              | 6.9526   | 6.5274 | 6.1022 | 5.6612 | 5.2832 | 5.0542  |
| 2.56              | 7.1259   | 6.5904 | 6.1809 | 5.6612 | 5.3304 | 5.0544  |
| 2.68              | 7.1731   | 6.6377 | 6.2439 | 5.7242 | 5.4092 | 5.2082  |
| 2.80              | 7.2834   | 6.7164 | 6.3384 | 5.8187 | 5.4722 | 5.1942  |
| 2.92              | 7.3149   | 6.7637 | 6.4329 | 5.8817 | 5.5509 | 5.2969  |
| 3.04              | 7.3464   | 6.8424 | 6.5117 | 5.8817 | 5.5824 | 5.3044  |
| 3.16              | 7.3936   | 6.9211 | 6.5589 | 5.9604 | 5.5667 | 5.3347  |
| 3.28              | 7.4094   | 7.0471 | 6.6534 | 6.0707 | 5.7084 | 5.4774  |
| 3.40              | 7.4566   | 7.0944 | 6.7007 | 6.1337 | 5.8029 | 5.5839  |
| 3.52              | 7.5039   | 7.1731 | 6.7007 | 6.2282 | 5.8502 | 5.5702  |
| 3.64              | 7.5511   | 7.1889 | 6.8109 | 6.2912 | 5.8974 | 5.6954  |
| 3.76              | 7.5511   | 7.2519 | 6.8109 | 6.3227 | 5.9604 | 5.6944  |
| 3.88              | 7.5354   | 7.2834 | 6.8581 | 6.3542 | 5.9919 | 5.7559  |
| 4.00              | 7.5354   | 7.3779 | 6.8896 | 6.3857 | 6.0234 | 5.7964  |



Wyniki wykazały, że model EDHO-SSA spowodował zwiększenie AEE w porównaniu z innymi metodami przy wszystkich poziomach zakłóceń. Na przykład przy interferencji 0,50 mW model EDHOSSA zapewnił wyższy AEE wynoszący 2,8893 J, podczas gdy MOMGWO, wieloobiektowa optymalizacja roju cząstek (MOPSO), wieloobiektowa optymalizacja wyszukiwania kukułki (MOCSO), wieloobiektowa optymalizacja szarego wilka (MOGWO) i nie Model algorytmu genetycznego opartego na dominacji (NSGA-II) oferują niższy AEE wynoszący odpowiednio 2,8578, 2,7948, 2,3381, 1,9286 i 1,6906 J. Ponadto przy zakłóceniach o mocy 1,60 mW metoda EDHO-SSA oferuje maksymalne AEE wynoszące 0,1022 J, podczas gdy podejścia MOMGWO, MOPSO, MOCSO, MOGWO i NSGA-II oferują niższe AEE wynoszące 5,7557, 5,3147, 4,9525, 4,3225 i Odpowiednio 4,1195 J. Oprócz tego, przy zakłóceniach o mocy 2,20 mW, system EDHO-SSA zapewnił wyższe AEE wynoszące 6,7164 J, podczas gdy modele MOMGWO, MOPSO, MOCSO, MOGWO i NSGA-II oferują niższe AEE wynoszące 6,3699, 5,9132, 5,4249, 5,0942 i Odpowiednio 4,8202 J. Co więcej, przy zakłóceniach o mocy 3,04 mW, system EDHO-SSA zapewnił wyższe AEE wynoszące 7,3464, podczas gdy modele MOMGWO, MOPSO, MOCSO, MOGWO i NSGA-II oferują niższe AEE wynoszące odpowiednio 6,8424, 6,5117, 5,8817, 5,5824 i 5,3044 J. Wreszcie, przy interferencji 4,00 mW, algorytm EDHO-SSA zapewnił wyższe AEE wynoszące 7,5354 J, podczas gdy modele MOMGWO, MOPSO, MOCSO, MOGWO i NSGA-II oferują niższe AEE wynoszące 7,3779, 6,8896, 6,3857, 6,0234 i 5,7964 J. odpowiednio. Tabela i Rysunek przedstawiają iteracyjną kontrolę uogólnionej demodulacji (IGD) modelu EDHO-SSA w porównaniu z innymi metodami.

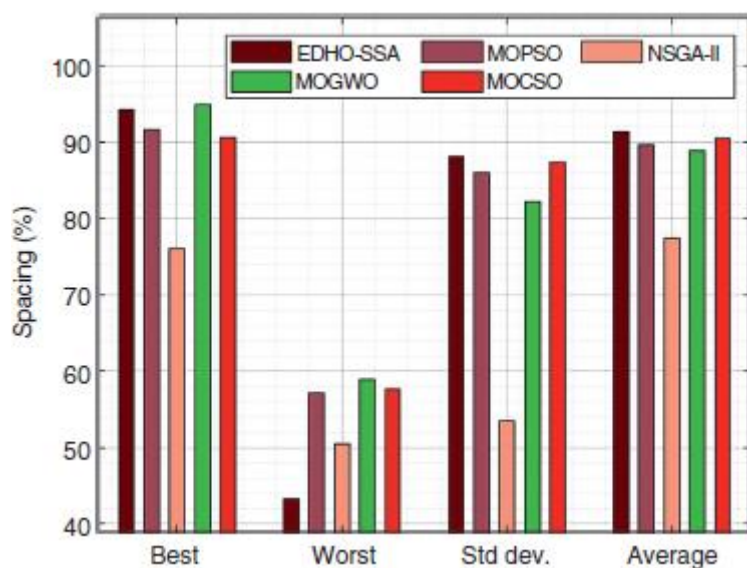
| IGD (%)  |          |       |         |       |       |
|----------|----------|-------|---------|-------|-------|
| Methods  | EDHO-SSA | MOPSO | NSGA-II | MOGWO | MOCSO |
| Best     | 50.12    | 55.44 | 55.63   | 62.92 | 62.93 |
| Worst    | 45.20    | 50.17 | 59.58   | 57.47 | 47.63 |
| Std dev. | 80.02    | 81.97 | 86.69   | 86.69 | 87.01 |
| Average  | 60.00    | 62.64 | 68.51   | 68.90 | 66.27 |






Wyniki pokazały, że technika EDHO-SSA przewyższa inne metody pod względem IGD. Na przykład model EDHO-SSA uzyskał najlepszy IGD na poziomie 50,12%, podczas gdy algorytmy MOPSO, NSGA-II, MOGWO i MOCSSO osiągnęły najlepszy IGD odpowiednio na poziomie 55,44, 55,63, 62,92 i 62,93%. Ostatecznie system EDHO-SSA uzyskał najgorszy IGD wynoszący 45,20%, podczas gdy algorytmy MOPSO, NSGAII, MOGWO i MOCSSO osiągnęły najgorszy IGD wynoszący odpowiednio 50,17, 59,58, 57,47 i 47,63%. Tymczasem model EDHOSSA uzyskał średni IGD wynoszący 60%, podczas gdy algorytmy MOPSO, NSGAII, MOGWO i MOCSSO osiągnęły średnie IGD odpowiednio 62,64, 68,51, 68,90 i 66,27%. Tabela i Rysunek przedstawiają analizę odstępów modelu EDHO-SSA w porównaniu z innymi metodami.

| Spacing (%) |          |       |         |       |        |
|-------------|----------|-------|---------|-------|--------|
| Methods     | EDHO-SSA | MOPSO | NSGA-II | MOGWO | MOCSSO |
| Best        | 94.36    | 91.60 | 76.02   | 94.94 | 90.71  |
| Worst       | 43.29    | 57.10 | 50.50   | 58.93 | 57.64  |
| Std dev.    | 88.11    | 85.95 | 53.53   | 82.25 | 87.36  |
| Average     | 91.35    | 89.67 | 77.41   | 88.94 | 90.49  |



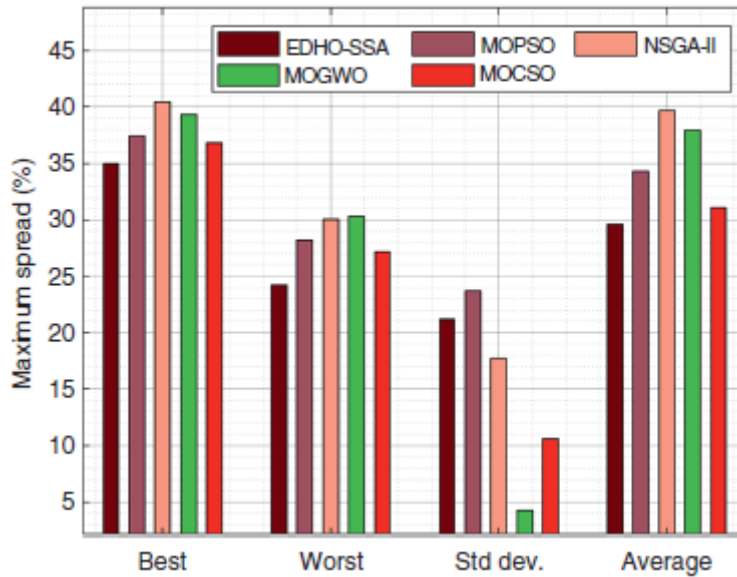
Wyniki pokazały, że podejście EDHO-SSA wykazało inne podejścia w odniesieniu do odstępów. Na przykład podejście EDHO-SSA uzyskało najlepsze odstępy wynoszące 94,36%, podczas gdy algorytmy MOPSO, NSGA-II, MOGWO i MOCSO osiągnęły najlepsze odstępy odpowiednio 91,60, 76,02, 94,94 i 90,71%. Następnie model EDHO-SSA osiągnął najgorszy odstęp wynoszący 43,29%, podczas gdy algorytmy MOPSO, NSGA-II, MOGWO i MOCSO osiągnęły najgorszy odstęp odpowiednio 57,10, 50,50, 58,93 i 57,64%. W międzyczasie metoda EDHO-SSA uzyskała średni odstęp 91,35%, podczas gdy systemy MOPSO, NSGAII, MOGWO i MOCSO osiągnęły średni odstęp 91,35%. Odpowiednio 89,67, 77,41, 88,94 i 90,49%. Tabela i Rysunek przedstawiają kontrolę współczynnika błędów systemu EDHOSSA w porównaniu z innymi metodami.

| Error ratio (%) |          |       |         |       |       |
|-----------------|----------|-------|---------|-------|-------|
| Methods         | EDHO-SSA | MOPSO | NSGA-II | MOGWO | MOCSO |
| Best            | 80.38    | 84.03 | 90.46   | 87.32 | 85.97 |
| Worst           | 61.75    | 71.67 | 75.52   | 70.23 | 70.72 |
| Std dev.        | 88.10    | 91.11 | 91.40   | 92.73 | 91.82 |
| Average         | 84.40    | 85.34 | 90.96   | 86.81 | 88.97 |



Wyniki wykazały, że metoda EDHO-SSA wykazała inne algorytmy pod względem współczynnika błędów. Na przykład model EDHO-SSA uzyskał najlepszy współczynnik błędów na poziomie 80,38%, podczas gdy algorytmy MOPSO, NSGA-II, MOGWO i MOCSO osiągnęły najlepszy współczynnik błędów odpowiednio 84,03, 90,46, 87,32 i 85,97%. Podobnie model EDHO-SSA uzyskał najgorszy współczynnik błędów na poziomie 61,75%, podczas gdy algorytmy MOPSO, NSGA-II, MOGWO i MOCSO osiągnęły najgorszy współczynnik błędów odpowiednio 71,67, 75,52, 70,23 i 70,72%. Wreszcie metodologia EDHO-SSA uzyskała średni współczynnik błędów na poziomie 84,40%, podczas gdy algorytmy MOPSO, NSGA-II, MOGWO i MOCSO uzyskały średnie współczynniki błędów odpowiednio 85,34, 90,96, 86,81 i 88,97. Tabela i Rysunek przedstawiają analizę maksymalnego rozrzutu.

| Maximum spread (%) |          |       |         |       |       |
|--------------------|----------|-------|---------|-------|-------|
| Methods            | EDHO-SSA | MOPSO | NSGA-II | MOGWO | MOCSO |
| Best               | 35.00    | 37.43 | 40.49   | 39.30 | 36.84 |
| Worst              | 24.24    | 28.22 | 30.05   | 30.33 | 27.20 |
| Std dev.           | 21.23    | 23.69 | 17.76   | 4.28  | 10.59 |
| Average            | 29.61    | 34.33 | 39.69   | 37.98 | 31.09 |



Metodologia EDHO-SSA nad innymi metodami. Wyniki pokazały, że model EDHO-SSA wykazał inne podejścia w odniesieniu do maksymalnego rozrzutu. Na przykład model EDHO-SSA uzyskał najlepszy maksymalny rozrzut wynoszący 35%, podczas gdy algorytmy MOPSO, NSGA-II, MOGWO i MOCSO osiągnęły najlepszy maksymalny rozrzut odpowiednio 37,43, 40,49, 39,30 i 36,84%. Jednocześnie technika EDHO-SSA uzyskała najgorszy maksymalny rozrzut wynoszący 24,24%, podczas gdy algorytmy MOPSO, NSGA-II, MOGWO i MOCSO osiągnęły najgorszy maksymalny rozrzut odpowiednio 28,22, 30,05, 30,33 i 27,20. Ostatecznie podejście EDHO-SSA uzyskało średni maksymalny rozrzut wynoszący 29,61%, podczas gdy algorytmy MOPSO, NSGA-II, MOGWO i MOCSO osiągnęły średni maksymalny rozrzut odpowiednio 34,33, 39,69, 37,98 i 31,09%.

### Wniosek

W artykule opracowano nową technikę EDHO-SSA dla optymalnego SS w sieciach komunikacyjnych 6G. Zaprezentowana technika EDHO-SSA prawidłowo zarządza dostępnością widm występujących w sieciach 6G. Technika EDHO-SSA opiera się na łowickim charakterze jeleniowatych. Wyprowadza również funkcję celu określającą wydajność SS, w tym różne parametry, takie jak energia i przepustowość. Przeprowadza się analizę wyników eksperymentalnych techniki EDHO-SSA, a wyniki ocenia się w odniesieniu do poszczególnych miar. Wyniki eksperymentów wykazały lepsze wyniki techniki EDHO-SSA w porównaniu z innymi technikami. W przyszłości zastosowane zostaną hybrydowe techniki głębokiego uczenia się, aby poprawić wydajność SS.