Elitarne opozycyjne igrzyska śmierci oparte na optymalizacji wyszukiwania, oparty na współpracy schemat wykrywania widma dla kognitywnych sieci radiowych 6G

Wstęp

Kognitywne sieci radiowe 5G (CRN) odgrywają kluczową rolę w ogólnoświatowej korespondencji i współdzieleniu widma. Podstawowym elementem korespondencji 5G CR jest ogromna korespondencja typu maszynowego, ulepszona, wszechstronna łączność szerokopasmowa i ultraniezawodna korespondencja o minimalnej bezwładności. Najważniejsze cechy sieci 5G to szybkość przesyłania informacji około 0,1 Gb/s, maksymalna szybkość przesyłania informacji wynosi około 20 Gb/s, czas bezczynności od początku do końca wynosi około 1 ms, dostępność gadżetów wynosi około 1 milion/km^2, trzykrotna wydajność w zakresie widma, wszechstronność obsługi 500 km/h, ograniczenie ruchu w regionie do 10 Mb/s/m^2 i kilkukrotna efektywność energetyczna w porównaniu z korespondencją 4G CRN . Rozważa się kilka podstawowych udoskonaleń, na przykład sieć ultragęstą, fale milimetrowe i wiele wejść i wiele wyjść (MIMO), aby uzyskać korespondencję 5G CRN. Chociaż piąty wiek nie jest w stanie sprostać potrzebom roku 2030. Badacze, instytucje i naukowcy skupiają się wokół korespondencji 6G CRN. Podstawową cechą 5G jest niska bezwładność, która wymaga deterministycznej sieci, aby zagwarantować bezczynność punktów świetlnych z warunkiem wstępnym i dokładnością zbliżania się do przyszłego porządku. Twórcy skupili się na tym, aby 6G było kompetentne do poszukiwania wyższej synchronizacji niż 5G. Poza tym będzie około największej inkluzji geologicznej, milisekundowej dokładności odświeżania obszaru topograficznego i subcentymetrowej precyzji geologicznej w 6G. Biorąc pod uwagę główny zakres powtarzalności, głównym wyzwaniem dla CR jest niezawodne rozpoznanie obecności kluczowych klientów w celu ograniczenia przeszkód na istniejących węzłach przesiadkowych. Proponowane są różne strategie rozróżniania obecności transmisji znaków, na przykład identyfikacja dopasowanego kanału, lokalizacja energii, w tym metody rozpoznawania i podejście falkowe. Rysunek przedstawia rozwój wykrywania widma (SS).

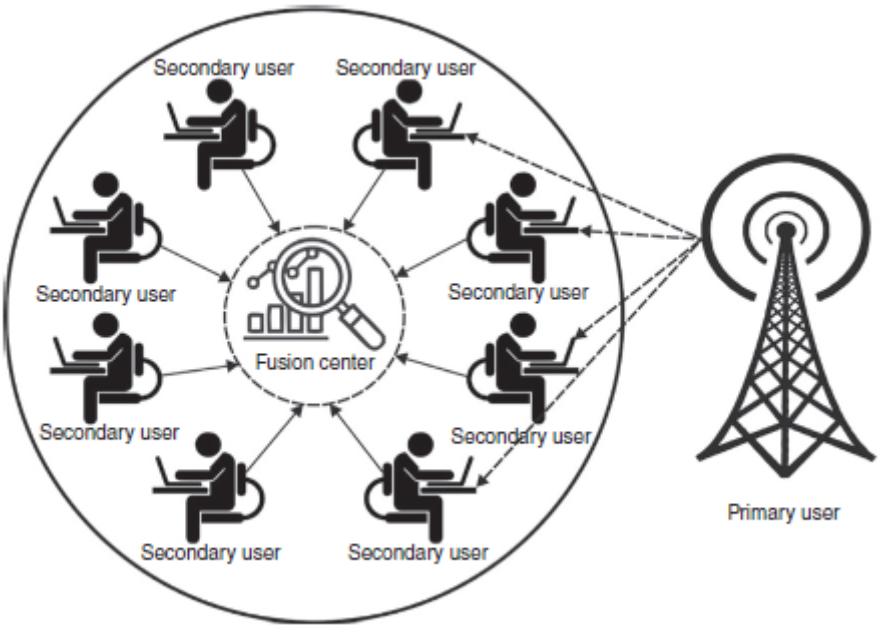

Niemniej jednak problem z ukrytym terminalem ma miejsce, gdy klient kognitywny jest cieniowany, w wyniku poważnego zanikania wielościeżkowego w strukturach ze zwiększonym nieszczęściem

związanym z infiltracją, gdy niezbędny klient pracuje w pobliżu. Ze względu na problem z ukrytym terminalem wykonanie wykrywania dla jednego klienta poznawczego zostanie obniżone . Aby zapobiec problemowi z ukrytym terminalem, sieć CR mogłaby łączyć skutki wykrywania różnych klientów poznawczych i wykorzystywać różnorodność przestrzenną wśród odpowiednich klientów poznawczych w celu zwiększenia niezawodności wykrywania. Zatem sieć przestrzennie przeniesionych klientów poznawczych, którzy doświadczają warunków kanału odmiennych od zakładanych, miałaby lepszą możliwość identyfikacji niezbędnego klienta poprzez handel danymi wykrywającymi. W ten sposób współpracujący SS mogą złagodzić problem błędnej identyfikacji, wykorzystując nieodłączną różnorodność przestrzenną, aby zmniejszyć prawdopodobieństwo utrudniania kluczowych klientów [8]. Ponieważ wspólne wykrywanie odbywa się w zasadzie za pośrednictwem kanału kontrolnego, należy zbadać skuteczne plany partycypacji, aby zmniejszyć wymagania wstępne dotyczące prędkości przesyłu i mocy, jednocześnie poprawiając niezawodność wykrywania. Znaczące rozważania dotyczące planu uwzględniają spadek w górę związany z handlem danymi czujnikowymi i kwestią praktyczności kanałów kontrolnych. Z reguły cechy robocze wskaźnika (na przykład oszustwo w porównaniu z prawdopodobieństwem identyfikacji) należy wybierać, biorąc pod uwagę możliwą do osiągnięcia sprawną przepustowość klientów kognitywnych i prawdopodobieństwo, że nie zderzą się z niezbędnymi klientami. Współpraca SS powinna być możliwa zarówno w sposób połączony, jak i zdecentralizowany . W przypadku wystąpienia metody włączonej, wyboru dokonuje się na podstawie miejsca kombinacji ogniskowej. Dane wszystkich klientów biorących udział w programie są konsolidowane w celu ustalenia dokonanego wyboru. W przypadku wykrywania opartego na współpracy wybór klienta nie jest dokonywany przez jednostkę główną. W celu idealnego podejmowania decyzji w przypadku CR wykorzystuje się liczne obliczenia metaheurystyczne . W niniejszym badaniu przedstawiono elitarny schemat wyszukiwania oparty na optymalizacji opozycyjnych igrzysk głodowych (EOHGSO-CSS) dla sieci CRN 6G. Technika EOHGSO-CSS ma na celu głównie efektywną alokację widma w sieciach CRN 6G. Proces SS można przeprowadzić przy użyciu różnych parametrów, takich jak zakłócenia, czas wykrywania, wartość progowa, energia, przepustowość i przydział mocy. Poza tym algorytm EOHSGO powstał w wyniku integracji elitarnego uczenia się opartego na opozycji (EOBL) z tradycyjnym algorytmem HGSO w celu poprawy jego wydajności. Aby ocenić doskonałe wyniki modelu EOHGSO-CSS, przeprowadzono szeroko zakrojone eksperymenty.

Powiązane prace

Zaprojektowano technikę selektywnej współpracy partnera współpracującego opartą na zdyskontowanej górnej granicy ufności (D-UCB), a użytkownicy drugorzędni (SU) poznali zmieniające się w czasie prawdopodobieństwa rozpoznania swoich sąsiadów, biorąc pod uwagę potencjalnie maksymalne prawdopodobieństwo wykrycia jako partnera współpracującego. Zaprezentowano nową, wieloobiektową, zmodyfikowaną technikę GWO (MOMGWO) do rozwiązywania wieloobiektowych zoptymalizowanych problemów z domeny SS z CRN, która jest istotnym paradygmatem technologii komunikacji bezprzewodowej. Zmodyfikowany w GWO został wykonany w celu zrównoważenia kompromisu pomiędzy procesami poszukiwawczo-wydobywczymi w konwencji GWO, w celu uzyskania globalnego maksimum. Khaf i inni zaproponowali skalowalną, częściowo technikę CSS, która jest niezwykle odporna na ataki polegające na wykrywaniu fałszowania danych (SDF). Oryginalność prezentowanej techniki polega na częściowej współpracy z rozwojem koalicji, która zmniejsza obciążenie związane z wykrywaniem i udostępnianiem danych, ale zwiększa dokładność wykrywania. Co więcej, technika ta nauczyła się dostosowywać procent udziału wykrywania i wybiera kanał z większą liczbą nagród do wykrycia w celu maksymalizacji nagród, ale minimalizacji zużycia energii. Le Anh i inni zbadali zachowanie poufności schematu nieortogonalnego wielokrotnego dostępu (NOMA) w niezaufanej sieci przekazywania energii (UEH). W tej sieci źródło komunikuje się z użytkownikiem za

pomocą sieci przekazującej złożonej z kilku niezaufanych elementów wykorzystujących protokoły wzmacniania i przekazywania (AF). Ten niezaufany węzeł przekazujący jest wyposażony w pojedynczą antenę i wykorzystuje protokół podziału mocy (PS) do gromadzenia energii z odbieranych sygnałów. Ponadto, w celu poprawy wydajności przerw w zapewnianiu poufności i ochrony tajnych danych w niezaufanej sieci przekazującej, źródło działa jako zakłócacz generujący sztuczny szum (AN).Zaprezentowano nowatorską metodę polegającą na integracji technik sztucznej inteligencji i technik rozpoznawania widma. Dokładność wyników jest eksperymentalna dzięki zastosowaniu tego nowatorskiego podejścia do technologii multipleksowania z ortogonalnym podziałem częstotliwości (OFDM). Do optymalnej alokacji kanałów pola i uzyskania maksymalnej dokładności wykorzystania widm wykorzystano algorytm genetyczny (GA). Wdrożono kilka rozwiązań obsługujących uczenie maszynowe, aby sprostać wyzwaniom związanym z trudnymi modelami wykrywania, od CSS po nieortogonalny proces rozgłaszania z kilkoma dostępem, obejmującymi techniki uczenia się bez nadzoru (grupowanie K-średnich i metoda mieszaniny Gaussa) oraz techniki uczenia się nadzorowanego (ukierunkowane graf acykliczny – maszyna wektorów nośnych [SVM], najbliższy sąsiad [KNN] i sieć neuronowa z propagacją wsteczną [BPNN]). Zaimplementowano wieloagentową technikę głębokiego uczenia się przez wzmacnianie (MADRL) do realizacji CSS z CRN. Wszystkie SU uczą się skutecznego podejścia do wykrywania wyników wykrywania określonej liczby wybranych widm w celu uniknięcia zakłóceń dla głównego użytkownika (PU) i koordynacji z innym SU.

Proponowany model

W tym badaniu opracowano nowe podejście EOHGSO-CSS w celu skutecznego wykrywania widma w CRN 6G. Proces SS można przeprowadzić przy użyciu różnych parametrów, takich jak zakłócenia, czas wykrywania, wartość progowa, energia, przepustowość i przydział mocy. Poza tym algorytm EOHSGO powstał poprzez integrację EOBL z tradycyjnym algorytmem HGSO w celu poprawy jego wydajności.

Projekt algorytmu EOHGSO

Algorytm HGSO jest metodą optymalizacji modelowania głodu i zachowań zwierząt. Zdolność do głodu mająca istotną homeostatyczną przyczynę decyzji, zachowania i działania w egzystencji zwierzęcej symbolizuje HGS. Modelowanie arytmetyczne HGS rozpoczyna się od populacji N rozwiązań, X, i przechodzi do wartości funkcji celu dla rozwiązania. Można to wyrazić w następujący sposób:

$$X = \begin{cases} X(t) \times (1 + rand), r_1 < l \\ W_1 \times X_b + R \times W_2 \times |X_b - X(t)|, r_1 > l, r_2 > E \\ W_1 \times X_b - R \times W_2 \times |X_b - X(t)|, r_1 > l, r_2 < E \end{cases} \quad (8.1)$$

Gdzie r_1 i r_2 są dwiema dowolnymi wartościami, a rand generuje liczbę na podstawie rozkładu standardowego, a R oznacza parametr, którego wartość można zdefiniować w zakresie [-a, a] i jest ona oparta na liczbie iteracji w następujący sposób:

$$R = 2 \times s \times rand - s, \quad s = 2 \times \left(1 - \frac{t}{T}\right) \quad (8.2)$$

Gdzie zmienna E wskazuje zmienną sterującą w następujący sposób:

$$E = \text{sech}(|\, Fit_i - Fit) \quad (8.3)$$

Fit_b oznacza największą wartość funkcji celu, a Sech odpowiada funkcji hiperbolicznej, gdzie sech x = $2/e^X - e^{-x}$ Ponadto W_1 i W_2 reprezentują wagę głodu w następujący sposób:

$$W_1 = \begin{cases} H_i \times \dfrac{N}{SH} \times r_4, & r_3 < l \\ 1 & r_3 > l \end{cases} \tag{8.4}$$

$$W_2 = 2\left(1 - e^{\left(-|H_j - SH|\right)}\right) \times r_5 \tag{8.5}$$

Gdzie r_3, r_4 i r_5 reprezentują dowolną liczbę w obrębie [0, 1], oraz parametr SH odpowiadający rozwiązaniu sumowania uczucia głodu:

$$SH = \sum_l H_i \tag{8.6}$$

Ponadto parametr H_i odpowiadający głodowi rozwiązania H_i jako:

$$H_i = \begin{cases} 0, & Fit_i = Fit_b \\ H_j + H_n, & \text{otherwise} \end{cases} \tag{8.7}$$

Optymalną wartość celu podaje Fit_b, istniejące rozwiązanie X_i ma cel dostarczony przez Fit, a nowy głód zapewnia parametr H_n:

$$H_n = \begin{cases} LH \times (1 + r), & TH < LH \\ TH, & \text{otherwise} \end{cases} \tag{8.8}$$

$$TH = 2\frac{Fit_i - Fit_b}{Fit_w - Fit_b} \times r_6 \times (UB - LB) \tag{8.9}$$

Fit_w nadaje niską wartość funkcji celu, a $r_6 \in [0, 1]$ wskazuje dowolny parametr, który wskazuje, czy głód ma pozytywne, czy szkodliwe skutki w oparciu o różne aspekty. Rysunek przedstawia schemat blokowy HGSO.

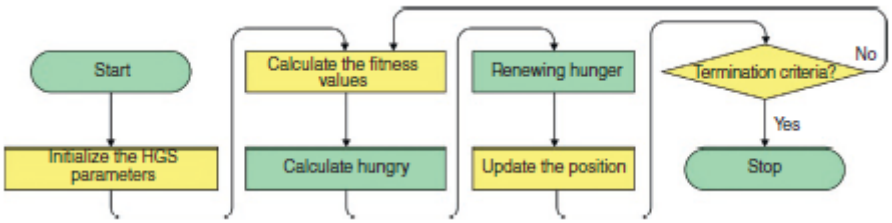

Poza tym algorytm EOHSGO powstał poprzez integrację EOBL z tradycyjnym algorytmem HGSO w celu poprawy jego wydajności. Oceń możliwe rozwiązanie problemu przeszukiwania przestrzeni. Tutaj, po uzyskaniu warunku końcowego, podejście to zatrzymuje się, w przeciwnym razie kontynuuje osiąganie optymalnego rozwiązania. EOBL jest techniką wykorzystywaną do zwiększania efektywności metaheurystyki [18]. Rozważmy, że elitarna jednostka w istniejącej populacji to $X_e = (x_{e,1}, x_{e,2},\ldots, x_{e,D})$, dla jednostki $X_i = (x_{i,1}, x_{i,2},\ldots, x_{i,D})$, elitarne rozwiązanie opozycji $\widetilde{X}_i = (\widetilde{x}_{i,1}, \widetilde{x}_{i,2}, \ldots, \widetilde{x}_{i,D})$ z X_i oznacza się następująco:

$$\bar{x} = \eta * (da_j + db_j) - x_{e,j} \quad (8.10)$$

Gdzie i = 1, 2, …, NP, NP wskazuje wielkość populacji, j = 1, 2, …, D, η ∈ U (O, 1) i η pokazują uogólniony współczynnik, a [da_j, db_j] reprezentują granicę adoptywną obszaru poszukiwań j-tego parametru i uzyskuje się ją wzorem:

$$da_j = \min\ (x_{i,j}) \quad (8.11)$$

$$db_j = \max\ (x_{i,j}) \quad (8.12)$$

Margines statyczny nie sprzyja zapisywaniu doświadczenia wyszukiwania, dlatego też ograniczenie adoptywne jest wykorzystywane w celu zastąpienia ustalonego ograniczenia w utrzymaniu doświadczenia wyszukiwania w celu uzyskania węższego rozwiązania przeciwstawnego. Dodatkowo, gdy operator wiązania dynamicznego powoduje, że xi, j wyskakuje z [daj, dbj], równanie. (8.13) służy do resetowania $\tilde{\tilde{x}}_{i,j}$:

$$\tilde{\tilde{x}}_{i,j} = rand\ (da_j, db_j) \quad (8.13)$$

EOBL generuje elitarne jednostki oparte na populacji opozycji i ocenia jednocześnie elitę i obecną populację. Ponadto w pełni wykorzystuje funkcję elitarnych osób, aby objąć przydatne dane wyszukiwania niż standardowe osoby. Ponadto EOBL pomaga w zwiększaniu globalnych możliwości poszukiwawczych metodą HGSO.

Zastosowanie algorytmu EOHGSO w CSS

Aby poprawić efektywność SS, przedstawiono kilka podejść. Algorytm metaheurystyczny wniósł istotny wkład. W tym przypadku algorytm EOHSGO jest wykorzystywany do poprawy SS dla CR. Odebrany sygnał składa się z N instancji, a radio kognitywne odbiera ten sygnał. Radio kognitywne nazywane jest także SU. SU muszą podjąć decyzję dotyczącą istnienia PU. Dane są wykorzystywane przez podstawowe centrum syntezy (FC) przy podejmowaniu decyzji o istnieniu PU. Można uznać, że wszystkie CR autonomicznie wyczuwają sieć i komunikują FC w sprawie swoich lokalnych decyzji [19]. Hipotezy alternatywne i zerowe dla prezentowanej metody są określone przez H_0: PU nie występuje. H_1: PU jest aktywny. FC podejmuje decyzję na podstawie optymalnej wagi.

$$y_l(k) = \begin{cases} \varsigma_l(k) : H_0 \\ G_l s(k) + \varsigma_l(k) : H_1 \end{cases} \quad (8.14)$$

Symbole użyte w równaniu. (8.14) oznaczają l = 1, 2, …, M, ςl(k) oznacza, że szum wykrywania Gaussa ma średnią wartość 0. s(k) oznacza sygnał główny, a G_l pokazuje wzmocnienie kanału. Lokalny stosunek sygnału do szumu (SNR) jest szacowany poprzez:

$$\eta_l = \frac{\Psi_s |G_1|^2}{\sigma_l^2} \quad (8.15)$$

Energię sygnału oblicza się ze wzoru:

$$\Psi_s = \sum_{k=1}^{N} |s(k)|^2 \qquad (8.16)$$

Energię sygnału dla l-tego CR z próbką N oszacowano wzorem:

$$\zeta_l = \sum_{k=1}^{N} |y_l(k)|^2 \qquad (8.17)$$

Każda odebrana energia sygnału jest przekazywana w sposób ortogonalny do FC w celu podjęcia decyzji. FC podjęła decyzję na podstawie wyników globalnych statystyk testowych. Globalną statystykę testową dla l-tego CR szacuje się według wzoru $f_l = \zeta_l + n_l$.

Statystyka testowa jest szacowana liniowo przez $f_c = \sum_{l=1}^{M} w_l f_l = w^T f$ w którym wektor wagi w jest reprezentowany jako $w \triangleq [w_1, w_2, \ldots, w_M]^T$ i $f = [f_1, f_2, \ldots, f_m]^T$. Wariancję f_c wyraża się wzorem:

$$Var(f_c H_0) = \sum_{l=1}^{M} (2N\sigma_l^4 + \vartheta_l^2) w_l^2 = w^T \chi_{H_0} w \qquad (8.18)$$

Gdzie

$$\chi_{H_0} = 2N diag^2(\sigma) + diag(\vartheta) \qquad (8.19)$$

$$\sigma = [\sigma_1^2, \sigma_2^2, \ldots, \sigma_M^2] \quad \text{and} \quad \vartheta = [\vartheta_1^2, \vartheta_2^2, \ldots, \vartheta_M^2].$$

$$Var(f_c H_1) = \sum_{l=1}^{M} (2N\sigma_l^4 + \vartheta_l^2 + 4\eta_l \sigma_l^4) w_l^2 = w^T \chi_{H_1} w \qquad (8.20)$$

Gdzie

$$\chi_{H_0} = 2N diag^2(\sigma) + diag(\vartheta) \qquad (8.19)$$

$$\sigma = [\sigma_1^2, \sigma_2^2, \ldots, \sigma_M^2] \quad \text{and} \quad \vartheta = [\vartheta_1^2, \vartheta_2^2, \ldots, \vartheta_M^2].$$

$$Var(f_c H_1) = \sum_{l=1}^{M} (2N\sigma_l^4 + \vartheta_l^2 + 4\eta_l \sigma_l^4) w_l^2 = w^T \chi_{H_1} w \qquad (8.20)$$

Gdzie

$$\chi_{H_1} = 2N diag^2(\sigma) + diag(\vartheta) + 4\Psi_s diag(G) diag(\sigma) \qquad (8.21)$$

Regułę decyzyjną oszacowano na podstawie detekcji energii w FC następująco:

$$f_c \underset{H_1}{\overset{H_o}{\gtrless}} \tau_{fu} \qquad (8.22$$

Teraz τ_{fu} charakteryzuje obowiązujący próg decyzyjny.

$$\tau_{fu} = Q^{-1}(P_f) \sqrt{w^T \chi_{H_0} w} + N\sigma^2 w \qquad (8.23)$$

Tutaj P_f oznacza możliwość fałszywego alarmu. Dlatego możliwość wykrycia p szacuje się przez:

$$P_d = Q\left(\frac{Q^{-1}(P_f)\sqrt{W^T\chi_{H_0}W} - \Psi_s G^T W}{\sqrt{W^T\chi_{H_1}W}}\right) \qquad (8.24)$$

Optymalny wektor wagowy (W) uzyskuje się w celu maksymalizacji ρ_d. ρ_d maksymalizuje się poprzez redukcję ρ(W), podczas gdy Q(x) jest funkcją redukcji względem x.

$$\rho(W) = \frac{Q^{-1}(P_f)\sqrt{W^T\chi_{H_0}W} - \Psi_s G^T W}{\sqrt{W^T\chi_{H_1}W}} \qquad (8.25)$$

$$\sum_{l=1}^{M} w_1 = 1, \quad 0 \le w_1 \le 1, \quad l = 1, 2, ..., M$$

Walidacja eksperymentalna

W tej sekcji sprawdza się walidację wydajności modelu EOHGSO-CSS w kilku iteracjach i CR. Tabela i Rysunek przedstawiają wyniki detekcji maksymalnego prawdopodobieństwa (MPD) modelu EOHGSO-CSS i istniejących technik w kilku iteracjach.

Maximum probability detection (Pd)					
No. of iterations	EOHGSO-CSS	MRFO	DA	PSO	GA
1	0.8116	0.5605	0.5872	0.7697	0.6140
2	0.8627	0.6767	0.5872	0.8081	0.6268
3	0.8941	0.8813	0.7151	0.8337	0.6721
4	0.9325	0.9546	0.7070	0.8616	0.6884
5	0.9697	0.9441	0.7174	0.8860	0.7174
6	0.9778	0.9395	0.7232	0.8906	0.7151
7	0.9709	0.9592	0.7930	0.8918	0.7349
8	0.9813	0.9604	0.7930	0.8953	0.7360
9	0.9813	0.9627	0.7930	0.9255	0.7581
10	0.9825	0.9627	0.8465	0.9244	0.7732
11	0.9825	0.9627	0.9104	0.9278	0.8267
12	0.9825	0.9627	0.9104	0.9278	0.8337
13	0.9825	0.9627	0.9139	0.9313	0.8965
14	0.9825	0.9627	0.9139	0.9290	0.8965
15	0.9825	0.9627	0.9139	0.9290	0.8999
16	0.9825	0.9627	0.9139	0.9290	0.8965
17	0.9825	0.9627	0.9139	0.9290	0.8988
18	0.9825	0.9627	0.9104	0.9290	0.9069
19	0.9825	0.9627	0.9116	0.9290	0.9069
20	0.9825	0.9627	0.9092	0.9290	0.9081
21	0.9825	0.9627	0.9127	0.9290	0.9081
22	0.9825	0.9627	0.9116	0.9290	0.9081
23	0.9825	0.9627	0.9278	0.9290	0.9081
24	0.9825	0.9627	0.9255	0.9290	0.9058
25	0.9825	0.9627	0.9255	0.9290	0.9069
26	0.9825	0.9627	0.9255	0.9290	0.9151
27	0.9825	0.9627	0.9255	0.9290	0.9151
28	0.9825	0.9627	0.9255	0.9290	0.9162
29	0.9825	0.9627	0.9255	0.9290	0.9139
30	0.9825	0.9627	0.9255	0.9290	0.9151

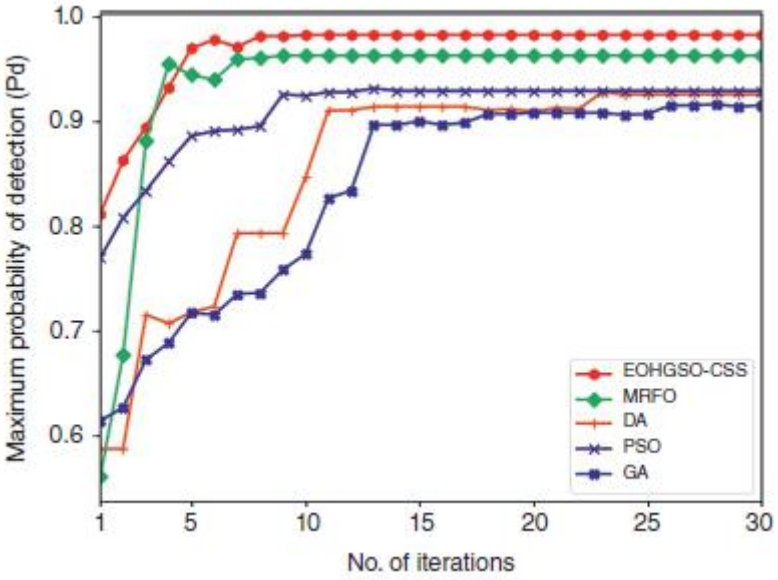

Wyniki wykazały, że model EOHGSO-CSS przewyższa inne metody przy maksymalnym MPD we wszystkich iteracjach. Na przykład w iteracji 1 model EOHGSO-CSS oferował wyższy MPD wynoszący 0,8116, podczas gdy optymalizacja żerowania promieni manty (MRFO), algorytm ważki (DA), optymalizacja roju cząstek (PSO) i modele GA uzyskały niższy MPD wynoszący 0,5605 , odpowiednio 0,5872, 0,7697 i 0,6140. Ponadto w iteracji 10 model EOHGSO-CSS zapewnił zwiększone MPD wynoszące 0,9825, podczas gdy modele MRFO, DA, PSO i GA uzyskały niższe MPD wynoszące odpowiednio 0,9627, 0,8465, 0,9244 i 0,7732. Co więcej, w 20. iteracji model EOHGSO-CSS oferował wyższe MPD wynoszące 0,9825, podczas gdy modele MRFO, DA, PSO i GA uzyskały niższe MPD wynoszące odpowiednio 0,9627, 0,9092, 0,9290 i 0,9081. Tymczasem w iteracji 30 zaoferowano model EOHGSO-CSS wyższy MPD wynoszący 0,9825 podczas gdy modele MRFO, DA, PSO i GA uzyskali niższe MPD wynoszące 0,9627, 0,9255, 0,9290 i 0,9151, odpowiednio. Tabela i Rysunek badają badanie prawdopodobieństwa wykrycia (PD) modelu EOHGSO-CSS innymi metodami przy CR = 8 i wyraźnym prawdopodobieństwie fałszywych alarmów (PF).

Probability of detection (Pd); *CR* = 8					
Probability of false alarm (Pf)	**EOHGSO-CSS**	**MRFO**	**DA**	**PSO**	**GA**
0.05	0.2796	0.1848	0.0387	0.0028	0.0464
0.10	0.5795	0.4846	0.4334	0.5128	0.2360
0.15	0.7999	0.7307	0.6871	0.5359	0.4641
0.20	0.8409	0.7819	0.7358	0.7409	0.5974
0.25	0.8639	0.8127	0.7947	0.7973	0.6512
0.30	0.9178	0.8563	0.8229	0.8486	0.6461
0.35	0.9485	0.9024	0.8665	0.8588	0.6794
0.40	0.9690	0.9383	0.9203	0.9178	0.7409
0.45	0.9690	0.9152	0.9101	0.9383	0.8434
0.50	0.9818	0.9203	0.9280	0.9229	0.8255
0.55	0.9921	0.9280	0.9537	0.9690	0.7999
0.60	0.9982	0.9511	0.9562	0.9767	0.8563
0.65	0.9982	0.9511	0.9767	0.9665	0.8845
0.70	0.9982	0.9742	0.9870	0.9818	0.8691
0.75	0.9982	0.9947	0.9742	0.9870	0.9126
0.80	0.9982	0.9844	0.9870	0.9998	0.9460
0.85	0.9982	0.9921	0.9972	0.9947	0.9921
0.90	0.9982	0.9921	0.9972	0.9947	0.9742
0.95	0.9982	0.9972	0.9921	0.9947	0.9818
1.00	0.9982	0.9972	0.9895	0.9947	0.9870

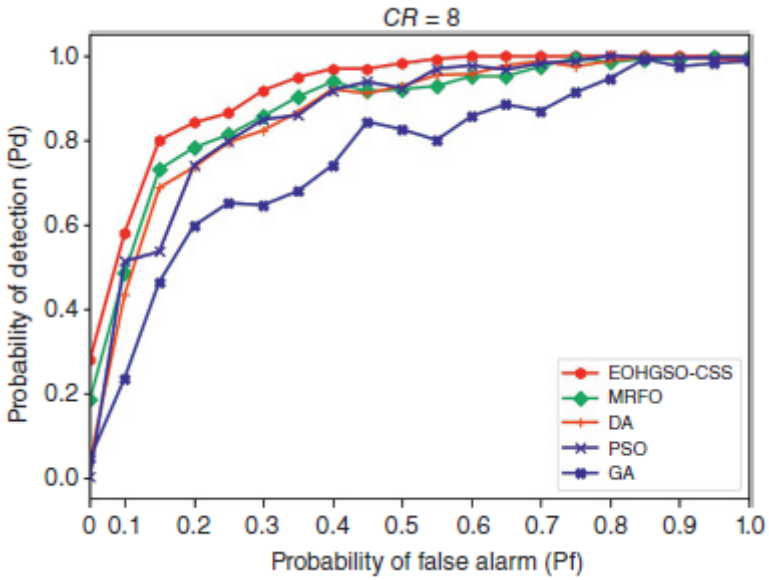

Wyniki wskazują, że model EOHGSO-CSS osiągnął zwiększone PD w przypadku wszystkich PF. Na przykład przy PF wynoszącym 0,05 model EOHGSO-CSS osiągnął wyższe PD wynoszące 0,2796, podczas gdy modele MRFO, DA, PSO i GA dały zmniejszone PD wynoszące odpowiednio 0,1848, 0,0387, 0,0028 i 0,0464. Oprócz tego, przy PF wynoszącym 0,25, technika EOHGSO-CSS osiągnęła wyższe PD wynoszące 0,8639, podczas gdy modele MRFO, DA, PSO i GA dały zmniejszone PD wynoszące odpowiednio 0,8127, 0,7947, 0,7973 i 0,6512. Co więcej, przy PF wynoszącym 0,65, model EOHGSO-CSS osiągnął wyższe PD wynoszące 0,9982, podczas gdy systemy MRFO, DA, PSO i GA dały zmniejszone PD wynoszące odpowiednio 0,9511, 0,9767, 0,9665 i 0,8845. Co więcej, przy PF wynoszącym 1,00, algorytm EOHGSO-CSS osiągnął wyższe PD wynoszące 0,9982, podczas gdy modele MRFO, DA, PSO i GA dały zmniejszone PD wynoszące odpowiednio 0,9972, 0,9895, 0,9947 i 0,9870. Tabela i Rysunek przedstawiają badanie WNZ metodą EOHGSOCSS innymi metodami przy CR = 10 i różnych PF.

Probability of detection (Pd); *CR* = 10					
Probability of false alarm (Pf)	**EOHGSO-CSS**	**MRFO**	**DA**	**PSO**	**GA**
0.05	0.7462	0.7145	0.7069	0.5051	0.5242
0.10	0.8376	0.8134	0.8046	0.7576	0.7259
0.15	0.8693	0.8388	0.8236	0.8173	0.7297
0.20	0.9124	0.8870	0.8756	0.8832	0.8033
0.25	0.9492	0.9187	0.9124	0.9048	0.8173
0.30	0.9746	0.9467	0.9073	0.9086	0.8350
0.35	0.9911	0.9530	0.9213	0.9403	0.8490
0.40	0.9911	0.9543	0.9581	0.9492	0.8896
0.45	0.9923	0.9847	0.9632	0.9657	0.9264
0.50	0.9961	0.9771	0.9657	0.9670	0.9048
0.55	0.9961	0.9835	0.9670	0.9670	0.9314
0.60	0.9974	0.9835	0.9885	0.9847	0.9327
0.65	0.9987	0.9898	0.9809	0.9822	0.9441
0.70	0.9999	0.9961	0.9885	0.9898	0.9441
0.75	0.9987	0.9961	0.9911	0.9923	0.9517
0.80	0.9987	0.9961	0.9911	0.9961	0.9733
0.85	0.9999	0.9961	0.9949	0.9949	0.9873
0.90	0.9999	0.9949	0.9974	0.9949	0.9822
0.95	0.9999	0.9984	0.9974	0.9987	0.9898
1.00	0.9999	0.9991	0.9989	0.9988	0.9936

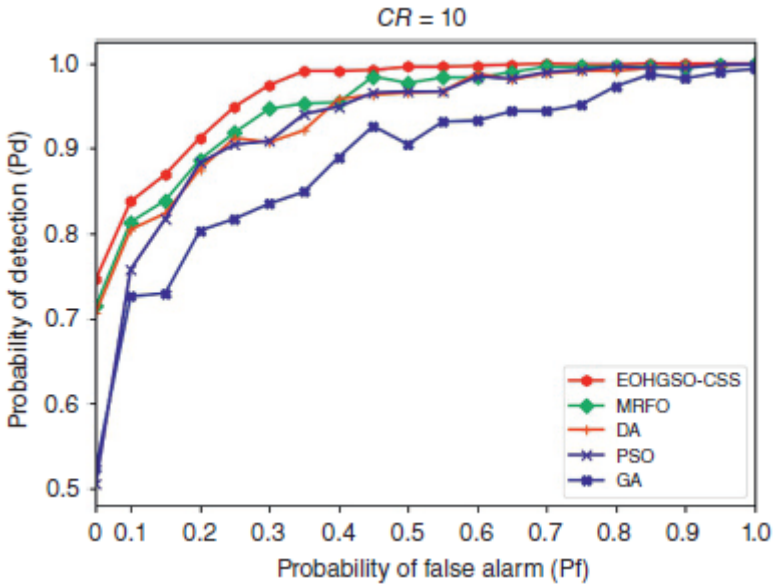

Wyniki wykazały, że metodą EOHGSO-CSS uzyskano zwiększone PD w przypadku wszystkich PF. Na przykład przy PF wynoszącym 0,05 podejście EOHGSO-CSS osiągnęło wyższe PD wynoszące 0,7462, podczas gdy modele MRFO, DA, PSO i GA dały zmniejszone PD wynoszące odpowiednio 0,7145, 0,7069, 0,5051 i 0,5242. Podobnie, przy PF wynoszącym 0,25, model EOHGSO-CSS osiągnął wyższe PD wynoszące 0,9492, podczas gdy systemy MRFO, DA, PSO i GA dały zmniejszone PD wynoszące odpowiednio 0,9187, 0,9124, 0,9048 i 0,8173. Następnie, przy PF wynoszącym 0,65, model EOHGSO-CSS osiągnął wyższe PD wynoszące 0,9987, podczas gdy metody MRFO, DA, PSO i GA spowodowały zmniejszenie PD wynoszące odpowiednio 0,9898, 0,9809, 0,9822 i 0,89441. Wreszcie, przy PF wynoszącym 1,00, technika EOHGSO-CSS osiągnęła wyższe PD wynoszące 0,9999, podczas gdy systemy MRFO, DA, PSO i GA dały zmniejszone PD wynoszące odpowiednio 0,9991, 0,9989, 0,9988 i 0,9936. Tabela i Rysunek przedstawiają badanie WNZ systemu EOHGSO-CSS innymi metodami przy CR = 12 i różnych PF.

Probability of detection (Pd); *CR* = 12					
Probability of false alarm (Pf)	**EOHGSO-CSS**	**MRFO**	**DA**	**PSO**	**GA**
0.05	0.8277	0.7892	0.6505	0.5027	0.5130
0.10	0.8920	0.8213	0.8162	0.7841	0.6672
0.15	0.9459	0.8804	0.8573	0.8521	0.7853
0.20	0.9729	0.9408	0.8406	0.8290	0.7918
0.25	0.9832	0.9318	0.9074	0.9010	0.8239
0.30	0.9870	0.9318	0.9241	0.9267	0.8380
0.35	0.9935	0.9716	0.9485	0.9472	0.8560
0.40	0.9922	0.9652	0.9536	0.9498	0.8894
0.45	0.9922	0.9652	0.9601	0.9716	0.9138
0.50	0.9960	0.9870	0.9909	0.9845	0.9318
0.55	0.9935	0.9857	0.9755	0.9780	0.9369
0.60	0.9999	0.9935	0.9883	0.9819	0.9344
0.65	0.9986	0.9922	0.9896	0.9832	0.9472
0.70	0.9999	0.9947	0.9896	0.9896	0.9523
0.75	0.9999	0.9986	0.9947	0.9909	0.9665
0.80	0.9986	0.9986	0.9922	0.9909	0.9870
0.85	0.9986	0.9960	0.9935	0.9883	0.9909
0.90	0.9986	0.9960	0.9947	0.9896	0.9883
0.95	0.9999	0.9960	0.9960	0.9870	0.9896
1.00	0.9999	0.9986	0.9982	0.9973	0.9845

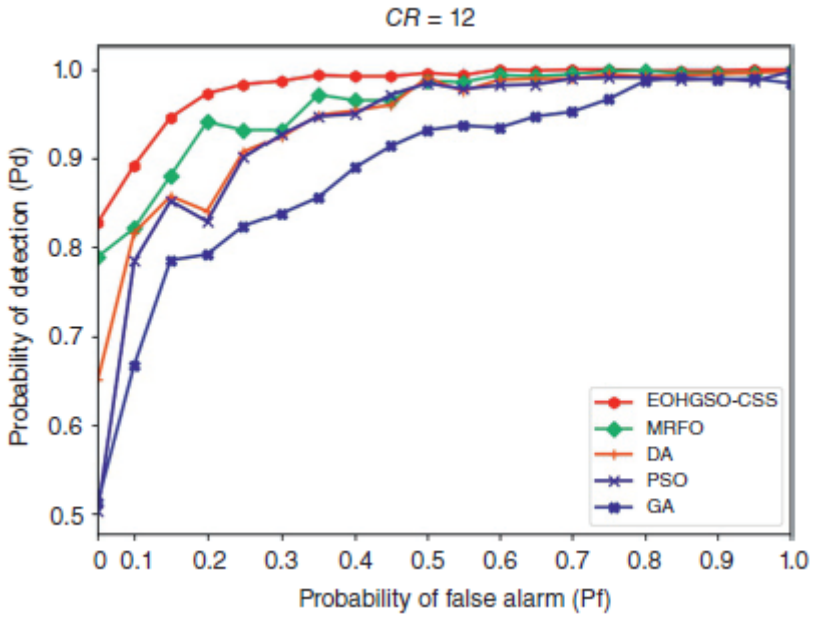

Wyniki wykazały, że metodą EOHGSO-CSS uzyskano zwiększone PD w przypadku wszystkich PF. Na przykład z PF z 0,05, metodologia EOHGSO-CSS osiągnęła doskonałe PD wynoszące 0,8277, podczas gdy techniki MRFO, DA, PSO i GA spowodowały zmniejszenie PD odpowiednio 0,7892, 0,6505, 0,5027 i 0,5130. Podobnie, przy PF wynoszącym 0,25, metoda EOHGSO-CSS osiągnęła zwiększone PD wynoszące 0,9832, podczas gdy techniki MRFO, DA, PSO i GA spowodowały zmniejszenie PD odpowiednio 0,9318, 0,9074, 0,9010 i 0,8239. Ponadto, przy PF wynoszącym 0,65, podejście EOHGSOCSS osiągnęło wyższe PD wynoszące 0,9986, podczas gdy techniki MRFO, DA, PSO i GA doprowadziły do zmniejszenia PD wynoszącego odpowiednio 0,9922, 0,9896, 0,9832 i 0,9472. Wreszcie, przy PF wynoszącym 1,00, algorytm EOHGSO-CSS osiągnął maksymalne PD wynoszące 0,9999, podczas gdy modele MRFO, DA, PSO i GA spowodowały zmniejszenie PD wynoszące odpowiednio 0,9986, 0,9982, 0,9973 i 0,9845. Z powyższych wyników wynika, że technika EOHGSO-CSS osiągnęła maksymalne wyniki w ciągu ostatnich lat innymi metodami.

Wniosek

W tym badaniu opracowano nowatorskie podejście EOHGSO-CSS do skutecznego wykrywania widma w CRN 6G. Proces SS można przeprowadzić przy użyciu różnych parametrów, takich jak zakłócenia, czas wykrywania, wartość progowa, energia, przepustowość i przydział mocy. Poza tym algorytm EOHSGO powstał poprzez integrację EOBL z tradycyjnym algorytmem HGSO w celu poprawy jego wydajności. Aby ocenić doskonałe wyniki modelu EOHGSO-CSS, przeprowadzono szeroko zakrojone eksperymenty. Obszerne badanie porównawcze podkreśliło ulepszenia modelu EOHGSO-CSS w porównaniu z innymi podejściami pod względem różnych miar. Dlatego technikę EOHGSO-CSS można zastosować jako sprawne narzędzie do wykrywania widma w CRN obsługujących 6G. W przyszłości w sieciach CRN obsługujących technologię 6G można zastosować modele głębokiego uczenia się w celu uzyskania optymalnego CSS.