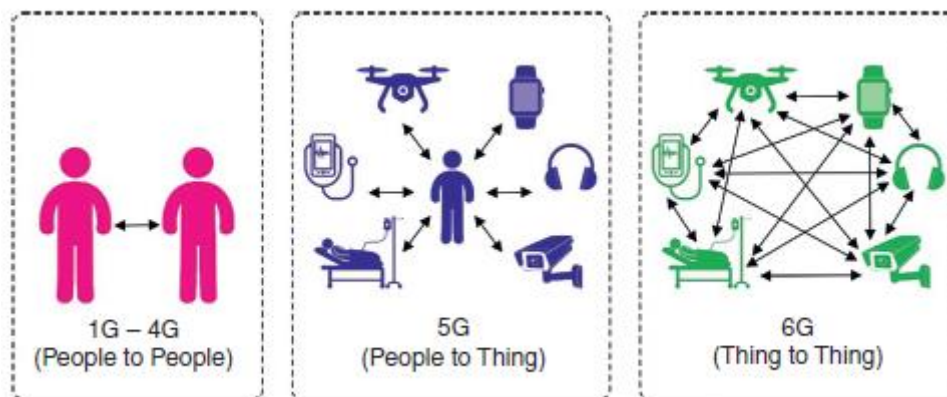


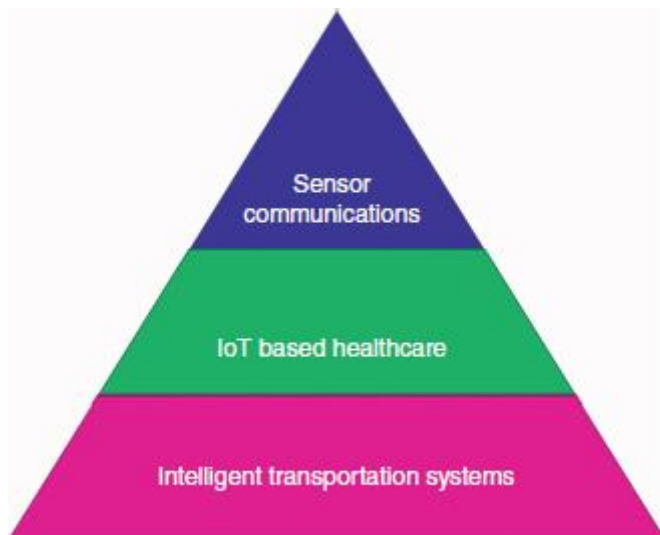
Projekt optymalizatora Dingo wykorzystującego sztuczną inteligencję do zarządzania energią w sieciach komunikacyjnych 6G

Wstęp

Sieć szóstej generacji (6G) powinna zapewniać lepsze wykonanie niż poprzednie generacje, aby sprostać potrzebom powstających administracji i aplikacji. Ewolucję sieci 6G pokazano na rysunku .



Aby złagodzić rosnące ograniczenia energetyczne związane z siecią 6G, świat naukowy i przemysł przewodziły szeroko zakrojonym badaniom. Co więcej, dostępne odpowiedzi na pytanie dotyczące ogromnego zużycia energii pochodzą głównie z dwóch sekcji: projektowania sieci energooszczędnych i pozyskiwania energii. W szczególności jednostki zbierające energię, takie jak ładowarki zasilane energią słoneczną, turbiny wiatrowe i żniwiarki wibracyjne, są powszechnie stosowane w celu zamiany różnych rodzajów energii na energię dla wyspecjalizowanych gadżetów . Efektywność energetyczna to jeszcze jeden interesujący punkt dla przyszłych zdalnych sieci. Atrakcyjne jest posiadanie sprzętu, który spełnia wymagania energetyczne 6G. Zmiany w energetyce zapoczątkowane przez układ polityczny i rosnący wpływ zrównoważonego wykorzystania energii na lądzie wymagają wyjątkowo realnego pomysłu na pobliskie wytwarzanie i wykorzystanie energii. Równoważenie wykorzystania energii pomiędzy wytwarzaniem i pozyskiwaniem energii musi zostać osiągnięte poprzez produktywny, solidny i praktyczny ramy zarządzania energią. Energię cieplną do ogrzewania oraz wodę o wysokiej temperaturze i energię elektryczną należy wykorzystywać do sterowania budynkami poprzez koncepcje o zmniejszonej emisji CO₂ . Podobnie wiele różnych zadań w zaawansowanej nieruchomości powinno mieć możliwość pomyślnego rozliczenia wydatków za pomocą części cyfrowych. Generowaniem danych w okolicy można zarządzać za pomocą oprogramowania z możliwością szybkiego połączenia z różnymi technologiami radiowymi Internetu rzeczy (IoT). Różne domeny zaangażowane w sieć 6G przedstawiono na rysunku .



Systemy zarządzania energią w świetle projektowania oprogramowania informatycznego przedsiębiorstwa pozwalają klientom i uczestnikom rynku tworzyć nowe administracje, takie jak zarządzanie energią dla małych jednostek (biura, lofty, biura kreacji), zarządzanie energią dla całych budynków i biur, zarządzanie energią dla obszarów metropolitalnych oraz parki przemysłowe z szacowaniem i pomiarami informacji. Cyfrowe sterowanie elementami i aplikacjami klienckimi zarządza własnymi wymaganiami związanymi z administracją energetyczną i elementami, w konsekwencji wykorzystując interfejsy rynkowe i jednocześnie wspierając jakość i bezpieczeństwo dostaw sieci elektroenergetycznej. Dzięki AIDO gadżety mogą czerpać siłę ze zdalnej korespondencji. Wydłuża to zatem czas działania baterii gadżetów. Celem energooszczędnej sieci w pudełku (NIB) opartej na technologii 6G jest przekształcenie rzeczywistego świata w genialny i nieunikniony. NIB jest także niezbędną substancją umożliwiającą wspieranie samoorganizującego się i spójnego powiązania z lepszą i rozsądną administracją, na przykład mediami interaktywnymi (tj. tekstem, dźwiękiem i wideo itp.) . NIB z obsługą 6G zapewnia elastyczną i wszechstronną podstawę z mniejszym i pomocnym transportem substancji w górę dla odległej nowoczesnej robotyzacji. Ręczna, zdalna scena daje wyłaniające się otwarte drzwi do nowoczesnej komputeryzacji, rozproszonych platform i pojazdów z zainstalowanymi platformami sieciowymi. Ze względu na trudny charakter czasu rzeczywistego i poważne czasy graniczne, nowoczesne aplikacje muszą opóźnić otwartą i pozbawioną błędów korespondencję. Obecnie różne zastosowania, na przykład komórkowe, naziemne i morskie, są w dużym stopniu objęte technologiami NIB . Hu i inni przedstawili energooszczędny światopogląd dotyczący rejestracji w sieci dla 6G, który uwzględnia możliwości sieci w ogólnym etapie przetwarzania, zamiast przypisywać szacowane przedsięwzięcia do gadżetów sieciowych. Etap planowania, który koordynuje przepustowość sieci, zastępuje konwencjonalne gadżety sieciowe i pełni rolę koncentratora sieciowego. W niczym nie przypominający zwykłych gadżetów sieciowych, koncentrator sieciowy zapewnia spójny klimat pracy przedsiębiorstwom aplikacyjnym za pośrednictwem hiperwizorów i przedziałów. Sodhro i inni proponują oryginalną przenośność opartą na uczeniu maszynowym, strategię zarządu dla sprawnej korespondencji w nowoczesnych zastosowaniach NIB. Po drugie, zaproponowano oryginalną inżynierię dotyczącą poprawy jakości energii (QoE) i jakości usług (QoS) w nowoczesnym NIB w oparciu o technologię 6G zaproponowano rozmytą procedurę budzenia opartą na racjonalnych przesłankach, która całkowicie uwzględnia poziom budzenia energetycznego i proporcję dostępnych zasobów sieciowych. Następnie w tym momencie stany energii oparte na Słońcu są analizowane numerycznie przy użyciu techniki zgadywania dyspersji. Wreszcie, aby zapobiec wymianie podstawowych sygnałów (BS) przez większą część czasu pomiędzy modelem drzemki i nieśpiącego, ożywiająca krawędź zostaje wzmocniona poprzez strategię pracy karania. Mao

i inni zaproponowali wszechstronną strategię bezpieczeństwa opartą na sztucznej inteligencji (AI) dla sieci 6G IoT, w której gadżety IoT są powiązane z sieciami komórkowymi za pomocą różnych grup powtarzalności, w tym fal terahercowych (THz) i fal milimetrowych (mmWave). Gadżety wykrywające IoT są akceptowane jako pomoc w procedurze gromadzenia energii, która jest powszechnie stosowana w sieci 6G. W naszej propozycji najpierw wykorzystano technikę rozszerzonego filtra Kalmana (EKF), aby przewidzieć przyszłą moc zbierania. W tym artykule zaproponowano nową, wielowymiarową, inteligentną metodę wielodostępu (MD-IMA), aby wykorzystać unikalne imperatywy zasobów wśród heterogenicznego sprzętu dla sieci 5Gpast i 6G. Przy pomocy ciągłego badania informacji, bieżących potrzeb QoS i zasobów dostępność podłączonego sprzętu nie została określona w proponowanym MD-IMA. W artykule przedstawiono optymalizator dingo obsługujący sztuczną inteligencję do zarządzania energią (AIDO-EM) w sieciach 6G. Głównym celem prezentowanej techniki AIDO-EM jest minimalizacja zużycia energii i maksymalizacja żywotności urządzeń IoT obsługujących 6G. Aby to osiągnąć, zastosowano nowy algorytm optymalizacji dingo (DOA) dla routingu z obsługą klastra, aby osiągnąć efektywną dystrybucję danych pomiędzy urządzeniami i wybrać efektywne główce bram (GWH). Aby wykazać ulepszone wyniki techniki AIDO-EM, przeprowadzono serię symulacji, a wyniki wykazały lepszą wydajność w porównaniu z najnowszymi, najnowocześniejszymi podejściami.

Proponowany model

W tym badaniu opracowano nowatorską technikę AIDO-EM w celu osiągnięcia efektywnej efektywności energetycznej w sieciach 6G. Zaprezentowana technika AIDO-EM ma na celu osiągnięcie minimalnego zużycia energii i maksymalnej żywotności urządzeń IoT obsługujących 6G. Ponadto zastosowano nowatorską metodę DOA w przypadku routingu z obsługą klastrów, aby osiągnąć efektywną dystrybucję danych pomiędzy urządzeniami i wybrać efektywne GWH.

Proces zaangażowany w DOA

DOA to inspirowana biologią technika globalnej optymalizacji, która stymuluje strategię polowania dingo. Strategia ta polega na ataku poprzez żerowanie, prześladowanie i taktykę grupowania [14, 15]. Australijskiemu dingo grozi wyginięcie. Dlatego bierze się pod uwagę możliwość przeżycia dingo.

Poziom 1: Atak grupowy. Zwykle podczas polowania dingo gromadzą się w grupach. Potrafią wykryć położenie ofiary i otoczyć ją. Można to wyrazić jako:

$$\vec{x}_i(t+1) = \beta_1 \sum_{k=1}^{na} \frac{[\overrightarrow{\varphi}_k(t) - \vec{x}_i(t)] \frac{1}{\phi_k(t)}}{na} - \vec{x}_{i^*}(t) \quad (5.1)$$

Gdzie $\vec{x}(t+1)$ oznacza lokalizację szukającego agenta (pokazuje ruch dingo), na wskazuje dowolną wartość całkowitą w obrębie $[2, \frac{SizePop}{2}]$ natomiast SizePop oznacza ogólną wielkość populacji $\vec{\varphi}_k(t)$ jest podzbiorem agentów poszukujących (dingo, które atakują) tutaj $\varphi \subset X$, X oznacza arbitralnie utworzoną populację, $\vec{x}_i(t)$ wskazuje obecnego agenta poszukującego, $\vec{x}_i(t)$ pokazuje optymalny agent przeszukujący znaleziony w poprzedniej iteracji, β_1 wskazuje dowolną wartość utworzoną w ramach $[-2, 2]$; jest to czynnik skalujący, który zmienia wielkość i sens trajektorii dingo.

Poziom 2: Prześladowanie. Zwykle dingo polują na mniejszą ofiarę i pędzą, aż ofiara zostanie indywidualnie ustalona w następujący sposób:

$$\vec{x}_i(t+1) = \vec{x}_*(t) + \beta_1 * e^{\beta_2} * (\vec{x}_{r_i}(t) - \vec{x}_i(t)) \quad (5.2)$$

Gdzie $\vec{x}(t+1)$ pokazuje ruch dingo, $\vec{x}_i(t)$ wskazuje obecnego agenta poszukującego, $\vec{x}_*(t)$ oznacza optima; agent wyszukujący rozpoczyna od poprzedniej rundy, β_1 obejmuje identyczną wartość, β_2 oznacza dowolną wartość w granicach $[-1, 1]$, r_1 oznacza dowolną wartość w zakresie od 1 do wielkości maksimum agenta poszukującego (dingo), oraz $\vec{x}_{r_1}(t)$ wskazuje wybranego r_1 -tego agenta wyszukującego, gdzie $i \neq r_1$.

Poziom 3: Padlinożerca. Określa się je jako działanie, gdy dingo wykryje padlinę do zjedzenia, gdy swobodnie spacerują po siedlisku.

$$\vec{x}_i(t+1) = \frac{1}{2} \left[e^{\beta_2} * \vec{x}_{r_1}(t) - (-1)^\sigma * \vec{x}_i(t) \right] \quad (5.3)$$

gdzie $\vec{x}(t+1)$ wskazuje ruch dingo, β_2 ma taką samą wartość jak w równaniu. (5.2), r_1 oznacza dowolną wartość w zakresie 1 od maksymalnego rozmiaru agenta wyszukującego, $\vec{x}_{r_1}(t)$ reprezentuje r_1 -tego wybranego agenta wyszukującego, x_i oznacza obecnego agenta wyszukującego, przy czym $i \neq r_1$, a σ oznacza wygenerowaną wartość binarną dowolnie.

Poziom 4: Wskaźniki przeżycia Dingo. Wartość współczynnika istnienia dingo jest pokazana w następujący sposób:

$$Survival(i) = \frac{fitness_{max} - fitness(i)}{fitness_{max} - fitness_{min}} \quad (5.4)$$

W którym $fitness_{max}$ i $fitness_{min}$ oznaczają odpowiednio gorsze i optymalne wartości sprawności w istniejących pokoleniach, gdzie $fitness(i)$ reprezentuje obecną wartość sprawności i -tego agenta poszukującego. Wektor istnienia obejmuje znormalizowaną przydatność w granicach $[0, 1]$.

$$\vec{x}_i(t) = \vec{x}_*(t) + \frac{1}{2} \left[\vec{x}_{r_1}(t) - (-1)^\sigma * \vec{x}_{r_2}(t) \right] \quad (5.5)$$

Gdzie $\vec{x}_i(t)$ oznacza agenta poszukującego o niższym współczynniku przeżywalności, który zostałby zmodernizowany, r_1 i r_2 wskazują dowolną wartość w zakresie od 1 do maksymalnego rozmiaru wyszukiwania, $\vec{x}_*(t)$ oznacza optymalny agent wyszukujący znaleziony w poprzedniej iteracji, a σ oznacza wartość binarną (dingo), gdzie $r_1 \neq r_2$, $\vec{x}_{r_1}(t)$ i $\vec{x}_{r_2}(t)$ oznacza wybrany r_1 , r_2 -ty agent wyszukujący, a $\vec{x}_*(t)$ oznacza optymalne wyszukiwanie agent znaleziony w poprzedniej iteracji.

Kroki związane z planem zarządzania energią

Głównym celem jest zmniejszenie wykorzystania mocy sieci IoT wspomaganą przez 6G, a tym samym rozwój ekologicznej transmisji w sieci. GWH odgrywa znaczącą rolę w zarządzaniu wykorzystaniem energii, zwłaszcza w ograniczaniu liczby połączeń w sieci. Procedura wyboru GWH przechodzi przez rozwiązanie udoskonalone zredukowane widmem o wysokiej długości fali o wyższym rzędzie (HWSHO). Następnie oblicz funkcję dopasowania w połączeniu z różnymi zmiennymi, aby wybrać GWH. Parametr sprawności opisuje indywidualną zmienną sprawności i konsekwencje w prezentowanym badaniu. GWH zużywają dużo energii w porównaniu z węzłem będącym członkiem klastra, ponieważ poprzez

zbieranie od nich przekazują informacje do odbiornika. Dlatego też niezwykle istotne staje się wybranie tego węzła jako GWH powiększonego o maksymalną prawdopodobną wartość.

$$F_1 = \sum_{p=1}^{T_N} \frac{E_{rsd}(p)}{E_{in}(p)} \quad (5.6)$$

$$E_{rsd}(p) = E_{in}(p) - E_{txn} - E_{rxn} - E_{agg} \quad (5.7)$$

Ze względu na warunek wyższej energii wyboru węzła jako GH, początkowa zmienna przystosowania powinna zostać zwiększona w przypadku wyboru węzła. Gdy czujniki nawiążą interakcję z innym węzłem lub ujściem, większe znaczenie ma odległość transmisji węzła. W tej zmiennej przystosowania załóż stosunek odległości określonego węzła kandydującego do średniej odległości węzła od ujścia:

$$F_2 = \sum_{p=1}^{T_N} \frac{D_{avg}}{D_{NS}(p)} \quad (5.8)$$

$$D_{avg} = \frac{1}{T_N} \sum_{p=1}^{T_N} D_{NS}(p) \quad (5.9)$$

$$D_{NS} = \sqrt{(N_{x2} - N_{x1})^2 + (N_{y2} - N_{y1})^2} \quad (5.10)$$

Dodatkowo w równaniu (5.9), oblicz normalną odległość węzła od zlewu i oblicz odległość euklidesową pomiędzy dwoma węzłami. Po rozpoczęciu procesu sieciowego energia sieci maleje. Dlatego też przychodzi moment, gdy ilość martwych węzłów staje się wysoka, reprezentujemy trzecią zmienną sprawności, która określa stan pozostałej energii sieci (NRE). W przypadku wzmocnionego wyboru GWH zmienna musi być maksymalna:

$$F_3 = \frac{1}{T_N} \times \sum_{p=1}^{T_N} E_{rsd}(p) \quad (5.11)$$

Podczas pracy z urządzeniem IoT wspomaganym przez 6G występują różne problemy, które opóźniają transmisję między czujnikami. Zmienną jest współczynnik utraty ścieżki, który należy wziąć pod uwagę przy komunikacji pakietowej danych pomiędzy czujnikami. Pomaga w badaniu stanu zużycia energii w różnych sieciach bezprzewodowych. Obliczenie utraty ścieżki odbywa się w następujący sposób:

$$P_{THL}(D_T) = P_L(T_{DST}) + 10 \times T_N \times \log \left(\frac{D_T}{T_{DST}} \right) \quad (5.12)$$

Ponadto $P_L(T_{DST})$ oblicza się poprzez:

$$P_L(T_{DST}) = 10 \times \log \times (4\pi \times Tim_{delay} \times Fq) \times c_L \quad (5.13)$$

Równanie (5.14) służy do określenia odwrotności obliczonej utraty ścieżki na odcinku DT:

$$F_4 = \frac{1}{P_{THL}(D_T)} \quad (5.14)$$

Aby osiągnąć efektywny energetycznie wybór GW, należy zwiększyć czwartą zmienną, F_4 . Gdy węzeł klastra zużywa energię, efektywna wartość energii klastra maleje. Dlatego obliczamy piątą zmienną dopasowania, która musi być wyższa, aby wybrać węzeł kandydujący jako GWH:

$$F_5 = \sum_{p=1}^{N_{cl}} E_{rsd(p)} \quad (5.15)$$

Wieloobiektową funkcję przystosowania przekształca się w cel indywidualny poprzez włączenie różnych modułów, czyli parametru przystosowania, i pomnożenie ich do liniowej funkcji wagi w następujący sposób:

$$F = \lambda \times F_1 + \sigma \times F_2 + \gamma \times F_3 + \beta \times F_4 + \rho \times F_5 \quad (5.16)$$

$$\lambda + \delta + \gamma + \sigma + \beta = 1 \quad (5.17)$$

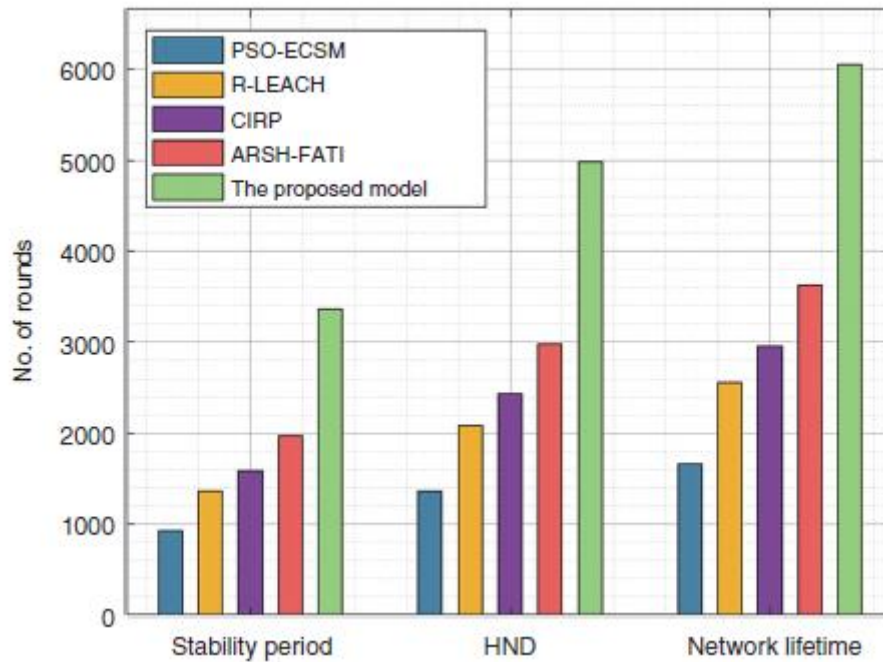
Powyższe równanie zapewnia ważoną sumę różnych czynników pomnożonych przez parametr. Dlatego wszystkie węzły są sprawdzane pod kątem funkcji przystosowania. Jako godzinę generacji (GH) wybierany jest węzeł o maksymalnej wartości sprawności.

Walidacja eksperymentalna

W tej sekcji omówiono walidację wydajności modelu AIDO-EM pod względem różnych wymiarów przy użyciu istniejących technik.

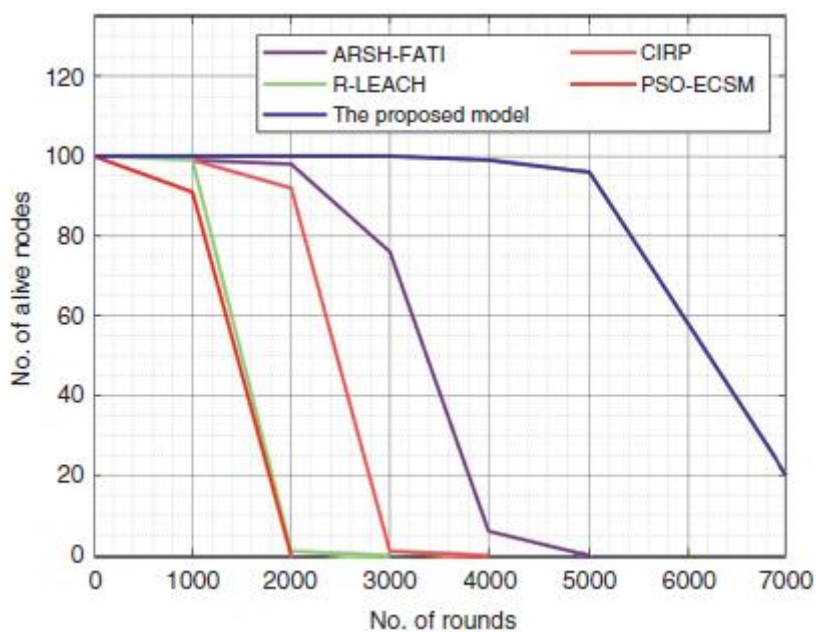
Tabela i Rysunek przedstawiają krótką analizę modelu AIDO-EM pod względem okresu stabilności, wyższych wymiarów (HND) i żywotności.

Methods	No. of rounds		
	Stability period	HND	Network lifetime
PSO-ECSM	930	1363	1656
R-LEACH	1363	2087	2552
CIRP	1587	2431	2949
ARSH-FATI	1966	2983	3621
Proposed model	3362	4983	6051



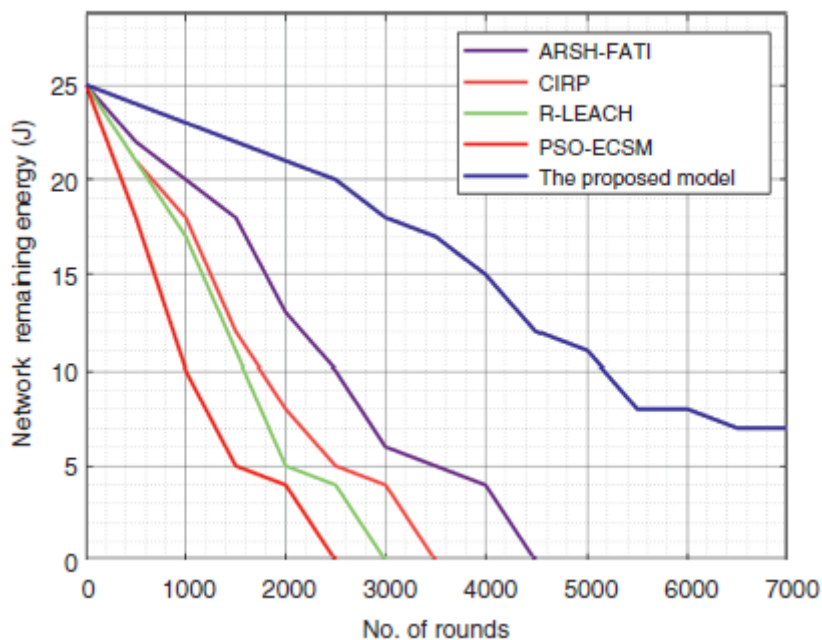
Wyniki wykazały, że model AIDO-EM uzyskał maksymalną wydajność w porównaniu z innymi metodami pod względem odrębnych miar. Pod względem okresu stabilności model AIDO-EM uzyskał dłuższy okres stabilności wynoszący 3362 nabojów, podczas gdy oparte na optymalizacji roju cząstek energooszczędne klastry i mobilność pochłaniania (PSOECSM), niezawodna niskoenergetyczna adaptacyjna hierarchia klastrów (R-LEACH), scentralizowana inteligentna i odporna ochrona (CIRP), a metody ARSH-FATI osiągnęły niższy okres stabilności wynoszący odpowiednio 930, 1363, 1587 i 1966 nabojów. Jednocześnie w odniesieniu do HND model AIDO-EM uzyskał wyższy okres stabilności wynoszący 4983 strzałów, natomiast metody PSO-ECSM, R-LEACH, CIRP i ARSH-FATI uzyskały niższy okres stabilności wynoszący 1363, 2087, Odpowiednio 2431 i 2983 nabojów. Co więcej, jeśli chodzi o czas życia, model AIDOEM osiągnął zwiększony okres stabilności wynoszący 6051 nabojów, podczas gdy metody PSO-ECSM, R-LEACH, CIRP i ARSH-FATI osiągnęły krótszy okres stabilności wynoszący 1656, 2552, 2949 i 3621 nabojów odpowiednio. Analizę wyników eksperymentalnych modelu AIDO-EM najnowszymi metodami pod względem liczby żywych węzłów (NOAN) przedstawiono w tabeli i na rysunku.

No. of alive nodes					
No. of rounds	ARSH-FATI	CIRP	R-LEACH	PSO-ECSM	Proposed model
0	100	100	100	100	100
1000	99	99	99	91	100
2000	98	92	1	0	100
3000	76	1	0	0	100
4000	6	0	0	0	99
5000	0	0	0	0	96
6000	0	0	0	0	58
7000	0	0	0	0	20



Wyniki wykazały, że model AIDO-EM osiągnął maksymalną wartość NOAN w porównaniu z istniejącą techniką we wszystkich rundach. Na przykład przy 1000 nabojach model AIDO-EM dał wyższy NOAN wynoszący 100, podczas gdy modele ARSH-FATI, CIRP, RLEACH i PSO-ECSM uzyskały niższy NOAN wynoszący odpowiednio 99, 99, 99 i 91. Następnie, przy 2000 nabojach, model AIDO-EM osiągnął zwiększoną wartość NOAN wynoszącą 98, podczas gdy modele ARSHFATI, CIRP, R-LEACH i PSO-ECSM osiągnęły zmniejszoną wartość NOAN wynoszącą odpowiednio 98, 92, 1 i 0. Zatem przy 3000 nabojach model AIDO-EM dał wyższy NOAN wynoszący 100, podczas gdy modele ARSH-FATI, CIRP, R-LEACH i PSO-ECSM uzyskały niższy NOAN wynoszący odpowiednio 76, 1, 0 i 0. Następnie, z 4000 nabojami, model AIDO-EM dał wyższy NOAN wynoszący 99, podczas gdy modele ARSH-FATI, CIRP, R-LEACH i PSO-ECSM uzyskały niższy NOAN wynoszący odpowiednio 6, 0, 0 i 0. Analizę wyników eksperymentalnych modelu AIDO-EM najnowszymi metodami w zakresie NRE przedstawiono w tabeli i rysunku.

Network remaining energy (NRE) (J)					
No. of rounds	ARSH-FATI	CIRP	R-LEACH	PSO-ECSM	Proposed model
0	25	25	25	25	25
500	22	21	21	18	24
1000	20	18	17	10	23
1500	18	12	11	5	22
2000	13	8	5	4	21
2500	10	5	4	0	20
3000	6	4	0	0	18
3500	5	0	0	0	17
4000	4	0	0	0	15
4500	0	0	0	0	12
5000	0	0	0	0	11
5500	0	0	0	0	8
6000	0	0	0	0	8
6500	0	0	0	0	7
7000	0	0	0	0	7

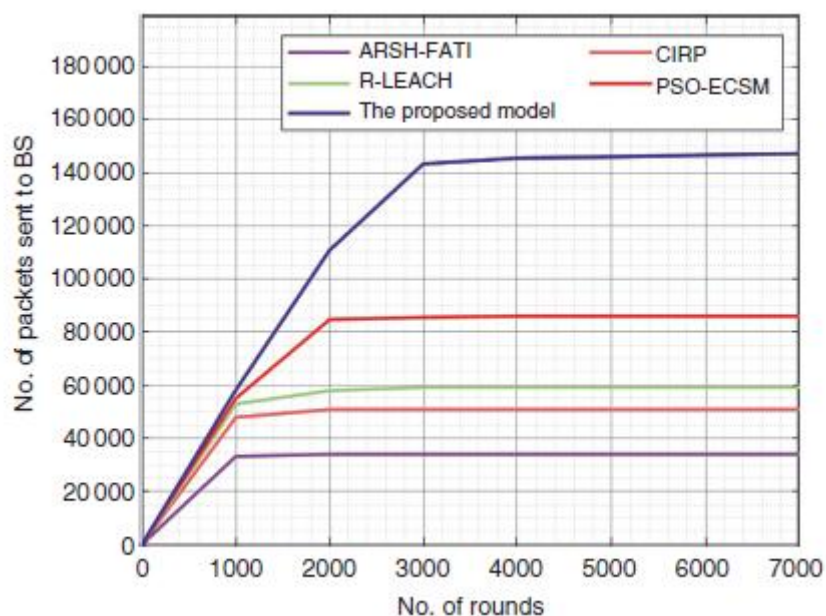


Wyniki wykazały, że model AIDO-EM osiągnął maksymalny NRE w stosunku do istniejącej techniki we wszystkich rundach. Na przykład przy 1000 nabożach model AIDO-EM dał wyższy NRE wynoszący 23 J, podczas gdy modele ARSH-FATI, CIRP, R-LEACH i PSO-ECSM uzyskały niższy NRE wynoszący 20, 18, 17 i 10 Odpowiednio J. Następnie przy 2000 nabożach model AIDO-EM osiągnął zwiększone NRE o 21 J, podczas gdy modele ARSH-FATI, CIRP, R-LEACH i PSO-ECSM osiągnęły zmniejszone NRE o 13, 8, 5 i 4 J,

odpowiednio. Następnie, przy 3000 nabojach, model AIDO-EM dał wyższy NRE wynoszący 18 J, podczas gdy modele ARSH-FATI, CIRP, R-LEACH i PSO-ECSM uzyskały niższy NRE wynoszący 6, 4, 0 i 0 J odpowiednio.

Następnie, z 4000 nabojami, model AIDO-EM dał wyższy NRE wynoszący 15 J, podczas gdy modele ARSH-FATI, CIRP, R-LEACH i PSO-ECSM uzyskały niższy NRE wynoszący 4, 0, 0 i 0, odpowiednio. Badanie porównawcze modelu AIDO-EM z najnowszymi metodami pod względem liczby pakietów wysyłanych do BS (NOPS-BS) przedstawiono w tabeli i rysunku.

No. of packets sent to BS (NOPS-BS)					
No. of rounds	ARSH-FATI	CIRP	R-LEACH	PSO-ECSM	Proposed model
0	0	0	0	0	0
1000	33 148	47 809	52 835	54 930	58 024
2000	33 985	50 741	57 862	84 671	110 804
3000	33 985	50 741	59 119	85 508	143 382
4000	33 985	50 741	59 119	85 927	145 477
5000	33 985	50 741	59 119	85 927	145 990
6000	33 985	50 741	59 119	85 927	146 665
7000	33 985	50 741	59 119	85 927	147 084



Wartości eksperymentalne wykazały, że model AIDO-EM osiągnął zwiększoną liczbę NOPS-BS w porównaniu z istniejącą techniką we wszystkich rundach. Na przykład przy 1000 nabojach model AIDO-EM osiągnął poprawę NOPS-BS wynoszącą 58 024, podczas gdy modele ARSH-FATI, CIRP, RLEACH i PSO-ECSM zaowocowały zmniejszeniem NOPS-BS wynoszącym 33 148, 47 809, Odpowiednio 52 835 i 54 930. Jednocześnie przy 2000 nabojach model AIDO-EM osiągnął zwiększoną NOPS-BS o 110 804, podczas gdy modele ARSH-FATI, CIRP, R-LEACH i PSO-ECSM osiągnęły obniżoną NOPS-BS o 3 3985, 50

741, odpowiednio 57 862 i 84 671. Jednocześnie przy 3000 nabojach model AIDO-EM dał wyższy NOPS-BS wynoszący 143 382, podczas gdy modele ARSH-FATI, CIRP, R-LEACH i PSO-ECSM uzyskały niższy NOPS-BS wynoszący 33 985, 50 741 , odpowiednio 59 119 i 85 508. Z powyższej analizy wyników wynika, że model AIDOEM przewyższył wszystkie inne istniejące metody pod względem odrębnych miar.

Wniosek

W tym badaniu opracowano nowatorską technikę AIDO-EM w celu osiągnięcia efektywnej efektywności energetycznej w sieciach 6G. Zaprezentowana technika AIDO-EM ma na celu osiągnięcie minimalnego zużycia energii i maksymalnej żywotności urządzeń IoT 6 generacji. Ponadto zastosowano nowatorską metodę DOA w przypadku routingu z obsługą klastrów, aby osiągnąć efektywną dystrybucję danych pomiędzy urządzeniami i wybrać efektywne GWH. DOA to inspirowana biologią technika globalnej optymalizacji, która stymuluje strategię polowania na dingo. Aby wykazać ulepszone wyniki techniki AIDO-EM, przeprowadzono serię symulacji, a wyniki wykazały lepszą wydajność w porównaniu z najnowszymi, najnowocześniejszymi podejściami. Dlatego technikę AIDO-EM można wykorzystać jako skuteczny sposób osiągnięcia maksymalnego zarządzania energią w sieciach 6G.