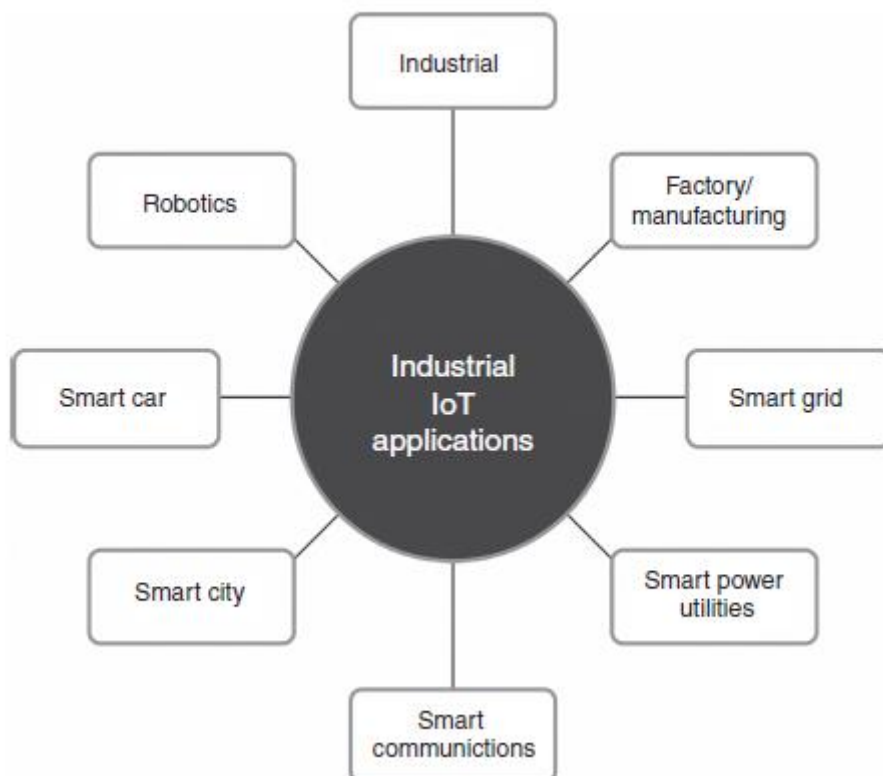


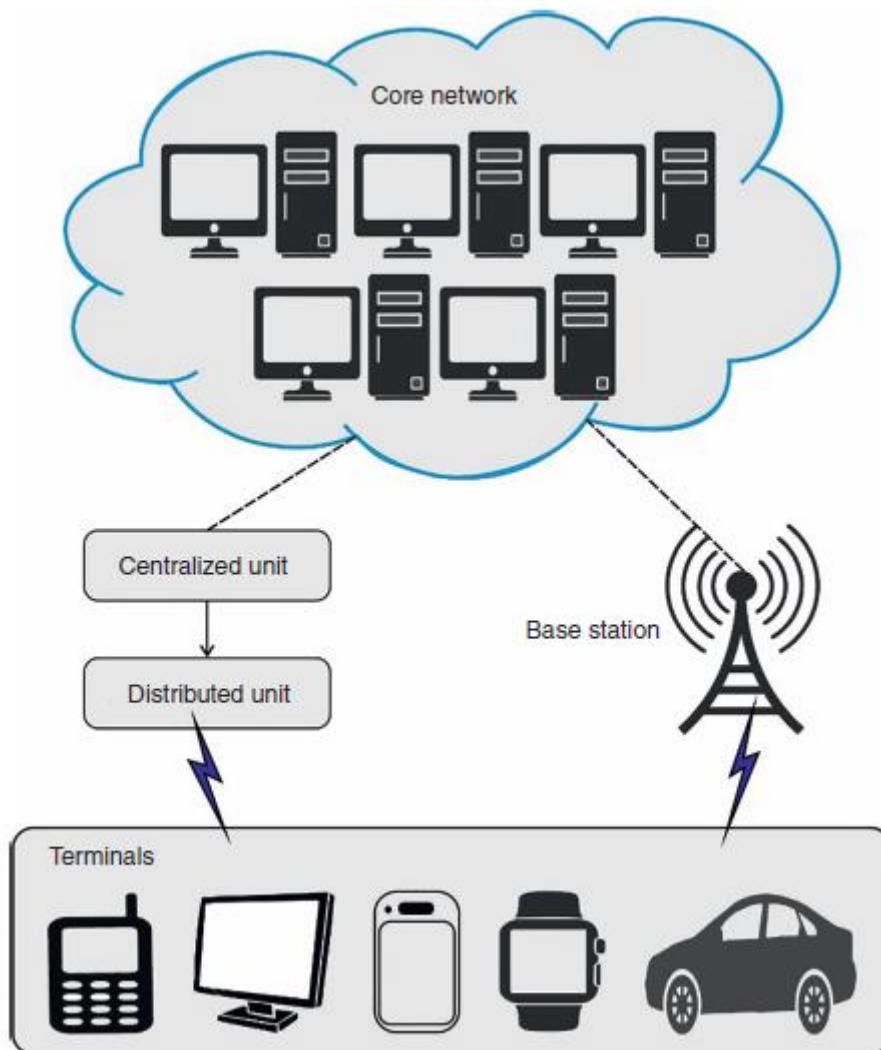
## **Metoda kwantyzacji wektorowej oparta na algorytmie Crow Search do kompresji obrazu w środowisku przemysłowego Internetu rzeczy z obsługą 6G.**

### **Wstęp**

Adaptacja nowych zastosowań i trendów technologicznych Internetu Rzeczy (IoT) w systemie przemysłowym ma dominujący wpływ na rozwój Przemysłowego Internetu Rzeczy (IIoT). IIoT pomaga jako nowatorska forma IoT w dziedzinie przemysłu poprzez usystematyzowanie inteligentnych obiektów do komunikacji, wykrywania, gromadzenia i przetwarzania zdarzeń w czasie rzeczywistym w systemach przemysłowych. Ogólnie rzecz biorąc, IIoT jest określany przez IoT, ponieważ jest stosowany w różnych rodzajach przemysłu, w tym w logistyce, transporcie, energetyce lub usługach użyteczności publicznej, produkcji (Przemysł 4.0), przemyśle naftowym, górnictwie, gazie, lotnictwie, metalach itp. . Przy projektowaniu IoT uwzględniono postęp w inteligentnym środowisku, automatyce domowej, sieciach czujników i inteligentnych miastach do zastosowań wojskowych i cywilnych. Dzięki obecnemu rozwojowi w dziedzinie technik teledetekcyjnych łatwiej jest przechwytywać wysokiej jakości obrazy teledetekcyjne za pomocą różnych satelitów wraz z urządzeniami detekcyjnymi, co jest z pewnością korzystne w zastosowaniach teledetekcyjnych. Jednak ogromna liczba danych, tj. obrazów teledetekcyjnych, stała się złożonym problemem w zakresie transmisji i przechowywania. W rezultacie technika kompresji stała się niezbędną w przetwarzaniu obrazu teledetekcyjnego. Ogólnie rzecz biorąc, do kompresji obrazów teledetekcyjnych stosowana jest tradycyjna metoda kompresji, JPEG2000 i ulepszony standard. Jednakże obraz teledetekcyjny posiada odrębne cechy, w tym przejrzyste dane, precyzyjną materię geograficzną, złożone dane przestrzenne itp. Domniemane jest, że ten tradycyjny model nie traktuje odpowiednio danych o wysokiej częstotliwości i skupia się jedynie na zachowaniu kilku informacji o niskiej częstotliwości, których nie można korzystać. Aby skompresować obrazy teledetekcyjne, należy uwzględnić tę cechę podczas stosowania metody kompresji. Rysunek przedstawia zastosowania techniki IIoT.



Metoda kwantyzacji wektorowej (VQ) przewyższała inne techniki, w tym różnicowe PCM (DPCM), modulację impulsowo-kodową (PCM) i adaptacyjną DPCM, która należy do klasy metod kwantyzacji skalarnej. VQ to bardziej znana metoda kompresji stratnej obrazu, która jest głównie metodą klastrową c-średnich, szeroko stosowaną do rozpoznawania wzorców i rozpoznawania mowy, kompresji obrazu, kodowania obrazu i wykrywania twarzy ze względu na jej zalety, które obejmują prostą strukturę dekodowania i wyższy stopień kompresji, który zapewnia mniejsze zniekształcenia. Badania dotyczą powiązania algorytmu optymalizacji ewolucyjnej z podejściem Linde'a – Graya – Buzo (LGB) zaproponowano nową metodę kompresji. Najpierw zdekorrelowano widmowo obraz za pomocą analizy składowych głównych (PCA) i VQ, a później zastosowano JPEG2000 do składowej głównej (PC), wykorzystując korelację przestrzenną do kompresji. Następnie wykorzystaj fakt, że wymiar redukcji pozwala zachować duże dane w komponencie początkowym i przydziela większą głębię początkowemu komputerowi PC. Lu i inni przedstawili strukturę głębokiej splotowej sieci neuronowej (DCNN) do kompresji obrazu, w ramach której dekodery, koder i kwantyzator uczą się wspólnie. W szczególności zaprezentowano sieć kwantyzacji wektorów splotu (VQNet) do kwantyzacji wektora cech ilustracji obrazu, przy czym wektor reprezentacyjny VQNet jest zbiorowo wzmacniany przez inne zmienne sieciowe poprzez kompleksowe szkolenie. Mimo że wiele obecnych metod opartych na DCNN zostało przeszkolonych na dużych zbiorach danych, dalej wdrażamy dostrajanie kodera i kodu utworzonego przez VQNet na obrazie wejściowym, aby dodatkowo poprawić wydajność kompresji. Rysunek przedstawia komponenty sieci 6G obsługujących usługi.



Zhou i inni przedstawili dwie efektywne metody kompresji obrazów cyfrowych z metodą selekcji adoktywnej do malowania obrazów, VQ i kwantyzacji wektorów dopasowania bocznego (SMVQ). Następnie po stronie nadajnika nowy obraz jest rozdzielany na bloki, a kompresja może być przeprowadzana blok po bloku. W tym systemie blok we wstępnie ustalonej lokalizacji jest początkowo kompresowany przez VQ. W przypadku wszystkich pozostałych bloków idealną technikę kompresji (dla systemu początkowego wraz z malowaniem lub VQ, a dla następnego systemu obejmuje malowanie, VQ i SMVQ) można opisać, obliczając błąd średniokwadratowy (MSE) pomiędzy oryginałem bloku i w wyniku malowania oraz w porównaniu z wcześniej określonym progiem] przedstawiono podejście VQ do kodowania obrazów z rozkładem biortogonalnym za pomocą algorytmu optymalizacji wyszukiwania wzorców hybrydowych (hADEPS) i ewolucji różniczkowej adoktywnej (ADE). ADE jest przyjętą formą ewolucji różniczkowej (DE), w której proces mutacji jest tworzony w sposób adoktywny zgodnie z wartością przystosowania lub rosnącymi lub malejącymi funkcjami celu i weryfikowany na 2 standardowych funkcjach arytmetycznych. Zaprezentowano podejście zwane zintegrowanym środowiskiem programistycznym (IDE)-LBG, które wykorzystuje ulepszone podejście DE oprócz Linde-Buzo-Gray (LBG) do tworzenia optymalnego słownika VQ. Prezentowane IDE działa skutecznie w porównaniu do konwencjonalnego DE z modyfikacją mechanizmu kontroli brzegowej i współczynnika skalowania. IDE stanowi dobre rozwiązanie poprzez efektywne wykorzystanie i eksplorację przestrzeni poszukiwań. Następnie przedstawiono optymalne rozwiązanie osiągnięte przez IDE jako podstawowy

słownik dla LBG. W tym badaniu przedstawiono nowatorskie podejście do kwantyzacji wektorowej oparte na algorytmie wyszukiwania wron w celu kompresji obrazu w środowisku IIoT z obsługą 6G, zwane modelem CSAVQ-ICIIoT. Proponowany model CSAVQ-ICIIoT ma na celu osiągnięcie efektywnej kompresji obrazu poprzez optymalizację procesu konstruowania książki kodowej na platformie IIoT obsługującej 6G. Technika CSAVQ-ICIIoT obejmuje LBG z techniką VQ do kompresji obrazu. Poza tym optymalny proces konstrukcji książki kodowej realizowany jest przy wykorzystaniu algorytmu wyszukiwania wronowego (CSA). Aby zbadać poprawę wydajności modelu CSAVQ-ICIIoT, przeprowadza się szczegółową analizę wyników, a wyniki są sprawdzane pod kątem kilku mierników.

### Proponowany model

W ramach tego badania opracowano nowy model CSAVQ-ICIIoT umożliwiający skuteczną kompresję obrazu poprzez optymalizację procesu konstruowania książki kodowej na platformie IIoT obsługującej technologię 6G. Technika CSAVQ-ICIIoT obejmuje LBG z techniką VQ do kompresji obrazu. Poza tym optymalny proces konstruowania książki kodowej realizowany jest przy użyciu CSA, co poprawia efektywność kompresji.

### Przegląd VQ

VQ to metoda kompresji stratnej danych w kodowaniu blokowym. Generowanie książki kodowej nazywane jest podstawową procedurą VQ. Załóżmy, że rozmiar nowego obrazu  $Y = \{y_{ij}\}$  wynosi  $M \times M$

$$N_b = \left\lfloor \frac{N}{n} \right\rfloor \times \left\lfloor \frac{N}{n} \right\rfloor$$

piksela dzielącego różne bloki o rozmiarze  $n \times n$  pikseli [16]. Innymi słowy, istnieje

bloków reprezentujących grupę wektorów wejściowych  $\{x_i, i = 1, 2, \dots, N_b\}$ . Rozważ  $L$  jako  $n \times n$ .

Wektor wejściowy  $\chi_i, \chi_i \in \mathfrak{R}^L$ , gdzie  $\mathfrak{R}^L$  jest przestrzenią euklidesową o wymiarze  $L$ . Książka kodowa

$C$  obejmuje słowo kodowe  $N_c$  o wymiarze  $L$ , to znaczy  $\{c_1, c_2, \dots, c_{N_c}\}$ ,  $c_j \in \mathfrak{R}^L, \forall j = 1, 2, \dots, N_c$ .

Wszystkie wektory wejściowe są oznaczane jako wektor wierszowy  $\chi_i = (x_{i1}, x_{i2}, \dots, x_{iL})$ , a  $j$ -te słowo kodowe słownika jest reprezentowane przez  $c_j = (c_{j1}, c_{j2}, \dots, c_{jL})$ . Technika VQ przypisuje wektor wejściowy do powiązanego słowa kodowego, co w końcu zastępuje powiązany wektor wejściowy, aby osiągnąć cel kompresji. Optymalizacja  $C$  pod względem MSE wyraża się poprzez minimalizację funkcji zniekształcenia  $D$ . Ogólnie rzecz biorąc, im mniejsza wartość  $D$ , tym lepsza będzie jakość  $C$ .

$$D(C) = \frac{1}{N_b} \sum_{j=1}^{N_c} \sum_{i=1}^{N_b} \mu_{ij} \cdot \|x_i - c_j\|^2 \quad (4.1)$$

podlega następującym ograniczeniom:

$$\sum_{j=1}^{N_c} \mu_{ij} = 1, \quad \forall i \in \{1, 2, \dots, N_b\} \quad (4.2)$$

$$\mu_{ij} = \begin{cases} 1 & \text{if } \chi_i \text{ is in the } j\text{th cluster;} \\ 0 & \text{otherwise} \end{cases} \quad (4.3)$$

również:

$$L_k \leq c_{jk} \leq U_k, \quad k = 1, 2, \dots, L \quad (4.4)$$

Gdzie  $L_k$  oznacza minimum  $k$ -tego elementu w każdym wektorze uczącym, a  $U_k$  oznacza maksimum  $k$ -tego elementu w każdym wektorze wejściowym.  $\|x - c\|$  reprezentuje odległość euklidesową między wektorem  $x$  i słowem kodowym  $c$ . Istnieją dwa podstawowe warunki optymalnego kwantyzatora wektorowego.

1) Podział  $R_j$ ,  $j = 1, \dots, N_c$  powinien być spełniony

$$R_j \supset \{x \in \mathcal{X} : d(x, c_j) < d(x, c_k), \quad \forall k \neq j\}. \quad (4.5)$$

2) Słowo kodowe  $c_j$  powinno być podane przez centroidę  $R_j$ :

$$c_j = \frac{1}{N_j} \sum_{i=1}^{N_j} x_i, \quad x_i \in R_j, \quad (4.6)$$

Gdzie  $N_j$  wskazuje, że całkowita ilość wektora należy do  $R_j$ .

### Model LBG

Podjęcie to nazywane jest uogólnionym algorytmem Lloyd'a (GLA) lub LBG. Wykorzystuje dwa wyżej wymienione warunki do wektora wejściowego w celu zdefiniowania słownika. Załóżmy, że wektor wejściowy,  $x_i$ ,  $i = 1, 2, \dots, N_b$ , funkcja odległości  $d$  i podstawowe słowo kodowe  $c_j(0)$ ,  $j = 1, \dots, N_c$ . LBG wykorzystuje dwa warunki do wygenerowania optymalnego słownika:

1) Podziel wektor wejściowy na różne grupy, stosując zasadę minimalnej odległości. Wynikowy podział jest zapisywany w binarnej macierzy wskaźników  $N_b \times N_c$ . Element  $U$  jest określany przez:

$$\mu_{ij} = \begin{cases} 1 & \text{if } d(x_i, c_j(k)) = \min d(x_i, c_p) \\ 0 & \text{otherwise} \end{cases} \quad (4.7)$$

2) Zdefiniuj środek ciężkości wszystkich przegród. Zamień stare słowo kodowe na ten centroid:

$$c_j(k+1) = \frac{\sum_{i=1}^{N_b} \mu_{ij} x_i}{\sum_{i=1}^{N_b} \mu_{ij}}, \quad j = 1, \dots, N_c. \quad (4.8)$$

3) Powtarzaj kroki (1) i (2), aż nie będzie żadnych zmian  $c_j$ ,  $j = 1, \dots, N_c$  w większym stopniu.

### Model LBG

Podjęcie to nazywane jest uogólnionym algorytmem Lloyd'a (GLA) lub LBG. Wykorzystuje dwa wyżej wymienione warunki do wektora wejściowego w celu zdefiniowania słownika. Załóżmy, że wektor wejściowy,  $x_i$ ,  $i = 1, 2, \dots, N_b$ , funkcja odległości  $d$  i podstawowe słowo kodowe  $c_j(0)$ ,  $j = 1, \dots, N_c$ . LBG wykorzystuje dwa warunki do wygenerowania optymalnego słownika:

1) Podziel wektor wejściowy na różne grupy, stosując zasadę minimalnej odległości. Wynikowy podział jest zapisywany w binarnej macierzy wskaźników  $N_b \times N_c$ . Element  $U$  jest określany przez:

$$\mu_{ij} = \begin{cases} 1 & \text{if } d(x_i, c_j(k)) = \min d(x_i, c_p) \\ 0 & \text{otherwise} \end{cases} \quad (4.7)$$

2) Zdefiniuj środek ciężkości wszystkich przegród. Zamień stare słowo kodowe na ten centroid:

$$c_j(k+1) = \frac{\sum_{l=1}^{N_b} \mu_{lj} x_l}{\sum_{l=1}^{N_b} \mu_{lj}}, \quad j = 1, \dots, N_c. \quad (4.8)$$

3) Powtarzaj kroki (1) i (2), aż nie będzie żadnych zmian  $c_j$ ,  $j = 1, \dots, N_c$  w większym stopniu.

### Proces zaangażowany w model CSAVQ-ICIoT

Wrony uważane są za najmądrzejsze stworzenia wśród ptaków. Mają duże mózgi w porównaniu do rozmiarów ciała. Jeśli chodzi o relację mózg-ciało, jego mózg jest nieco mniejszy w porównaniu z człowiekiem. Posiadają zdolność wytwarzania narzędzi i wykazali się samowiedzą w testach lustrzanych. Wiedzą o sobie w momencie wystąpienia zagrożenia i zapamiętują twarze [17]. Co więcej, dzielą się danymi, w skomplikowany sposób stosują narzędzia i zapamiętują swoją sekretną pozycję żywieniową. Obserwują różne ptaki, śledzą, gdzie ptak trzymał pożywienie w tajemnicy i kradną je, gdy ptak opuści swoje stanowisko. Po dokonaniu rabunku postępują ostrożnie, m.in. po tym zmienią kryjówkę, aby uniknąć ofiary. Wykorzystują swoją wiedzę do ustalenia pozostałego złodzieja i zabezpieczonego sposobu obrony swojej żywności przed kradzieżą przez innych. Następujące właściwości pokazują standard wron:

- Wrony pamiętają o położeniu sekretnego miejsca.
- Wrony żyją w grupie.
- Wrony zabezpieczają swoją kryjówkę przed możliwością kradzieży.
- Wrony podążają za sobą, aby dokonać kradzieży.

Najwyraźniej istnieją środowiska N-wymiarowe obejmujące

różne wrony. Ogółem wrony reprezentują  $C$ , a pozycja wrony  $u$  w czasie (iteracji)  $iter$  w przestrzeni poszukiwań (SS) jest zdefiniowana w następujący sposób:

$$V^{u,iter}(p = 1, 2, \dots, C; iter = 1, 2, \dots, iter_{max}) \quad (4.9)$$

Gdzie  $V^{u,iter} = [V_1^{u,iter}, V_2^{u,iter}, \dots, V_c^{u,iter}]$  a  $iter_{max}$  oznacza iterację z maksymalną wartością. Wszystkie wrony mają pamięć, w której zapisana została pozycja tajnego miejsca. W momencie iteracji położenie sekretnego miejsca wrony  $u$  jest określone jako  $s^{u,iter}$ . To najlepsza pozycja, jaką osiągnęłaś do tej pory. W pamięci wszystkich wron została zapisana pozycja lepszego doświadczenia. Wrona zaczyna szukać dobrych źródeł w środowisku. Załóżmy, że w iteracji wrona  $v$  musi przejść do swojej sekretnej pozycji,  $s^{v,iter}$ . W iteracji wrona  $u$  ustaliła, że wysłodzi wronę  $v$  do tajnej pozycji wrony  $v$ . W tej fazie mogą mieć miejsce dwa zdarzenia. Zdarzenie 1: Wrona  $v$  nie ma pojęcia, że wrona  $u$  ją śledzi. Następnie wrona  $u$  osiąga tajną pozycję wrony  $v$ .

$$V^{u,iter+1} = V^{u,iter} + k_j \times fl^{u,iter} \times (S^{v,iter} - V^{u,iter}) \quad (4.10)$$


Gdzie  $k_j$  oznacza dowolną wartość o rozkładzie standardowym od 0 do 1, a  $fl^{u,iter}$  reprezentuje długość lotu wrony  $u$  w iteracji. Minimalna wartość  $fl$  prowadzi do wyszukiwania lokalnego, a maksymalna wartość do wyników wyszukiwania globalnego. Zdarzenie 2: Wrona wie, że wrona ją śledziła. Dlatego, aby chronić swoje tajne stanowisko przed kradzieżą, wrona oszukuje wronę, przechodząc na inne stanowisko SS.

$$V^{u,iter+1} = \begin{cases} V^{u,iter} + k_j \times fl^{u,iter} \times (S^{v,iter} - V^{u,iter}) & k_j \geq AWP^{v,iter} \\ a \text{ random location} & \text{otherwise} \end{cases} \quad (4.11)$$

W którym  $AWP^{v,iter}$  reprezentuje możliwość świadomości wrony v w iteracji. Cała procedura techniki CSAVQ-ICIIoT była krótka i obejmowała pięć wymienionych tutaj podprocesów. Początkowo parametr jest inicjalizowany, w którym wygenerowany słownik techniką LBG wybiera rozwiązania podstawowe [18]. Po zainicjowaniu metody wybierane są obecne optymalne rozwiązania, które decydują o przydatności całego miejsca i określają miejsce o maksymalnej sprawności jako najlepsze. W przypadku wypracowania obecnie optymalnego rozwiązania, w procesie roamingu powstają nowatorskie rozwiązania. Następnie wprowadzono technikę rankingową, w ramach której w kolejnym kroku rozwiązanie jest klasyfikowane w zależności od sprzężenia zwrotnego (FF) i wybierane jest rozwiązanie optymalne.


### Wyniki i dyskusja

Proponowany model symulowany jest z wykorzystaniem zbioru danych porównawczych [19]. Zbiór danych zawiera obrazy teledetekcyjne o wysokiej rozdzielczości. W pracy wykonano zestaw sześciu obrazów o wymiarach 1024×1024 i rozmiarze 3072 kB. Kilka przykładowych obrazów pokazano na rysunku .



Krótkie badanie współczynnika kompresji (CR) modelu CSAVQ-ICIloT z istniejącymi modelami na różnych obrazach przedstawiono w Tabeli i Rysunku .

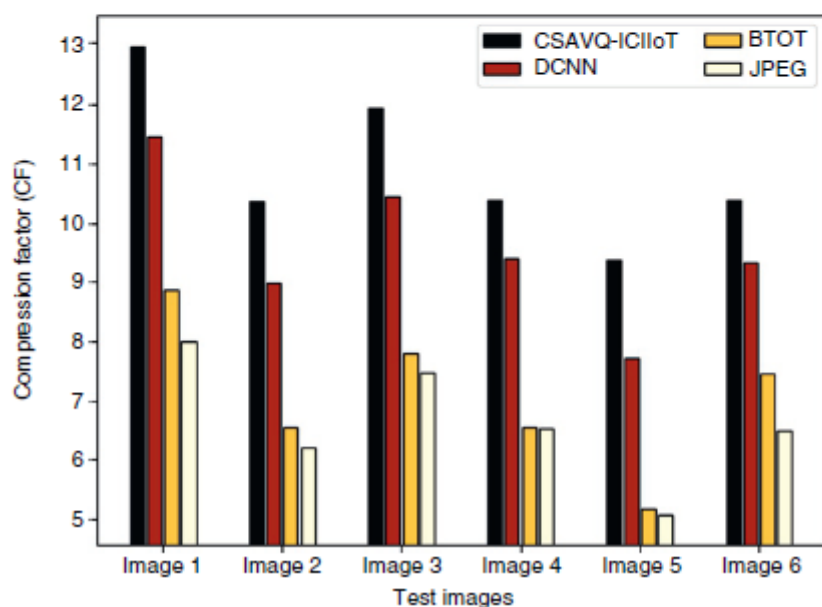
Test images	Compression ratio (CR)			
	CSAVQ-ICIloT	DCNN	BTOT	JPEG
Image 1	0.0735	0.0872	0.1126	0.1250
Image 2	0.1048	0.1113	0.1527	0.1611
Image 3	0.0846	0.0957	0.1283	0.1338
Image 4	0.0937	0.1064	0.1523	0.1533
Image 5	0.1184	0.1296	0.1934	0.1969
Image 6	0.0946	0.1071	0.1341	0.1543



Wyniki wykazały, że model CSAVQ-ICIloT spowodował niższe wartości CR w porównaniu z innymi metodami. Na przykład na obrazie 1 model CSAVQ-ICIloT uzyskał minimalną CR wynoszącą 0,0735, podczas gdy techniki DCNN, BTOT i JPEG osiągnęły maksymalną CR wynoszącą odpowiednio 0,0872, 0,1126 i 0,1250. Ponadto na obrazie 3 technika CSAVQ-ICIloT uzyskała mniejszy CR wynoszący 0,0846, podczas gdy techniki DCNN, BTOT i JPEG osiągnęły maksymalny CR wynoszący odpowiednio 0,0957, 0,1283 i 0,1338. Co więcej, na obrazie 6, podejście CSAVQ-ICIloT uzyskało niższy CR wynoszący 0,0946, podczas gdy techniki DCNN, BTOT i JPEG osiągnęły wyższy CR wynoszący odpowiednio 0,1071, 0,1341 i 0,1543. Tabela i Rysunek ilustrują badanie współczynnika kompresji (CF) modelu CSAVQ-ICIloT przy użyciu istniejących technik.

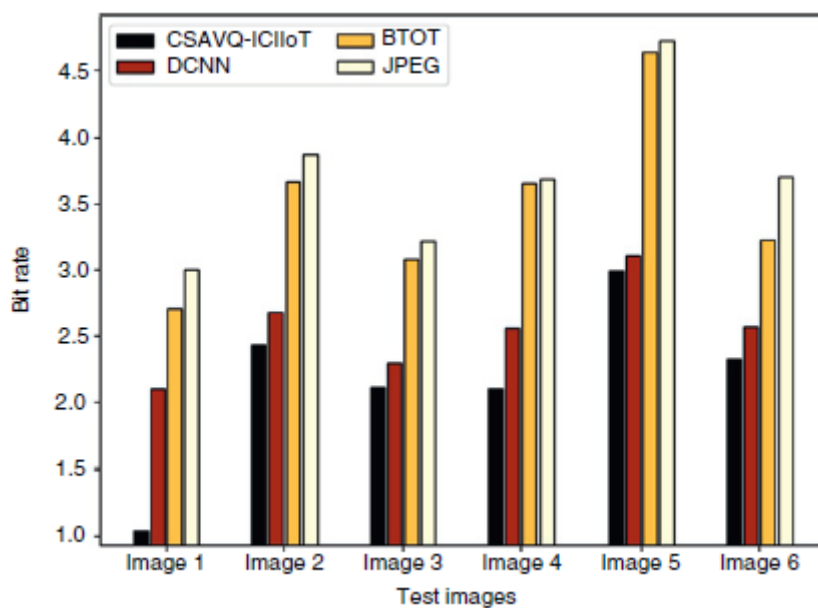


Test images	Compression factor (CF)			
	CSAVQ-ICIIoT	DCNN	BTOT	JPEG
Image 1	12.9505	11.4627	8.8786	8.0000
Image 2	10.3662	8.982 50	6.5501	6.2061
Image 3	11.9377	10.4490	7.7970	7.4745
Image 4	10.3789	9.394 50	6.5641	6.5223
Image 5	09.3766	7.718 60	5.1717	5.0777
Image 6	10.3764	9.337 40	7.4563	6.4810



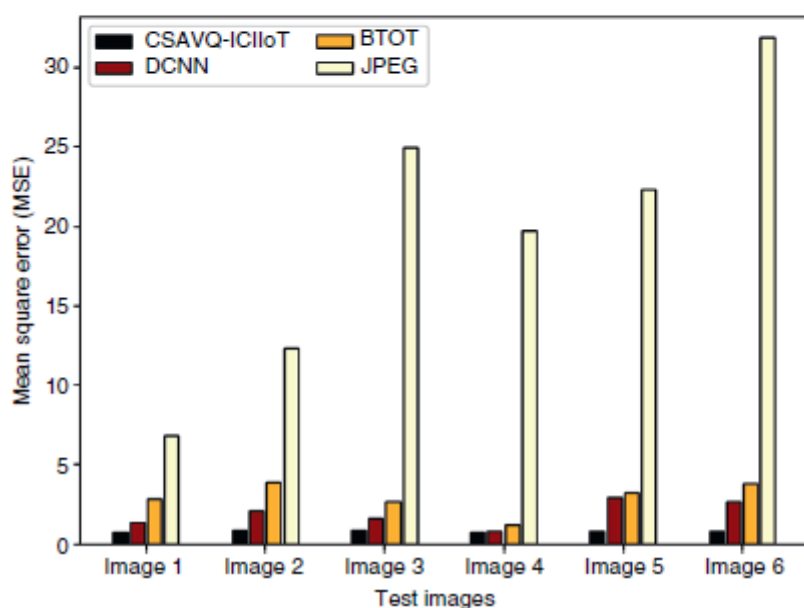
Wyniki wykazały, że model CSAVQ-ICIIoT ma zdolność osiągnięcia maksymalnej wydajności kompresji w porównaniu z innymi technikami. Na przykład na obrazku 1 model CSAVQ-ICIIoT oferuje wyższy CF wynoszący 12,9505, podczas gdy techniki DCNN, BTOT i JPEG dały niższy współczynnik CF wynoszący 11,4627, 8,8786 i 8,0000. Jednocześnie na obrazku 3 model CSAVQ-ICIIoT ma możliwość do uzyskania maksymalnego CF wynoszącego 11,9377, podczas gdy systemy DCNN, BTOT i JPEG dały minimalny CF wynoszący 10,4490, 7,7970 i 7,4745. Jednocześnie na obrazie 6 technika CSAVQ-ICIIoT zapewniła wyższy CF wynoszący 10,3764, podczas gdy metody DCNN, BTOT i JPEG dały minimalny współczynnik CF wynoszący 9,337·40, 7,4563 i 6,4810. Szczegółowe badanie podstawowych zasobów (BR) techniki CSAVQ-ICIIoT z istniejącymi podejściami na różnych obrazach przedstawiono w Tabeli i Rysunku

Test images	Bit rate			
	CSAVQ-ICIIoT	DCNN	BTOT	JPEG
Image 1	1.0387	2.0938	2.7031	3.0000
Image 2	2.4332	2.6719	3.6641	3.8672
Image 3	2.1038	2.2969	3.0781	3.2109
Image 4	2.0937	2.5547	3.6563	3.6797
Image 5	2.9846	3.1094	4.6406	4.7266
Image 6	2.3210	2.5703	3.2188	3.7031



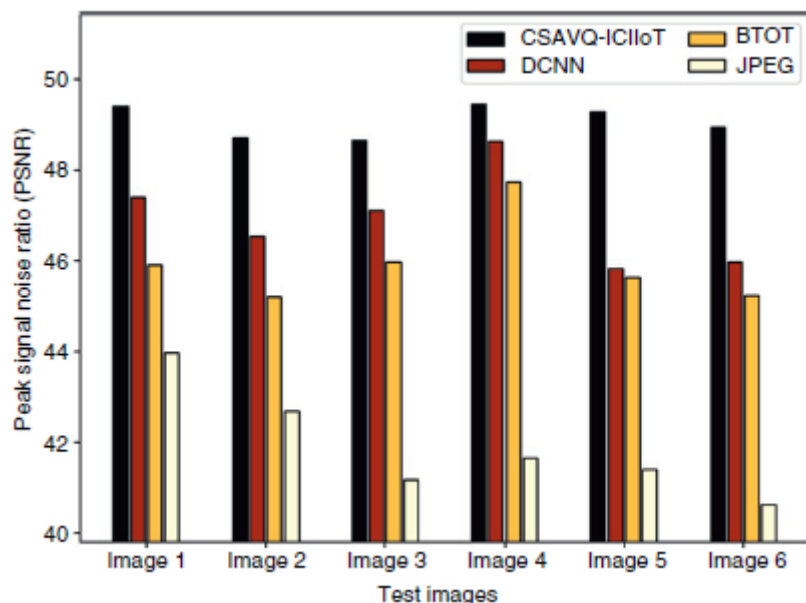
Wyniki wykazały, że technika CSAVQ-ICIIoT spowodowała niższe wartości BR w porównaniu z innymi metodami. Na przykład na obrazie 1 model CSAVQ-ICIIoT uzyskał minimalny BR wynoszący 1,0387, podczas gdy podejścia DCNN, BTOT i JPEG uzyskały zwiększony BR odpowiednio 2,0938, 2,7031 i 3,0000. Następnie, na obrazie 3, system CSAVQ-ICIIoT osiągnął minimalny BR wynoszący 2,1038, podczas gdy techniki DCNN, BTOT i JPEG osiągnęły doskonały BR wynoszący odpowiednio 2,2969, 3,0781 i 3,2109. Ostatecznie na obrazie 6 metodologia CSAVQ-ICIIoT uzyskała zmniejszony BR wynoszący 2,3210, podczas gdy techniki DCNN, BTOT i JPEG osiągnęły zwiększony BR odpowiednio 2,5703, 3,2188 i 3,7031. Porównawcze badanie MSE modelu CSAVQ-ICIIoT z istniejącymi modelami na różnych obrazach przedstawiono w Tabeli i na rysunku .

Test images	Mean square error (MSE)			
	CSAVQ-ICIIoT	DCNN	BTOT	JPEG
Image 1	0.75	1.40	2.80	06.80
Image 2	0.88	2.10	3.90	12.30
Image 3	0.89	1.60	2.70	24.90
Image 4	0.74	0.80	1.20	19.70
Image 5	0.77	2.90	3.20	22.30
Image 6	0.83	2.70	3.80	31.90



Wyniki wykazały, że model CSAVQ-ICIIoT spowodował niższe wartości MSE w porównaniu z innymi metodami. Na przykład na obrazie 1 model CSAVQ-ICIIoT uzyskał zmniejszony MSE wynoszący 0,75, podczas gdy podejścia DCNN, BTOT i JPEG osiągnęły lepsze MSE wynoszące odpowiednio 1,40, 2,80 i 6,80. Oprócz obrazu 3, technika CSAVQ-ICIIoT osiągnęła minimalny MSE wynoszący 0,89, podczas gdy techniki DCNN, BTOT i JPEG osiągnęły zwiększone MSE wynoszące odpowiednio 1,60, 2,70 i 24,90. Wreszcie na obrazie 6 model CSAVQ-ICIIoT uzyskał mniejsze MSE wynoszące 0,83, podczas gdy techniki DCNN, BTOT i JPEG osiągnęły zwiększone MSE wynoszące odpowiednio 2,70, 3,80 i 31,90. Tabela i Rysunek przedstawiają badanie PSNR podejścia CSAVQ-ICIIoT przy użyciu istniejących technik .

Test images	Peak signal noise ratio (PSNR)			
	CSAVQ-ICIIoT	DCNN	BTOT	JPEG
Image 1	49.38	47.40	45.90	43.97
Image 2	48.69	46.52	45.18	42.68
Image 3	48.64	47.11	45.97	41.15
Image 4	49.44	48.62	47.73	41.66
Image 5	49.27	45.82	45.61	41.39
Image 6	48.94	45.97	45.23	40.61



Wyniki przekroczyły fakt, że metoda CSAVQ-ICIIoT umożliwia osiągnięcie maksymalnej wydajności kompresji w porównaniu z innymi technikami. Na przykład na obrazku 1 technika CSAVQ-ICIIoT pozwoliła uzyskać wyższy PSNR wynoszący 49,38, podczas gdy algorytmy DCNN, BTOT i JPEG dały niższy PSNR wynoszący 47,40, 45,90 i 43,97. Jednocześnie na obrazie 3 model CSAVQ-ICIIoT oferuje wyższy PSNR wynoszący 48,64, podczas gdy techniki DCNN, BTOT i JPEG dały niższy PSNR wynoszący 47,11, 45,97 i 41,15. Wreszcie, na obrazie 6, technika CSAVQ-ICIIoT zapewniła maksymalny PSNR wynoszący 48,94, podczas gdy podejścia DCNN, BTOT i JPEG doprowadziły do niższego PSNR wynoszącego 45,97, 45,23 i 40,61.

### Wniosek

W ramach tego badania opracowano nowy model CSAVQ-ICIIoT umożliwiający skuteczną kompresję obrazu poprzez optymalizację procesu konstruowania książki kodowej na platformie IIoT obsługującej technologię 6G. Technika CSAVQ-ICIIoT obejmuje LBG z techniką VQ do kompresji obrazu. Poza tym optymalny proces konstruowania książki kodowej realizowany jest przy użyciu CSA, co poprawia efektywność kompresji. W celu zbadania zwiększonej wydajności modelu CSAVQ-ICIIoT przeprowadzana jest szczegółowa analiza wyników, a wyniki są sprawdzane pod kątem kilku mierników. Wyniki eksperymentów wykazały lepsze wyniki modelu CSAVQ-ICIIoT w porównaniu z innymi metodami. W przyszłości będzie można go wdrożyć w sieciach bezzałogowych statków powietrznych działających w czasie rzeczywistym.