

## Porównanie metod rozpoznania otoczenia radiowego w kognitywnych sieciach sensorowych w obecności zakłóceń niegaussowskich

**Streszczenie.** Intensywny rozwój systemów mobilnych powoduje, że statyczne metody alokacji częstotliwości przestają gwarantować rozwój aplikacji wymagających transmisji bezprzewodowej. W wyniku tego poszukiwane są innowacyjne techniki umożliwiające dynamiczny dostęp do zasobów radiowych. Podstawową metodą dynamicznego dostępu jest współdzielenie częstotliwości pomiędzy użytkownikami posiadającymi licencję, a użytkownikami nielicencjonowanymi. Użytkownik wtórny uzyskuje dostęp do niezajętych zasobów w czasie gdy użytkownik pierwotny jest nieaktywny. Omówiona metoda stanowi podstawę tzw. radia kognitywnego [1] - [3] i wymaga właściwych metod analizy dostępności zasobów częstotliwościowych przez użytkownika wtórnego i odpowiednio szybkich algorytmów podejmowania decyzji o nadawaniu i zwolnieniu pasma gdy zostanie wykryta transmisja użytkownika pierwotnego. W artykule przedstawiono numeryczne wyniki porównania różnych metod rozpoznania otoczenia radiowego wykorzystywanych do wykrywania transmisji sygnałów zgodnych ze standardem 802.11 w obecności zakłóceń o charakterze gaussowskim i niegaussowskim.

**Abstract.** It becomes observable that the current static frequency allocation schemes cannot provide sufficient requirements of an increasing number of applications requiring wireless transmission. As a result, innovative techniques that can offer new methods of sharing the available spectrum are needed. One of the most effective methods to solve this problem is allowing the secondary users to utilize the frequency band licensed to the primary users, only if it can be ensured that the band is not being currently used by the primary users. Cognitive radio [1]-[3] is the technology that implement of spectrum sensing to ensure that another users are not present before data transmission can begin. The paper presents the numerical simulation results for comparison of various spectrum sensing methods used for detection of 802.11 frame transmission in Gaussian and non-Gaussian noise. (**Comparison of Sensing Techniques for Cognitive Radio Networks Operating in non-Gaussian Disturbances**).

**Słowa kluczowe:** kognitywne sieci radiowe, rozpoznanie otoczenia radiowego, zakłócenia niegaussowskie

**Keywords:** cognitive radio networks; spectrum sensing; non-Gaussian disturbances.

### Wstęp

Koncepcja radia kognitywnego [1] - [3] umożliwia dynamiczny dostęp do zasobów widmowych oraz elastyczne i efektywne ich wykorzystywanie. W przypadku dynamicznego dostępu do widma kluczowe jest pozyskanie informacji o dostępności zasobów w określonym paśmie częstotliwości. Informację tę można uzyskać na drodze kooperacyjnej lub samodzielnej detekcji wolnych pasm. Najbardziej popularnymi technikami samodzielnego rozpoznania otoczenia radiowego są metody detekcji energii, cyklostacjonarnej analizy sygnałów oraz detekcji z zastosowaniem filtrów dopasowanych. Metody te różnią się wymaganą ilością wiedzy a priori o sygnałach użytkownika pierwotnego. Ponadto zakładają, że wykrywane sygnały są obserwowane na tle zakłóceń w postaci addytywnego szumu białego o rozkładzie normalnym AWGN (ang. *additive white Gaussian noise*). Jednakże w rzeczywistości odebrany sygnał może być również zakłócany przez szum o charakterze niegaussowskim. Przykładem takich sygnałów są zakłócenia impulsowe, które utrudniają poprawną detekcję sygnałów użytecznych. Zakłócenia te są generowane przez urządzenia takie jak: kuchenki mikrofalowe, systemy mikroprocesorowe czy elementy stykowe. Optymalne metody detekcji stosujące filtrację dopasowaną dobrze sprawdzają się w przypadku zakłóceń AWGN, ale ich efektywność znacznie spada w przypadku zakłóceń niegaussowskich. Znaczną poprawę jakości detekcji można uzyskać stosując odbiornik uwzględniający niegaussowski charakter zakłóceń. Wymaga to jednak statystycznej analizy oddziaływujących zaburzeń i estymacji nieznannej funkcji gęstości prawdopodobieństwa sygnałów zakłócających.

### Statystyczne modelowanie zakłóceń impulsowych

Zakłócenia impulsowe składają się z krótkich impulsów o losowej amplitudzie, czasie trwania i czasie wystąpienia. Można je modelować jako wyjście filtru wzbudzonego przez losową sekwencję binarną w postaci (1):

$$(1) \quad n_i(m) = \sum_{k=0}^{P-1} h_k n(m-k) b(m-k)$$

gdzie:  $b(m)$  jest sekwencją binarną modelującą czas występowania sygnałów impulsowych,  $n(m)$  modeluje wartość chwilową stochastycznego sygnału zakłócającego, a  $h_k$  jest odpowiedzią impulsową filtra, który modeluje czas trwania i kształt każdego impulsu.

W przypadku modelowania zakłóceń impulsowych z zastosowaniem modelu Bernoulliego-Gausa [4] czas wystąpienia impulsów jest określony przez binarny proces Bernoulliego, a amplituda impulsów jest modelowana przez proces Gausa. Funkcja prawdopodobieństwa procesu Bernoulliego jest określona przez (2):

$$(2) \quad P_b(b(m)) = \begin{cases} \alpha & \text{for } b(m)=1 \\ 1-\alpha & \text{for } b(m)=0 \end{cases}$$

gdzie  $b(m)$  jest procesem binarnym przyjmującym wartość "1" z prawdopodobieństwem  $\alpha$  i wartość "0" z prawdopodobieństwem  $1-\alpha$ .

Stochastyczny proces Bernoulliego jest określony przez wartość średnią i wariancję w postaci (3):

$$(3) \quad \mu_b = \alpha, \quad \sigma_b^2 = \alpha(1-\alpha).$$

Chwilowa wartość procesu Bernoulliego dana jest następującą zależnością:

$$(4) \quad f_N^{BG}(n_i(m)) = (1-\alpha)\delta_{n_i(m)} + \alpha f_N(n_i(m)),$$

gdzie:  $\delta(n_i(m))$  jest deltą Kroneckera

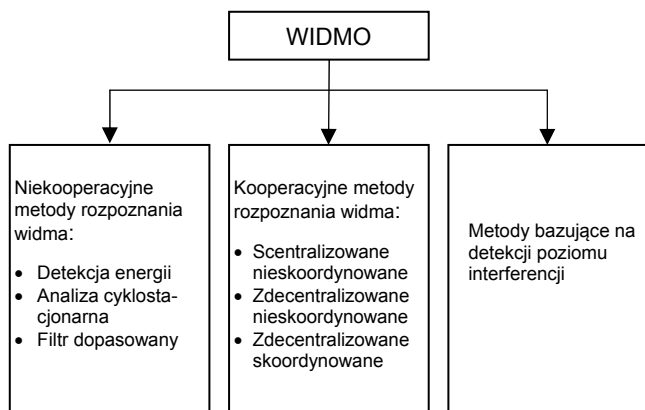
Zgodnie z równaniem (3) funkcja  $f_N^{BG}(n_i(m))$  jest określona przez dyskretny sygnał losowy  $\delta(n_i(m))$  i ciągłą gęstość prawdopodobieństwa  $f_N(n_i(m))$ , która jest najczęściej modelowana jako proces stochastyczny o rozkładzie normalnym opisanym następującą zależnością (5):

$$(5) \quad f_N(n(m)) = \frac{1}{\sqrt{2\pi}\sigma_n} e^{-\frac{n^2(m)}{2\sigma_n^2}}.$$

## Metody rozpoznania otoczenia radiowego

Zagadnienie rozpoznania otoczenia radiowego może być określone jako binarne testowanie hipotez  $H_0$  i  $H_1$  [3] odpowiadających przypadkom występowania i braku transmisji sygnałów użytkownika pierwotnego. Jakość detekcji jest określona za pomocą prawdopodobieństw detekcji PD i prawdopodobieństwa fałszywego alarmu PFA. PD jest prawdopodobieństwem wykrycia sygnału kiedy jest on rzeczywiście obecny. PFA jest zaś prawdopodobieństwem podjęcia nieprawidłowej decyzji o wykryciu użytkownika pierwotnego gdy faktycznie jest on nieobecny.

Jak pokazano na rysunku 1 techniki rozpoznania otoczenia radiowego mogą być sklasyfikowane na trzy kategorie: niekooperacyjne, kooperacyjne i metody bazujące na detekcji poziomu interferencji [5].



Rys.1. Klasyfikacja metod rozpoznania otoczenia radiowego [5]

W przypadku gdy detekcja użytkownika pierwotnego odbywa się jedynie na podstawie realizowanych na bieżąco pomiarów mamy do czynienia z metodami rozpoznania niekooperacyjnego. Podstawowymi metodami detekcji w tym przypadku są: detekcja energii, wykrywanie użytkownika na podstawie określania cech sygnałów z zastosowaniem analizy cyklostacjonarnej i zastosowanie filtrów dopasowanych.

### Detekcja energii

Najbardziej popularną metodą analizy zajętości zasobów widmowych jest detekcja energii. Metoda ta nie wymaga wcześniejszych informacji o sygnale użytkownika pierwotnego. Wykrywa sygnał przez pomiar energii odbieranego sygnału. Podejmowanie decyzji w tej metodzie może być zatem zdefiniowane następująco (6):

$$(6) \quad E(k) = \begin{cases} H_0 & \text{if } E < \lambda \\ H_1 & \text{if } E \geq \lambda \end{cases}$$

gdzie:  $E = E[|x(u)|^2]$  jest estymatą energii odbieranego sygnału  $x(u)$ , a  $\lambda$  jest wartością progową.

Próg detekcyjny  $\lambda$  powinien być określony tak aby zapewnić odpowiedni stosunek PD i PFA. Wartość progowa jest zazwyczaj dobierana przy założeniu określonego poziomu prawdopodobieństwa fałszywego alarmu. W tym przypadku do wyznaczenia wartości progowej wystarczająca jest estymacja wartości wariancji sygnału zakłócającego.

### Wykrywanie użytkownika na podstawie określania cech sygnałów z zastosowaniem analizy cyklostacjonarnej

Sygnały radiowe i większość sygnałów wytwarzanych przez człowieka ma charakterystykę cyklostacjonarną [6]. Oznacza to, że zmienność parametrów probabilistycznych charakteryzujących te sygnały cechuje się okresowością.

Wartość cyklicznej funkcji autokorelacji zdefiniowanej zależnością (7) jest dla tej klasy sygnałów różna od zera.

$$(7) \quad R_x^\alpha(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-\frac{T}{2}}^{\frac{T}{2}} x\left(t + \frac{\tau}{2}\right) x^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi\alpha t} dt,$$

gdzie:  $\alpha$  jest częstotliwością rozpatrywanej cykliczności. Cykliczna funkcja autokorelacji ma też swoją reprezentację widmową określaną jako cykliczną gęstość widmowa mocy (8) [6]:

$$(8) \quad S_x^\alpha(f) = \int_{-\infty}^{\infty} R_x^\alpha(\tau) e^{-j2\pi\alpha\tau} d\tau = \lim_{T \rightarrow \infty} \frac{1}{T} X_T\left(f + \frac{\alpha}{2}\right) X_T^*\left(f + \frac{\alpha}{2}\right),$$

gdzie:

$$(9) \quad X_T(f) = \int_{-\frac{T}{2}}^{\frac{T}{2}} x(u) e^{-j2\pi fu} du$$

jest transformatą Fouriera sygnału  $x(u)$ .

Cykliczna gęstość widmowa jest zatem dwuwymiarową reprezentacją sygnałów określoną przez  $\alpha$  i  $f$ . Funkcja  $S_x^\alpha(f)$  zawiera wyraźne piki gdy częstotliwość cykliczna  $\alpha$  jest równa częstotliwościom głównych składowych sygnału  $x(u)$ .

Detekcja na podstawie analizy cyklostacjonarnej jest bardzo skuteczna nawet dla słabych sygnałów użytkownika pierwotnego. Wynika to z faktu, że sygnały generowane przez człowieka w procesie modulacji wykazują cyklostacjonarność z powodu wykorzystywania nośnych sinusoidalnych. Można je zatem łatwo odróżnić od sygnałów zakłócających, które nie posiadają cech cyklostacjonarnych.

### Optymalna detekcja sygnałów

W systemach radiokomunikacyjnych, wykorzystujących transmisję cyfrową, jednym z zadań odbiornika jest odtwarzanie, na podstawie odbieranych danych, zegara transmisji. Jedną z najczęściej stosowanych technik, umożliwiających realizację synchronizacji jest wprowadzenie na początku bloku przesyłanych danych cyfrowych tzw. preambuły, czyli znanego ciągu symboli, którego obecność może być wykrywana w odbiorniku.

Detekcja sygnału deterministycznego, który jest zakłócany addytywnym szumem o normalnym rozkładzie gęstości prawdopodobieństwa jest jednym z najczęściej spotykanych problemów detekcji. W tym przypadku odbierany sygnał może być opisany następującą zależnością (10):

$$(10) \quad x = s(\theta) + w,$$

gdzie:  $x$  jest odbieranym sygnałem,  $w$  jest losowym zakłóceniem oddziaływującym na wykrywany sygnał, a  $s$  jest sygnałem znanym dokładnie zależnym od parametru  $\theta$ . Amplituda sygnału  $\theta$  przyjmuje wartość zerową w przypadku brak sygnału lub dodatnią w przypadku jego występowania. Detekcja polega zatem na ustaleniu na podstawie odebranego sygnału  $x$  wartości parametru  $\theta$ . Jeżeli wartość parametru  $\theta$  jest znana, detekcja może być zrealizowana z zastosowaniem metody największej wiarygodności (11):

$$(11) \quad \frac{f_x(\bar{x}; \theta = \theta_0)}{f_x(\bar{x}; \theta = 0)} > H_1 \gamma.$$

W przypadku, gdy hipoteza alternatywna  $H_1$  jest położona bardzo blisko hipotezy  $H_0$ , decyzję o wykryciu sygnału podejmuje się z zastosowaniem lokalnie optymalnej LO (Locally Optimal detection) [7]. W tym przypadku decyzja o wykryciu sygnału podejmowana jest na podstawie następującej zależności: (12):

$$(12) \quad \frac{\left. \frac{\partial}{\partial \theta} f_x(\bar{x}; \theta) \right|_{\theta=0}}{f_x(\bar{x}; \theta=0)} < \frac{H_1}{H_0} \gamma.$$

Jeżeli zakłócenie  $w$  ma charakter addytywny to funkcję rozkładu gęstości prawdopodobieństwa wykrycia sygnału można przedstawić w następujący sposób:

$$(13) \quad f_x(\bar{x}; \theta) = f_w(\bar{x} - s(\theta)).$$

i równanie (12) przyjmuje następującą postać:

$$(14) \quad \frac{\left. \frac{\partial}{\partial \theta} f_x(\bar{x}; \theta) \right|_{\theta=0}}{f_x(\bar{x}; \theta=0)} = \frac{\left. \frac{\partial}{\partial \theta} f_w(\bar{x} - \bar{s}(\theta)) \right|_{\theta=0}}{f_w(\bar{x}; \theta=0)} = \frac{-\frac{\partial}{\partial \bar{x}} f_w(\bar{x})}{f_w(\bar{x}; \theta=0)} \frac{\partial}{\partial \theta} \bar{s}(\theta) = g(\bar{x}) \frac{\partial}{\partial \theta} \bar{s}(\theta).$$

Jak widać detekcja, zgodnie z algorytmem LO, polega na wyznaczeniu korelacji nieliniowej funkcji  $g(x)$  zależnej od obserwowanego sygnału  $x$  z pochodną sygnału znanego dokładnie w punkcie  $\theta = 0$ . Jeżeli szum kanału transmisyjnego ma rozkład normalny  $N(0, \sigma)$ , a parametr  $\theta$  określa wartość amplitudy sygnału  $s(\theta) = \theta \cdot s$  to równanie (14) sprowadza się do następującej zależności:

$$(15) \quad \frac{-\frac{\partial}{\partial \bar{x}} \left( \frac{1}{\sqrt{2\pi\sigma}} e^{-0.5 \left( \frac{\bar{x}-\mu}{\sigma} \right)^2} \right)}{\frac{1}{\sqrt{2\pi\sigma}} e^{-0.5 \left( \frac{\bar{x}-\mu}{\sigma} \right)^2}} \frac{\partial}{\partial \theta} \bar{s} = \frac{\bar{x}}{\sigma^2} \bar{s}.$$

W tym wypadku detektor lokalnie optymalny realizowany jest jako korelacja obserwowanego sygnału  $x$  z sygnałem znanym dokładnie  $s$ . Jednak w ogólnym przypadku, gdy funkcja gęstości rozkładu nie jest znana *a priori*, należy estymować ją na podstawie bieżącej obserwacji sygnału. Istnieje wiele metod estymacji gęstości prawdopodobieństwa [8], [9], które można podzielić na trzy grupy: parametryczne, w których zakładany jest dany typ rozkładu (np. normalny, Raleigha czy równomierny), zaś zbieżność estymacji dokonuje się przez wyznaczenie wartości parametrów charakteryzujących przyjęty rozkład, nieparametryczne, które nie wymagają znajomości typu estymowanej gęstości a jedynie estymacji pewnych parametrów związanych z estymowanym rozkładem charakterystycznych dla określonej metody (np. szerokości pasma w przypadku histogramu, czy parametru wygładzania dla estymatorów jądrowych) oraz metody semiparametryczne [8], [9]. Estymatory semiparametryczne łączą uniwersalność metod nieparametrycznych z szybkością metod parametrycznych. W metodach tych estymowany rozkład gęstości stanowi kombinację rozkładów o różnych parametrach. Przykładem metod semiparametrycznych są estymatory, w których wykorzystano sieci neuronowe o radialnych i hiperradialnych funkcjach bazowych (RBF, HRBF) [8], [9].

Funkcja opisująca sieć RBF wyrażona jest następującą zależnością:

$$(16) \quad f(X) = \sum_{i=1}^n w_i \cdot G_i(X),$$

gdzie  $n$  jest liczbą neuronów w warstwie ukrytej, a  $G_i(X)$  funkcją aktywacji  $i$ -tego neuronu w warstwie ukrytej. Najczęściej stosowaną funkcją  $G_i(X)$  jest funkcja Gaussa, która dla sieci typu RBF przyjmuje następującą postać:

$$(17) \quad G_i(X) = \frac{1}{(2\pi)^{n/2} \det(\Sigma_i)} \exp\left(-\frac{(X - c_i)^T \Sigma_i^{-1} (X - c_i)}{2}\right),$$

gdzie  $\Sigma_i$  jest macierzą kowariancji.

Celem uczenia sieci RBF jest takie uporządkowanie neuronów (tj. określenie położenia centrów, wartości dyspersji i wag sieci), które zminimalizuje błąd popełniany przy estymacji gęstości prawdopodobieństwa parametrami poszczególnych neuronów. Zadanie to może być realizowane np. z zastosowaniem algorytmów opartych o proces samoorganizacji czy z zastosowaniem algorytmu EM (ang. *Expectation - Maximization*) [8], [9].

Wykorzystanie konkretnej metody estymacji gęstości prawdopodobieństwa uzależnione jest od kilku czynników. Do najważniejszych zaliczyć można wiedzę *apriori* o estymowanym rozkładzie (np. typ rozkładu, wymiar zmiennej losowej itp.), nieobciążalność, zgodność i efektywność estymatora oraz możliwość estymacji rozkładu zarówno na podstawie całej próby losowej jak i w czasie rzeczywistym na podstawie bieżących wartości zmiennej losowej.

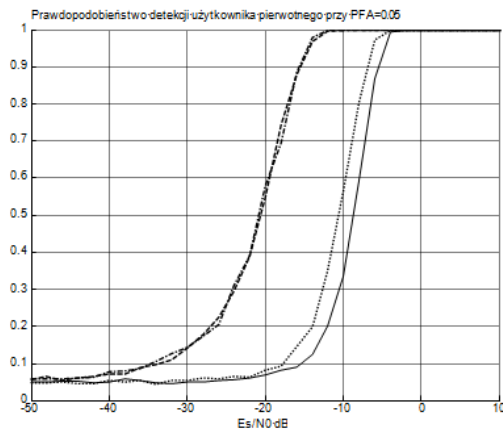
#### Porównanie metod rozpoznania otoczenia radiowego

Porównanie omówionych w artykule metod rozpoznania otoczenia radiowego zrealizowano z zastosowaniem detekcji pojedynczej ramki systemu 802.11 [10]. Wykrywane sygnały były zakłócone przez addytywny szum o rozkładzie normalnym oraz szum impulsowy. Wartość progowa została dobrana na podstawie wartości prawdopodobieństwa fałszywego alarmu wynoszącego 0.05. W przypadku detektora energii wartość proggu ustalono na podstawie estymacji mocy sygnału zakłócającego. W przypadku detektora cyklostacjonarnego detekcja zrealizowana została na podstawie analizy wartości cyklicznej gęstości widmowej mocy (8). W przypadku detektora optymalnego estymacja gęstości mocy została zrealizowana z zastosowaniem estymatora semiparametrycznego opartego na sieciach neuronowych o radialnych funkcjach bazowych uczonych z zastosowaniem algorytmu EM [8], [9].


Rysunki 2 - 4 przedstawiają prawdopodobieństwo wykrycia sygnału użytkownika pierwotnego w funkcji energii transmitowanego symbolu względem wartości gęstości widmowej szumu ( $E_s/N_0$ ). Rysunek 2 przedstawia charakterystyki detekcji sygnału zakłócanego tylko przez addytywny szum o rozkładzie normalnym.

Z analizy rysunku 2 wynika, że najlepszą jakością detekcji zapewniają detektory optymalne. Detektor cyklostacjonarny jest tylko nieznacznie efektywniejszy od detektora energii. Wynika to z faktu realizacji detekcji jedynie na podstawie pojedynczej ramki transmitowanego sygnału.

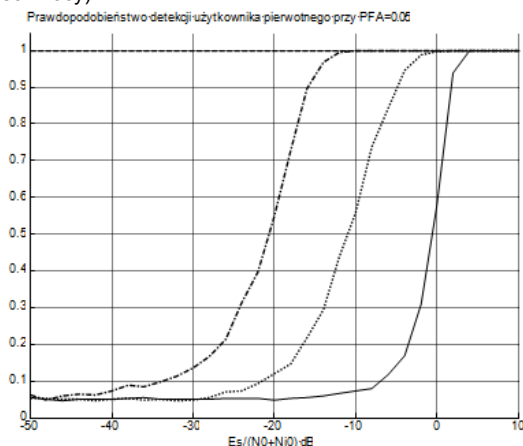
Rysunek 3 przedstawia charakterystyki detekcji sygnału zakłócanego przez addytywny szum o rozkładzie normalnym i szum impulsowy o stałej gęstości mocy ( $E_s/N_0$ ) równej 0dB. Szum impulsowy był generowany na podstawie modelu Bernoulliego-Gaussa przy założeniu prawdopodobieństwa  $\alpha$  (2) równe 0.05.



Rys.2. Prawdopodobieństwo wykrycia sygnału użytkownika pierwotnego zakłócanego szumem AWGN w funkcji stosunku energii symbolu do gęstości mocy szumu (linia ciągła: detektor energii, linia kropkowana: detektor cyklostacjonarny, linia złożona z kresek i kropek: detektor optymalny dla szumu AWGN, linia przerywana: detektor optymalny z estymacją widmowej gęstości mocy)



Rys.3. Prawdopodobieństwo wykrycia sygnału użytkownika pierwotnego zakłócanego szumem AWGN oraz szumem impulsowym o stałej gęstości mocy ( $E_s/(N_0+N_{10})$ ) równej 0dB w funkcji stosunku energii symbolu do gęstości mocy szumu (linia ciągła: detektor energii, linia kropkowana: detektor cyklostacjonarny, linia złożona z kresek i kropek: detektor optymalny dla szumu AWGN, linia przerywana: detektor optymalny z estymacją widmowej gęstości mocy)



Rys.4. Prawdopodobieństwo wykrycia sygnału użytkownika pierwotnego zakłócanego szum impulsowym oraz szumem AWGN o stałej gęstości mocy ( $E_s/(N_0+N_{10})$ ) równej 0dB w funkcji stosunku energii symbolu do gęstości mocy szumu (linia ciągła: detektor energii, linia kropkowana: detektor cyklostacjonarny, linia złożona z kresek i kropek: detektor optymalny dla szumu AWGN, linia przerywana: detektor optymalny z estymacją widmowej gęstości mocy)

Z analizy rysunku 3 wynika, że najlepszą jakością detekcji zapewniają detektory optymalne. Detektorem, którego efektywność znacznie maleje w momencie występowania zakłóceń impulsowych jest detektor energii.

Rysunek 4 przedstawia charakterystyki detekcji sygnału zakłócanego przez szum impulsowy i addytywny szum normalny o stałej gęstości mocy ( $E_s/N_0$ ) równej 0dB. Szum impulsowy był generowany na podstawie modelu Bernoulliego-Gaussa przy założeniu prawdopodobieństwa  $\alpha(2)$  równego 0.05.

Jak widać z rysunku 4 najbardziej efektywnym i odpornym na zakłócenia impulsowe metodą jest zaproponowany algorytm detekcji optymalnej wykorzystujący estymację widmowej gęstości mocy zakłóceń.

## Podsumowanie

W pracy przedstawiono porównanie najczęściej stosowanych metod rozpoznania otoczenia radiowego, które mogą być stosowane w systemach radia kognitywnego w celu detekcji emisji użytkownika pierwotnego. Ponadto w pracy zaproponowano wykorzystanie w systemie radia kognitywnego detektora optymalnego opartego na estymacji widmowej gęstości mocy sygnałów zakłócających. Przedstawione wyniki badań symulacyjnych pokazują wyraźną przewagę efektywności zaproponowanego detektora w przypadku występowania zakłóceń o niegaussowskich gęstościach mocy.

Badania zostały zrealizowane w ramach pracy nr S/WE/1/2015 i sfinansowane ze środków na naukę MNiSW.

**Autor:** dr inż. Krzysztof Konopko, Politechnika Białostocka, Wydział Elektryczny, ul. Wiejska 45D, 15-351 Białystok, e-mail: k.konopko@pb.edu.pl;

## LITERATURA

- [1] J. Mitola, G. Q. Maguire, „Cognitive radio: making software radios more personal”, IEEE Personal Commun. Mag., vol. 6, no. 4, pp. 13–18, Aug. 1999.
- [2] S. Hakin, „Cognitive Radio: Brain-Empowered Wireless Communications”, IEEE J. On selected areas in communication, vol.23, pp.201-220, Feb. 2005.
- [3] H. Bogucka, „Technologie radia kognitywnego”, Wydawnictwo Naukowe PWN, Warszawa, 2013
- [4] S. V. Vaseghi, „Advanced Digital Signal Processing and Noise Reduction”, John Wiley & Sons Ltd. New York 2009.
- [5] M. Subhedar, G. Birajda, „Spectrum Sensing Technique in Cognitive Radio Networks: A Survey,” International Journal of Next-Generation Networks (IJNGN), vol. 3, no. 2, pp. 37-51., June 2011.
- [6] A. Gardner, „Cyclostationarity in Communications and Signal Processing”, IEEE Press, 1994
- [7] S. A. Kassam, „Signal Detection in Non-Gaussian Noise”, Springer-Verlang, New York 1987.
- [8] K. Konopko, „Estymacja i generacja wielowymiarowych zmiennych losowych”, Oficyna Wydawnicza Politechniki Białostockiej, pp. 255-272, Białystok 2016
- [9] K. Konopko, „Estymacja i generacja sygnałów szumowych z zastosowaniem procesorów masowo-równoległych”, Przegląd Elektrotechniczny, nr 2 pp. 54-57 Feb. 2016
- [10] <https://standards.ieee.org/findstds/standard/802.11-2016.htm>