

REKURENCYJNY ALGORYTM DETEKCJI SYGNAŁU RECURSIVE SIGNAL DETECTION ALGORITHM

Bartosz Bossy¹, Grzegorz Fotyga^{1,2}, Aleksander Nowak¹, Paweł Żukowski¹

¹ Hertz Systems Ltd sp. z o. o., Zjednoczenia 118A, 65-120 Zielona Góra

b.bossy@hertzsystems.com, a.nowak@hertzsystems.com, p.zukowski@hertzsystems.com

² Faculty of Electronics, Telecommunications, and Informatics, Gdansk University of Technology, Gdansk, Poland
g.fotyga@hertzsystems.com

Streszczenie: W niniejszym artykule przedstawiono nowy rekurencyjny algorytm detekcji sygnału, bazując na analizie częstotliwościowo czasowej. Algorytm przetestowano dla szerokiej gamy rzeczywistych sygnałów zarejestrowanych z wykorzystaniem stanowiska pomiarowego. Wyniki pokazują, że zaproponowany algorytm bardzo dobrze wykrywa sygnał użyteczny, a w dodatku jest skalowalny. Ponadto w obecnej postaci detekcja zajmuje dwukrotność czasu trwania sygnału, a możliwe jest zmniejszenie jej czasu poprzez m.in. zrównoleglenie obliczeń.

Abstract: This article presents the proposed recursive signal detection algorithm based on time-frequency analysis. The algorithm has been tested for a wide range of real signals recorded using a measurement station. The results show that the proposed algorithm detects the useful signal very well and is also scalable. Moreover, in its current form, detection takes twice the signal duration and it is possible to reduce its time by, among others, parallelization of calculations.

Słowa kluczowe: detekcja, dron, pomiary, zagłuszanie

Keywords: detection, drone, jamming, measurements

1. WSTĘP

W ciągu ostatniej dekady nastąpił gwałtowny rozwój bezzałogowych systemów powietrznych (ang. *Unmanned Aerial System* - UAS) we wszystkich sektorach: wojskowym, komercyjnym i cywilnym. Jednakże te postępy stwarzają również znaczące wyzwania w zakresie zabezpieczenia infrastruktury krytycznej, takiej jak energetyka, telekomunikacja i transport. W szczególności w ostatnich latach zaobserwowano znaczne zakłócenia na lotniskach spowodowane UASs, z których najpoważniejsze zostały wymienione w [1].

W ostatnich latach zaproponowano wiele metod detekcji i klasyfikacji sygnałów związanych z dronami w celu ochrony infrastruktury krytycznej. Rozwiązanie zaproponowane w [2] wprowadza podejście oparte na sieciach neuronowych do klasyfikacji sygnałów. Podejście to obejmuje następujące kroki: 1) tworzenie bazy danych sygnałów; 2) ręczne etykietowanie i adnotowanie bazy danych, co zazwyczaj jest procesem czasochłonnym; oraz 3) zastosowanie sieci neuronowej do rozpoznawania sygnałów. Alternatywnie, można wykorzystać ogólny model stworzony przez firmę DeepSig, który jest ciągle aktualizowany. Ten

model potrafi rozróżniać różne sygnały, takie jak: LTE, Wi-Fi, Bluetooth. W publikacji [3] opisano implementację [2] na wydajnym serwerze HPE Edgeline EL8000, który obejmuje trening modelu i klasyfikację sygnałów.

Alternatywne podejście do wykrywania sygnałów związanych z transmisją danych w górę i w dół opiera się na analizie cyklostacjonarności [4, 5]. Jest to również metoda używana w analizie sygnałów FHSS (ang. *Frequency-Hopping Spread Spectrum*) [6]. W [7] zaproponowano metodę detekcji spektrum opartą na wartościach własnych macierzy kowariancji sygnałów odbieranych przez użytkowników wtórnych.

2. DETEKCJA SYGNAŁU

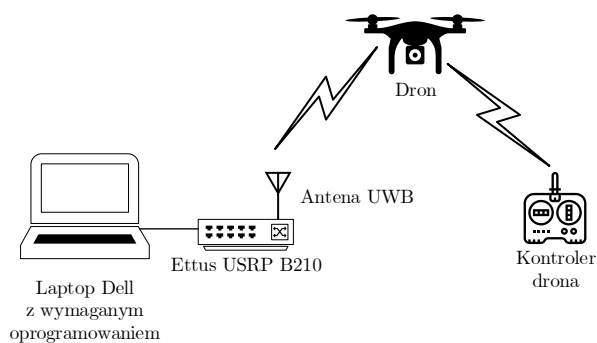
Głównym celem detekcji sygnału jest określenie czy dany nadajnik, w tym przypadku dron, transmituje sygnał. Matematycznie decyzję dotyczącą wykrywania sygnału $D(x)$ można traktować jako statystykę podwójnej hipotezy:

$$D(x) = \begin{cases} \mathcal{H}_0 & \text{jeżeli } r(x) = n(x) \\ \mathcal{H}_1 & \text{jeżeli } r(x) = s(x) + n(x), \end{cases} \quad (1)$$

gdzie \mathcal{H}_0 jest hipotezą, że odebrany sygnał to szum, natomiast \mathcal{H}_1 jest hipotezą, że odebrany sygnał jest sumą szumu oraz sygnału z nadajnika. Jakość detekcji jest opisana przez prawdopodobieństwo detekcji P_d czyli prawdopodobieństwo, że $D(x) = \mathcal{H}_1$ w przypadku, gdy nadajnik faktycznie transmituje sygnał oraz prawdopodobieństwo błędnej detekcji (ang. *miss-detection*) P_{md} tzn. prawdopodobieństwo, że $D(x) = \mathcal{H}_0$ w przypadku, gdy nadajnik jest aktywny a nie wykrył żadnego sygnału. Ponadto ważnym wskaźnikiem jest prawdopodobieństwo fałszywego alarmu P_f definiowane jako prawdopodobieństwo, że $D(x) = \mathcal{H}_1$ w przypadku, gdy nadajnik faktycznie nie transmituje.


3. REJESTROWANIE SYGNAŁU

Głównym celem prezentowanych w artykule prac jest stworzenie algorytmu detekcji sygnałów transmitowanych przez drony komercyjne. W związku z tym w pierwszym etapie zarejestrowano sygnały w paśmie 2,4 GHz bez rozróżnienia czy są to sygnały sterujące w łączu w górę i w dół, czy transmisja obrazu. Do rejestracji sygnału użyto systemu przedstawionego na Rysunku 1.




Rysunek 1: Schemat poglądowy stanowiska pomiarowego.


Częstotliwość próbkowania wynosiła 50 MHz a czas rejestrowanego sygnału to 2 sekundy. Sygnał był rejestrowany w miejscu oddalonym od innych nadajników w celu zarejestrowania tylko sygnału wykorzystywanego do komunikacji z dronem. Poniżej przedstawiono spektrogramy kilku zarejestrowanych sygnałów.



Rysunek 2: Spektrogram dla transmisji drona Autel Evo Nano+.



Rysunek 3: Spektrogram dla transmisji Dji MiniPro 3.



Rysunek 4: Spektrogram dla transmisji Dji Inspire.

Można zaobserwować, że poszczególne transmisje różnią się od siebie drastycznie, nawet jeżeli drony pochodzą od tego samego producenta (Rysunek 3 i Rysunek 4). Ponadto widoczne są transmisje różnego typu. W ogólności można wyróżnić transmisję OFDM (ang. *Orthogonal Frequency-Division Multiplexing*) wykorzystywana do transmisji video oraz FHSS, za pomocą której przesyłane są dane sterujące, które zajmują wąskie pasmo i trwają maksymalnie kilka milisekund. Dlatego też konieczne zaprojektowanie jest elastycznego algorytmu detekcji sygnału o niskiej złożoności, aby możliwe było zagłuszanie w czasie rzeczywistym.

4. ALGORYTM DETEKCJI

Zaproponowany rekurencyjny algorytm detekcji sygnału bazuje na jego analizie czasowo-częstotliwościowej reprezentowanej przez spektrogram. Problemem w detekcji bazującej na analizie czasowo-częstotliwościowej jest fakt, że parametry wyznaczonego spektrogramu mają istotny wpływ na jakość detekcji. Jest tak, ponieważ wysoka rozdzielczość w dziedzinie częstotliwości spowoduje obniżenie rozdzielczości w czasie i odwrotnie. Zatem wysoka jakość detekcji w dziedzinie częstotliwości może spowodować obniżenie jej jakości w czasie i vice versa. Rozwiązaniem tego problemu może być zwiększenie liczby próbek, które nakładają się między sąsiednimi segmentami, jednak skutkuje to znacznym zwiększeniem liczby punktów spektrogramu, a to może skutkować zwiększeniem czasu wyznaczania samego spektrogramu, ale także zwiększenia czasu detekcji. Dlatego też konieczny jest kompromis pomiędzy jakością detekcji a czasem detekcji.

Dla wyznaczonego spektrogramu kolejnym krokiem zaproponowanego algorytmu jest analiza zarejestrowanego sygnału w czasie. W tym celu dla danej chwili czasu zsumowano wszystkie próbki z dziedziny częstotliwości, otrzymując tym samym informację o tym w jakich chwilach czasu transmitowany jest sygnał. Matematycznie można tę operację przedstawić za pomocą następującego wzoru:


$$\forall n \sum_{\omega \in \Omega} |\text{STFT} \{x[n]\}(\tau, \omega)|^2, \quad (2)$$

gdzie $\text{STFT} \{x[n]\}(\tau, \omega)$ to krótkookresowa transforma-

ta Fouriera sygnału $x[n]$ i częstotliwości ω dana wzorem:

$$\begin{aligned} \text{STFT} \{x[n]\}(\tau, \omega) &\equiv X(\tau, \omega) \\ &= \sum_{n=-\infty}^{\infty} x[n] w[n - \tau] e^{-i\omega n}, \end{aligned} \quad (3)$$

gdzie $w(\tau)$ to funkcja okna, którą w tym przypadku jest funkcja Hann. Dla tak wyznaczonego sygnału kolejnym krokiem jest wykrycie punktów, dla których następują zmiany (ang. *change point detection*). Wykorzystano w tym celu algorytm *bottom up segmentation* [8, 9] o złożoności obliczeniowej $\mathcal{O}(n \log n)$, gdzie n to liczba próbek. W celu przyspieszenia obliczeń, w zaproponowanym algorytmie analizowany sygnał jest dzielony na mniejsze fragmenty. Na Rysunku 5 przedstawiono przykładowe wyniki działania algorytmu *bottom up segmentation* dla sygnału po wykonaniu operacji (2) oraz spektrogramu z Rysunku 2. Można zaobserwować, że większość zmian w sygnale została poprawnie wykryta niemniej jednak są widoczne fragmenty, dla których następuje zmiana i nie została ona wykryta (przykład takiej sytuacji jest oznaczony elipsą). Wynika to z ustawień "czułości" algorytmu detekcji punktu zmiany, który z jednej strony może poprawić jakość detekcji sygnału, ale może też zwiększyć czas detekcji. Problem ten został rozwiązany przez rekurencyjne wywołanie zaproponowanej metody detekcji. Dzięki temu pierwsza (Rysunek 5) analiza w czasie nie jest ostateczna, a jest wejściem do kolejnego wywołania algorytmu.




Rysunek 5: Rezultat operacji (2) oraz działania algorytmu *bottom up segmentation* dla Autel Evo Nano+.

Jak wspomniano, operacja (2) sumuje próbki ze wszystkich częstotliwości w danym czasie, a jak wiadomo w tym samym czasie może być transmitowanych kilka sygnałów na różnych częstotliwościach. Zatem w kolejnym kroku dla każdej wykrytej w czasie transmisji przeprowadzono analizę częstotliwością. W tym celu dla wyznaczonych wcześniej przedziałów czasowych zsumowano sygnał w dziedzinie czasu, co można przedstawić następującym wzorem:

$$\forall \omega \sum_{n \in \mathcal{N}} |\text{STFT} \{x[n]\}(\tau, \omega)|^2, \quad (4)$$

gdzie \mathcal{N} to zbiór chwil czasu wykryty w poprzednim kroku. Następnie dla sygnału będącego wynikiem tej operacji zostają wykryte punkty zmiany za pomocą wcześniej

wspominanego algorytmu *bottom up segmentation*. Poniżej, na Rysunku 6, przedstawiono wykryte punkty zmiany dla sygnału będącego wynikiem (4) dla chwil czasowych pomiędzy zielonymi liniami z Rysunku 5. Kolejny raz można zaobserwować, że nie wszystkie zmiany zostały wykryte. Powód jest ten sam, czyli "czułość" algorytmu detekcji punktów zmiany. Oczywiście można zmienić parametr odpowiedzialny za "czułość", lecz znacznie zwiększa to czas detekcji i dużo lepszym rozwiązaniem jest rekurencyjne wywołanie algorytmu.



Rysunek 6: Rezultat operacji (4) oraz działania algorytmu *bottom up segmentation* dla Autel Evo Nano+.

Ostatnim etapem decydującym o tym, czy daną transmisję można uznać za wykrytą jest dalsza analiza w czasie, ale tylko dla konkretnych częstotliwości, czyli dla sygnału będącego wynikiem poniższej operacji:

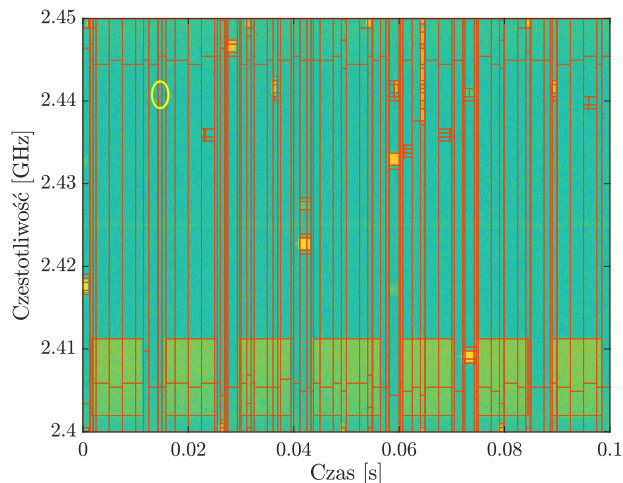
$$\forall n \in \mathcal{N} \sum_{\omega \in \Psi} |\text{STFT} \{x[n]\}(\tau, \omega)|^2, \quad (5)$$

gdzie Ψ to zbiór częstotliwości wykryty w poprzednim kroku. Jeżeli dla takiego sygnału nie wykryto nowych punktów zmiany oznacza to, że uznajemy transmisję za wykrytą. W przeciwnym przypadku oznacza to, że w danym paśmie i w danym czasie zostały wykryte sygnały, który wcześniej został pominięty. Dlatego też dla nowo wykrytego sygnału dokonywane jest ponowna analiza częstotliwościowa poprzez rekurencyjne wywołanie. Procedura ta jest powtarzana, aż do momentu, gdy nowy sygnał (punkt zmiany) dla danego pasma i czasu nie zostaje wykryty.


5. WYNIKI

W niniejszym rozdziale przedstawiono wyniki zaproponowanego rekurencyjnego algorytmu detekcji dla sygnałów zarejestrowanych zgodnie z procedurą i parametrami opisanymi w Rozdziale 3. Rysunek 7 przedstawia wynik działania algorytmu przed wykonaniem operacji progowania dla drona Autel Evo Nano+. Można zauważyć, że algorytm z dużą dokładnością rozdziela spektrogram na fragmenty zawierające transmisję, jak i te zawierające szum. Ponadto niektóre bloki są dzielone na mniejsze, ze względu na zmieniającą się moc. Widać to szczególnie na granicach pasma, gdzie występują wyższy poziom szumu wynikający z niedoskonałości urządzeń pomiarowych. Rysunek

8 przedstawia zbliżenie fragmentu z Rysunku 7 zaznaczonego żółtą elipsą, który również odpowiada niewykrytemu fragmentowi z Rysunku 5. Rysunek ten potwierdza, że rekurencyjne wywołanie algorytmu detekcji pozwala na zwiększenie skuteczności detekcji. Kolejne wyniki zostały wygenerowane dla drona DjiMini Pro3 i zostały przedstawione na Rysunku 9. Ponownie można zaobserwować wysoką skuteczność zaproponowanego algorytmu.




Rysunek 7: Wynik działania algorytmu dla drona Autel Evo Nano+.




Rysunek 8: Zbliżony fragmentu z Rysunku 7 zaznaczony zieloną elipsą.

Podsumowując, zaproponowany rekurencyjny algorytm detekcji sygnału poprawnie rozdziela spektrogram na fragmenty zawierające transmisję, jak i te zawierające szum, zachowując przy tym dużą dokładność. Ponadto zaproponowany algorytm jest skalowalny w swej dokładności i możliwy do zrównoleglenia, ponieważ każdy wykryty w pierwszym kroku fragment transmisji może być przetwarzany niezależnie. Jak już wspomniano najbardziej czasochłonnym etapem zaproponowanego algorytmu jest wywoływanie metody znajdującej punkt zmiany, i to on w dużej mierze determinuje czas detekcji. W zaproponowanym algorytmie wykorzystano metodę *bottom up segmentation*, dla którego czas wykonania zaproponowanego algorytmu detekcji wynosi dwukrotność czasu trwania analizowanego sygnału.



Rysunek 9: Wynik działania algorytmu dla drona Dji MiniPro 3.


Jak wspomniano zaproponowany algorytm dzieli spektrogram na fragmenty zawierające transmisję, jak i te zawierające szum, zachowując przy tym dużą dokładność. Niemniej jednak w celu zagłuszenia należy wyodrębnić tylko te fragmenty, dla których występuje transmisja sygnału. Metodą zaproponowaną w tym artykule jest klasyfikacja na bloki zawierające szum i transmisje poprzez progowanie na podstawie amplitudy. Jest to relatywnie prosta i szybka metoda, ale jej główną trudnością jest określenie wartości, od której blok jest uznawany za ten zawierający sygnał. Rysunek 10 oraz Rysunek 11 przedstawiają wyniki progowania na podstawie amplitudy dla Dji MiniPro 3. Można zaobserwować, że poprawnie dobrany próg odpowiednio usuwa fragmenty spektrogramu zawierające szum.



Rysunek 10: Wyniki dla progowania na podstawie amplitudy dla drona Dji MiniPro 3.

6. WNIOSKI

W artykule przedstawiono zaproponowany rekurencyjny algorytm detekcji sygnału. Zaproponowany algorytm bazuje na analizie czasowo-częstotliwościowej reprezentowanej przez spektrogram. Parametry wyznaczonego spektrogramu mają istotny wpływ na jakość detekcji, ponieważ wysoka rozdzielczość w dziedzinie częstotliwości spowoduje obniżenie rozdzielczości w czasie i odwrotnie. Zatem wysoka



Rysunek 11: Wyniki dla progowania na podstawie amplitudy dla drona Dji Inspire.

jakość detekcji w dziedzinie częstotliwości może spowodować obniżenie jej jakości w czasie i vice versa. W zaproponowanym algorytmie rozwiązano ten problem poprzez rekurencyjne wywołanie metody w myśl zasady "dziel i zwyciężaj". Zaproponowany algorytm został przetestowany dla zarejestrowanych rzeczywistych sygnałów dla szerokiej gamy dronów. Wyniki pokazują, że zaproponowany rekurencyjny algorytm detekcji sygnału poprawnie rozdziela spektrogram na fragmenty zawierające transmisję, jak i te zawierające szum, zachowując przy tym dużą dokładność. Ponadto zaproponowany algorytm jest skalowalny w swej dokładności, a zastosowanie odpowiedniego progowania pozwala na wyodrębnienie użytecznego sygnału. Finalnie, mimo że w obecnej postaci detekcja zajmuje dwukrotnie czasu trwania analizowanego sygnału, to istnieje możliwość zrównoleglenia obliczeń oraz zastosowanie procesorów graficznych GPU (ang. *Graphics Processing Unit*). Wstępne analizy pokazują, że możliwe jest zmniejszenie czasu detekcji, tak aby był on porównywalny bądź mniejszy niż czas trwania sygnału co pozwoli na zakłócanie w czasie rzeczywistym bazując na tej detekcji.

PODZIĘKOWANIA

Publikacja powstała w wyniku realizacji Projektu pt.: „Sieciocentryczny system monitorowania ruchu i ochrony przestrzeni powietrznej przed BSP dla prewencji

w stanach zagrożenia publicznego, ochrony infrastruktury krytycznej i obiektów publicznych (SSAD)” realizowany w ramach Działania 1.1 Programu Operacyjnego Inteligentny Rozwój 2014-2020 współfinansowanego ze środków Europejskiego Funduszu Rozwoju Regionalnego.

LITERATURA

- [1] Carolyn J. Swinney oraz John C. Woods. 2021. „The Effect of Real-World Interference on CNN Feature Extraction and Machine Learning Classification of Unmanned Aerial Systems”. *Aerospace* 8, 7(179). <https://doi.org/10.3390/aerospace8070179>
- [2] DeepSig. 2023. „Using OmniSIG SDK to Create a Drone Detection Model”. <https://www.deepsig.ai/white-papers/>
- [3] DeepSig. 2023. „Wireless Signal Identification and Analysis”. <https://www.deepsig.ai/white-papers/>
- [4] S. Horstmann, D. Ramírez oraz P. J. Schreier. 2020. „Two-Channel Passive Detection of Cyclostationary Signals”. *Proceedings of the IEEE Transactions on Signal Processing*, 68:2340-2355, 2020, doi: 10.1109/TSP.2020.2981767
- [5] P. Urriza, E. Rebeiz oraz D. Cabric. 2013. „Multiple antenna cyclostationary spectrum sensing based on the cyclic correlation significance test”. *IEEE Journal on Selected Areas in Communications*, 31(11):2185-2195
- [6] H. Fan, Y. Guo oraz Y. Xu. 2008. „A novel algorithm of blind detection of frequency hopping signal based on second-order cyclostationarity”. *Proceedings of the Congress on Image and Signal Processing*, 5:399-402
- [7] Y. Zeng, Y-C Liang. 2009. „Eigenvalue-based spectrum sensing algorithms for cognitive radio”. *IEEE transactions on communications*, 57(6):1784-1793
- [8] Keogh, E., Chu, S., Hart, D., and Pazzani, M. 2001. „An online algorithm for segmenting time series”. *Proceedings of the IEEE International Conference on Data Mining (ICDM)*, 289-296.
- [9] Fryzlewicz, P. 2007. „Unbalanced Haar technique for nonparametric function estimation”. *Journal of the American Statistical Association*, 102(480):1318-1327.