

**KLASYFIKATOR SVM W ZASTOSOWANIU DO SYNCHRONIZACJI
SYGNAŁU OFDM ZNIEKSZTAŁCONEGO PRZEZ KANAŁ WIELODROGOWY**
SVM CLASSIFIER IN APPLICATION TO SYNCHRONIZATION
OF THE OFDM SIGNAL DISTORTED BY THE MULTIPATH CHANNEL

Marek Blok¹; Karol Gmiński²; Patryk Miklaszewski³

¹ Politechnika Gdańska, Wydział Elektroniki, Telekomunikacji i Informatyki, Gdańsk, marek.blok@pg.edu.pl

² Politechnika Gdańska, Wydział Elektroniki, Telekomunikacji i Informatyki, Gdańsk, s171856@student.pg.edu.pl

³ Politechnika Gdańska, Wydział Elektroniki, Telekomunikacji i Informatyki, Gdańsk, s172010@student.pg.edu.pl

Streszczenie: W pracy przedstawiono analizę przydatności klasyfikatora SVM bazującego na uczeniu maszynowym do estymacji przesunięcia czasowego odebranego symbolu OFDM. Przedstawione wyniki wykazują, że ten klasyfikator potrafi zapewnić synchronizację dla różnych kanałów wielodrogowych o wysokim poziomie szumu. Eksperymenty przeprowadzone w Matlabie z użyciem modeli modulatora i demodulatora wykazały, że w większości przypadków klasyfikator prawidłowo oceniał przesunięcie czasowe symbolu OFDM, nawet gdy był trenowany dla innego modelu kanału.

Abstract: The paper presents an analysis of capabilities of machine learning based SVM classifier to estimate the OFDM symbol time offset at the receiver. The presented results demonstrate classifier's ability to provide synchronization for various multipath channel models with high noise levels. The research was conducted using OFDM modulator and demodulator models implemented in Matlab. It has been shown that in most cases the classifier was able to determine the time shift of the OFDM symbol with high confidence even if it was trained for a different channel model.

Słowa kluczowe: klasyfikator SVM, OFDM, prefiks cykliczny, synchronizacja symbolowa.

Keywords: cyclic prefix, OFDM, SVM classifier, symbol synchronization.

1. WSTĘP

OFDM (Orthogonal Frequency-Division Multiplexing) jest bardzo popularną metodą multipleksacji częstotliwościowej, wykorzystywaną między innymi w technologii dostępowej ADSL, sieciach bezprzewodowych 802.11, telefonii mobilnej 4G/LTE oraz 5G jak i w systemach telewizji cyfrowej DVB-T oraz DVB-T2 [3, 5]. Zastosowanie techniki OFDM upraszcza uzyskanie wysokich przepływności strumienia danych poprzez rozdzielanie danych pomiędzy wiele mniejszych strumieni przesyłanych z wykorzystaniem ortogonalnych podnośnych. Użycie w OFDM ortogonalnych podnośnych powoduje zwiększenie efektywności widmowej transmisji i uzyskanie wyższych szybkości transmisji. Dodatkowo podejście to pozwala na znaczące zredukowanie wpływu zniekształceń wynikających z propagacji wielodrogowej i odbiór sygnału transmitowanego przez kanał cechujący się wysokim poziomem ISI (*Intersymbol Interference*) [1, 5].

Prawidłowy odbiór sygnału OFDM wymaga poprawnej synchronizacji symbolowej, która istotna jest również w odniesieniu do minimalizacji wpływu ISI. Synchronizacja symbolu OFDM może być uzyskana na różne sposoby. Ze względu na złożoną postać symbolu OFDM zwykle wykorzystuje się do tego dodatkowe elementy takie jak sygnały pilotowe, czy prefiks cykliczny [1, 5]. Kanał wielodrogowy sprawia, że odebrany sygnał jest sumą wielu sygnałów nadanych różniących się opóźnieniem, co skutkuje rozmyciem sygnału obserwowanym jako ISI, co utrudnia prawidłową ocenę przesunięcia czasowego odebranego symbolu OFDM. W związku z tym autorzy postanowili do tego zadania zastosować klasyfikator bazujący na sieci neuronowej i zweryfikować jego przydatność do tego zastosowania. Jak udało się wykazać w ramach przeprowadzonych symulacji, zastosowany klasyfikator pozwala na skuteczne oszacowanie opóźnienia symbolu OFDM nawet dla silnych interferencji między-symbolowych, jednak użycie sieci neuronowej utrudnia ocenę czy podejmowana decyzja bazuje na cyklicznym prefiksie dodawanym do symboli OFDM, czy też na innych cechach przetwarzanego sygnału.

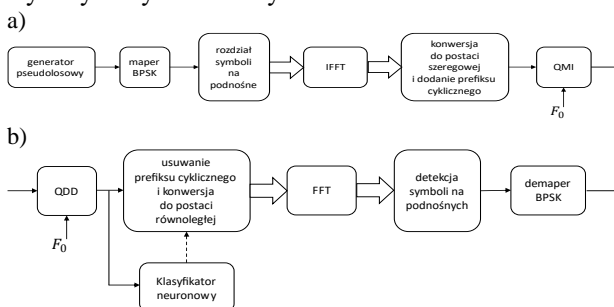
2. PROPONOWANE ROZWIĄZANIE

Zaproponowane rozwiązanie synchronizacji symbolowej zakłada uzupełnienie odbiornika OFDM [1, 4, 5] o klasyfikator wykorzystujący uczenie maszynowe. W symulowanym systemie zakładamy, że odebrany sygnał jest przekształcany z użyciem demodulatora kwadraturowego do postaci zespolonego sygnału podstawowo-pasmowego. Następnie klasyfikator SVM (*Support Vector Machines*) [2] dostępny w środowisku Matlab jest wykorzystywany do oceny przesunięcia czasowego bieżącego segmentu odebranego sygnału, co pozwala na realizację synchronizacji symbolowej nawet, jeżeli odbierany sygnał jest zniekształcony przez zaszumiony kanał wielodrogowy. Na potrzeby treningu klasyfikatora oraz jego testów konieczne było również zrealizowanie generatora podstawowo-pasmowego sygnału OFDM.

2.1. Generacja i demodulacja sygnału OFDM

Na rys. 1 przedstawiono ogólny schemat nadajnika (a) oraz odbiornika (b) sygnału OFDM [1, 5]. Istotną cechą OFDM jest, to że generacja oraz demodulacja sygnału

OFDM może być zrealizowana z użyciem wydajnego numerycznie algorytmu IFFT/FFT. Poza tym elementem odpowiedzialnym za umieszczanie/wydobywanie symboli na/z podnośnych, po stronie nadawczej (rys. 1a) mamy konwersję ciągu binarnego na symbole konstelacji podstawowej modulacji cyfrowej używanej w podkanałach (tutaj dla uproszczenia zastosowano BPSK), uzupełnianie symbolu OFDM o prefiks cykliczny oraz ulokowanie tak wygenerowanego sygnału podstawowo-pasmowego na zakładanej częstotliwości nośnej F_0 (QMI – *quadrature modulation with interpolation*). Z kolei, po stronie odbiorczej odwracamy ten proces zaczynając od demodulacji do pasma podstawowego (QDD – *quadrature decimation with demodulation*) z filtracją decymacyjną usuwającą jednocześnie zakłócenia pozapasmowe. Następnie konieczna jest identyfikacja początku symbolu OFDM pozwalająca na usunięcie prefiksu cyklicznego a następnie wydobywanie symboli z użyciem FFT.



Rys. 1. Nadajnik (a) i odbiornik (b) OFDM

2.2. Synchronizacja symbolowa

W zaproponowanym rozwiązaniu zakładamy, tak jak to pokazano na rys. 1, że symbole generowanego sygnału OFDM są uzupełniane o prefiks cykliczny. Dodanie prefiksu cyklicznego jest z jednej strony wykorzystywane do ograniczenia wpływu ISI, ułatwiając wydobywanie po stronie odbiorczej segmentu symbolu o ograniczonym wpływie ISI na ortogonalność w obrębie symbolu. Z drugiej strony prefiks cykliczny przenosi dodatkową informację o przesunięciu czasowym symbolu OFDM, powiązaną z tym, że początek każdego przedłużonego symbolu jest kopią jego końcowej części [1, 5].

Można przypuszczać, że zastosowany klasyfikator uczy się przede wszystkim identyfikować przesunięcie czasowe prefiksu cyklicznego w obserwowanym segmencie sygnału. Ponieważ długość segmentu sygnału podawanego na wejście klasyfikatora może być różna, w ramach badań sprawdzono również wpływ jego długości na dokładność klasyfikacji. Aby zagwarantować, że niezależnie od opóźnienia w analizowanym fragmencie będzie zawarty przynajmniej jeden kompletny symbol OFDM zawierający prefiks cykliczny i odpowiadający mu oryginalny fragment symbolu, przyjęto, że najmniejsza długość okna równoważną dwóm okresom symbolowym OFDM.


2.3. Model kanału

Na potrzeby treningu klasyfikatora oraz jego testów przyjęto kanał Rice'a, który jest wielodrogowym modelem kanału z zanikami, z addytywnym gaussowskim szumem białym. Na potrzeby testów założono, że sygnał dociera ścieżkami o pięciu różnych opóźnieniach i średnich tłumieniach. Poza referencyjnym kanałem z pojedynczą ścieżką (rys. 2a, dalej oznaczany jako Rice 0), przyjęto pięć różnych modeli kanałów.

Na rys. 2 pokazano wykresy oczkowe zastosowanych modeli kanałów dla wysokiego SNR w kanale. W efekcie zniekształceń wielodrogowych transmitowany sygnał ulega rozproszeniu czasowemu co skutkuje zamykaniem się oka (*eye diagram*) i wymaga dodatkowej korekty w ramach synchronizacji symbolowej. Dla modeli Rice 1 (rys. 2b), Rice 2 (rys. 2c) oraz Rice 3 (rys. 2d) przyjęto następujące średnie tłumienia ścieżek: 0, -10, -20, -25 oraz -30dB. W tab. 1 zestawiono wielkość opóźnień ścieżek modelu podanych jako procent czasu trwania prefiksu cyklicznego. Tylko dla modelu Rice 1 opóźnienia te nie przekraczają czasu trwania prefiksu, ale ze względu na duże tłumienie kolejnych ścieżek możliwy jest odbiór praktycznie pozbawiony ISI (rys. 2b, c i d). Dwa kolejne modele Rice 4 (rys. 2e) oraz Rice 5 (rys. 2f) cechują nieduże średnie tłumienia ścieżek: 0, -2, -4, -5 oraz -6dB, stąd też rozmycie wykresów oczkowych jest znacząco wyraźniejsze. Model Rice 4 cechują stosunkowo nieduże opóźnienia, stąd i w tym przypadku możliwy jest odbiór pozbawiony ISI (rys. 2e). Z kolei, dwie ostatnie ścieżki modelu Rice 5 cechuje opóźnienie przekraczające wielkość prefiksu cyklicznego i chociaż w przypadku braku addytywnego szumu w kanale możliwy jest prawidłowy odbiór, to jednak zniekształcenia ISI są nieuniknione (rys. 2f). W tym przypadku zadaniem synchronizacji symbolowej jest minimalizacja tych zniekształceń.

Tab. 1. Opóźnienia ścieżek modeli kanałów; % CP

Model	1.	2.	3.	4.	5.
Rice 1	0	24	48	72	98
Rice 2	0	35	69	115	172
Rice 3	0	104	111	118	125
Rice 4	0	52	66	82	104
Rice 5	0	78	99	123	156



Rys. 2. Wykresy oczkowe obserwowane dla demodulacji podkanału OFDM dla zastosowanych modeli kanałów

2.4. Dane treningowe i klasyfikator neuronowy


Jak wspomniano wcześniej, do rozwiązania problemu synchronizacji symbolowej sygnału OFDM proponujemy zastosować klasyfikator neuronowy. Przygotowanie, trening i walidację klasyfikatora pozwalającego na

ocenę przesunięcia czasowego symbolu OFDM wykonano z wykorzystaniem narzędzi dostępnych w środowisku Matlab. W ramach wstępnych analiz do dalszych badań wytypowano nieliniowy klasyfikator SVM.

W ramach eksperymentów przyjęto, że generowany sygnał OFDM przenosi 20 podkanałów oraz 20% prefiks cykliczny, co daje surowy symbol OFDM o długości 24 próbek. Przyjęto, że na wejście klasyfikatora podajemy część rzeczywistą obwiedni zespolonej zdemodulowanego sygnału, czyli sygnału wyjściowego QDD (rys. 1b).

Dane treningowe oraz walidacyjne przygotowano dla losowo generowanego strumienia binarnego podawanego na wejście modulatora OFDM (rys. 1a), sygnał wyjściowy był przepuszczany przez model kanału (p.2.3) a po dodaniu szumu białego dla zadanego SNR przepuszczany w demodulatorze przez QDD (rys. 1b). Tak pozyskany sygnał był cięty na segmenty o długości równej czasowi trwania 2, 5 lub 9 symboli OFDM. Początek każdego kolejnego wycinanego segmentu dobierano losowo, a wielkość tego przesunięcia była zachowywana jako etykieta na potrzeby treningu oraz walidacji.

Założono tu, że zadaniem klasyfikatora będzie ocena przesunięcia czasowego symbolu OFDM z dokładnością do jednej próbki, co przekłada się na 24 klasy wyjściowe klasyfikatora. Na rys. 3 przedstawiono przykładową macierz błędów (*Confusion Matrix*) uzyskaną dla treningu klasyfikatora na podstawie sygnału przesyłanego przez model kanału Rice 3. Jak widać przesunięcie czasowe dla większości ramek z sygnałem OFDM zostało w tym przypadku prawidłowo zaklasyfikowane (segmenty wyróżnione niebieskim kolorem), pozostałe pola sygnalizują błędną klasyfikację przesunięcia czasowego sygnału.



Rys. 3. Macierz błędów dla klasyfikatora trenowanego na podstawie sygnału przesyłanego przez kanał Rice 3.

3. WYNIKI

W punkcie tym przedstawiono wyniki eksperymentów służących ocenie przydatności klasyfikatora SVM do synchronizacji symbolowej w OFDM.

3.1. Wyniki treningu klasyfikatora zależnie od długości analizowanego segmentu sygnału

W ramach eksperymentów zweryfikowano dokładność klasyfikacji trenowanych klasyfikatorów (procent analizowanych segmentów, dla których w ramach walidacji dokonano bezbłędnej klasyfikacji przesunięcia symbolu OFDM wewnątrz analizowanego segmentu) zależnie do liczby symboli OFDM (2, 5 oraz 9) znajdujących się w segmencie analizowanym przez klasyfikator dla różnych wartości SNR (od 5 do 30dB). Dodatkowo zbadano jak dokładność klasyfikacji zależy od liczby segmentów zawartych w zestawie treningowym (od 5 do 80 tysięcy segmentów). W tab. 2-5 przedstawiono wyniki uzyskane dla kanału Rice 3, przy czym dla pozostałych modeli zaobserwowano podobne efekty.

Tab. 2. Dokładność klasyfikacji [%] kanału Rice 3 i użycia 2 symboli OFDM na segment

liczba segmentów	SNR [dB]				
	5	10	15	20	30
5k	4,3	7,5	22,3	52,4	76,8
10k	4,5	10,8	32,8	71,5	91,3
20k	5,2	11,7	43,6	83,0	97,0
40k	5,8	15,1	51,0	89,3	98,7
60k	6,0	16,8	53,7	91,3	99,3
80k	6,1	16,9	56,5	92,3	99,5

Tab. 3. Dokładność klasyfikacji [%] kanału Rice 3 i użycia 5 symboli OFDM na segment

liczba segmentów	SNR [dB]				
	5	10	15	20	30
5k	4,0	5,3	13,2	33,0	56,0
10k	5,2	8,3	32,5	73,5	92,7
20k	5,2	12,8	60,3	95,5	99,6
40k	5,7	21,2	80,5	99,1	99,9
60k	6,5	25,5	86,1	99,7	100,0
80k	7,0	27,8	88,1	99,8	100,0

Tab. 4. Dokładność klasyfikacji [%] kanału Rice 3 i użycia 9 symboli OFDM na segment

liczba segmentów	SNR [dB]				
	5	10	15	20	30
5k	4,0	5,8	7,9	17,3	28,5
10k	4,8	5,5	16,3	42,1	72,7
20k	4,5	9,9	45,3	90,7	99,1
40k	5,1	19,5	84,7	99,8	100,0
60k	6,3	28,0	93,4	100,0	100,0
80k	6,7	33,9	96,4	100,0	100,0

Zgodnie z oczekiwaniem zwiększanie liczby symboli w segmencie pozwala na uzyskanie lepszych wyników, co jest przede wszystkim istotne przy większym poziomie szumu w kanale. Dla dwóch symboli OFDM w analizowanym segmencie nie udało się przekroczyć istotnie 50% trafnych decyzji dla SNR równego 15dB. Zwiększenie liczby symboli OFDM w segmencie do 9-ciu pozwala na uzyskanie w tym przypadku 96% dokładności, a przy SNR równego 10dB uzyskać 33% dokładność. Uzyskanie takiej dokład-

ności wymaga jednocześnie zwiększania wielkości zestawu treningowego. Warto tutaj zauważyć, że jeżeli średnie opóźnienie kanału nie ulega gwałtownym zmianom, to pracę klasyfikatora można uzupełnić o mechanizmy śledzenia bieżącego opóźnienia sygnału, co może pozwolić na skuteczną synchronizację symbolową nawet przy mniejszej dokładności klasyfikacji.

3.2. Walidacja dla niedopasowanego kanału

W kolejnym eksperymencie zweryfikowano, na ile skutecznie klasyfikator wytrenowany na wybranym modelu kanału potrafi klasyfikować przesunięcie segmentu sygnału, który odebrano na wyjściu innego modelu kanału. Tab. 5-9 przedstawia wyniki uzyskane dla weryfikacji modeli wytrenowanych dla wszystkich pięciu przyjętych modeli kanałów (trenowanych dla SNR = 20dB). We wszystkich przypadkach walidację przeprowadzono na prostym kanale AWGN (Rice 0) oraz wszystkich pozostałych modelach dla różnych poziomów SNR.

Tab. 5. Dokładność [%] klasyfikatora trenowanego dla kanału Rice 1 i użycia 5 symboli OFDM na segment

Kanał	SNR [dB]					
	5	10	15	20	25	30
Rice 0	13,0	43,2	88,0	98,9	99,8	99,9
Rice 1	12,4	36,9	84,8	98,4	99,0	99,8
Rice 2	12,7	42,2	87,2	98,7	99,5	99,9
Rice 3	11,0	31,6	74,8	95,5	98,8	99,3
Rice 4	2,5	3,0	2,3	1,5	1,3	1,2
Rice 5	6,6	11,2	18,9	30,0	36,7	38,6

Tab. 6. Dokładność [%] klasyfikatora trenowanego dla kanału Rice 2 i użycia 5 symboli OFDM na segment

Kanał	SNR [dB]					
	5	10	15	20	25	30
Rice 0	12,0	38,3	86,8	98,0	99,4	99,7
Rice 1	11,1	36,8	79,5	97,0	99,3	99,4
Rice 2	14,3	45,7	90,2	98,8	99,8	100,0
Rice 3	9,2	30,4	75,7	93,2	98,0	98,6
Rice 4	3,7	1,2	1,1	0,5	0,3	0,1
Rice 5	5,9	8,6	15,9	21,3	29,8	28,0

Tab. 7. Dokładność [%] klasyfikatora trenowanego dla kanału Rice 3 i użycia 5 symboli OFDM na segment

Kanał	SNR [dB]					
	5	10	15	20	25	30
Rice 0	13,0	44,0	89,6	98,9	99,9	100,0
Rice 1	11,2	33,1	79,4	98,5	99,5	99,5
Rice 2	14,4	40,3	86,1	98,6	99,7	99,7
Rice 3	12,9	32,7	83,9	98,0	99,6	99,8
Rice 4	5,6	3,9	2,0	1,9	1,8	0,8
Rice 5	7,0	10,4	19,1	31,4	38,4	39,3

Jak można zauważyć, klasyfikatory trenowane na sygnałach pochodzących z mniej zniekształconych kanałów (Rice 1-3) dobrze sobie radzą, jeżeli są zastosowane dla innych kanałów podobnego typu. Najbardziej obiecujący wydaje się w tym przypadku klasyfikator trenowany na modelu Rice 3, który dla SNR nie mniejszego od 15dB dla kanałów Rice 0-3 osiąga dokładność rzędu 80% lub lepszą. Z drugiej strony kanały, w których ISI nie można skompensować zastosowanym CP dobre efekty można uzyskać jedynie dla klasyfikatora trenowanego dla danego modelu.

Tab. 8. Dokładność [%] klasyfikatora trenowanego dla kanału Rice 4 i użycia 5 symboli OFDM na segment

Kanał	SNR [dB]					
	5	10	15	20	25	30
Rice 0	8,2	14,9	31,7	47,0	51,8	56,4
Rice 1	6,9	10,0	22,0	36,0	39,2	40,5
Rice 2	6,6	10,4	15,9	24,2	29,7	31,1
Rice 3	6,0	11,0	21,6	31,7	37,3	39,9
Rice 4	3,9	4,5	3,8	3,6	1,8	1,8
Rice 5	12,1	34,6	80,8	97,3	98,7	99,6

Tab. 9. Dokładność [%] klasyfikatora trenowanego dla kanału Rice 5 i użycia 5 symboli OFDM na segment

Kanał	SNR [dB]					
	5	10	15	20	25	30
Rice 0	3,9	3,4	2,8	2,4	1,8	2,5
Rice 1	4,3	2,9	1,7	1,3	1,1	1,3
Rice 2	2,7	2,7	1,4	0,7	0,4	0,2
Rice 3	2,9	3,5	3,2	1,8	2,1	1,9
Rice 4	13,9	43,2	82,4	96,2	98,3	99,4
Rice 5	5,6	5,7	7,3	5,7	4,8	4,2

4. PODSUMOWANIE

W pracy przedstawiono wyniki badań możliwości zastosowania klasyfikatora SVM bazującego na uczeniu maszynowym do synchronizacji symbolowej w demodulatorze OFDM w obecności szumu i zniekształceń wielodrogowych. Wyniki pokazały, że dobre efekty można uzyskać dla kanałów, dla których ISI są ograniczane przez użyty prefiks cykliczny (CP). W takim przypadku wytrenowany klasyfikator można zastosować również dla odmiennego modelu kanału. Dla kanałów, dla których CP niewystarczająco eliminuje ISI klasyfikator SVM również dobrze sobie radził, ale w tym przypadku konieczne jest użycie klasyfikatora dedykowanego dla konkretnego modelu kanału.

LITERATURA

- [1] Ćwikowski Łukasz, Blok Marek. 2009. Educational model of the OFDM modulator and demodulator. *Photonics Applications in Astronomy, Communications, Industry, and High-Energy Physics Experiments*, SPIE, vol. 7502, pp. 485-490.
- [2] Garcia M. G., Rojo-Álvarez J. L., Alonso-Atienza F., Martínez-Ramón M. 2006. „Support vector machines for robust channel estimation in OFDM. *IEEE Signal Processing Letters*, 13(7), 397-400.
- [3] Khaizuran Abdullah, Hussain Zahir M. 2007. „Performance of Fourier-based and wavelet-based OFDM for DVB-T systems.” *IEEE Australasian Telecommunication Networks and Applications Conference*, pp. 475-479.
- [4] Kung Te-Lung, Parhi Keshab K. 2011. “Frequency Domain Symbol Synchronization for OFDM Systems”, *IEEE International Conference on Electro/Information Technology*, pp. 1-5.
- [5] Langton Charan. 2004. Orthogonal Frequency Division Multiplexing (OFDM) Tutorial, *Intuitive Guide to Principles of Communications*.

