



BIULETYN WAT
VOL. LV, NR 1, 2006

Specyficzna identyfikacja emiterów radarowych bazująca na analizie składowych głównych

ADAM KAWALEC, ROBERT OWCZAREK, TOMASZ RAPACKI,
STANISŁAW WNUCZEK

Wojskowa Akademia Techniczna, Wydział Elektroniki, Instytut Radioelektroniki,
00-908 Warszawa, ul. S. Kaliskiego 2

Streszczenie. W artykule została przedstawiona problematyka związana z identyfikacją emiterów radarowych należących do tego samego typu i klasy. Jest to specyficzny rodzaj identyfikacji (SEI, ang. *Specific Emitter Identification*), polegający na rozróżnianiu poszczególnych egzemplarzy tego samego typu radaru. Klasyczna identyfikacja sygnałów bazująca na analizie statystycznej podstawowych parametrów mierzalnych sygnału nie spełnia wymagań stawianych przed SEI. Przedstawiona w artykule metoda identyfikacji opiera się na przekształceniu Karhunen-Loeve'a (KL), która należy do metod analizy składowych głównych (PCA, ang. *Principal Component Analysis*).

Słowa kluczowe: walka elektroniczna, klasyfikacja cech sygnałów radarowych, specyficzna identyfikacja emiterów, przekształcenie Karhunen-Loeve'a

Symbole UKD: 621.396.96

1. Wstęp

Końcowym etapem procesu analizy sygnałów radarowych w urządzeniach rozpoznania (UR) jest identyfikacja. Jest to proces, w wyniku którego otrzymujemy odpowiedź na ważne pytanie: *czy odebrany sygnał radarowy posiada swoje odwzorowanie w zasobach bazy danych danego systemu rozpoznania* [1]. Specyficzna identyfikacja radarów jest problemem złożonym i skomplikowanym z kilku względów: wzorce poszczególnych egzemplarzy nie są rozdzielne względem uśrednionych (wyestymowanych) wartości podstawowych parametrów mierzalnych sygnału, ich prosta struktura minimalizuje liczbę pośrednich zależności między parametrami mierzalnymi (warunków dyskryminacyjnych), na podstawie których można szacować różnice między poszczególnymi egzemplarzami.

Ostatnio prowadzone w Instytucie Radioelektroniki WAT badania w tym zakresie jednoznacznie potwierdziły hipotezę dotyczącą istnienia w sygnałach radarowych nieintencjonalnych modulacji stanowiących wystarczający podzbiór dystynktywnych cech. Jest to związane z tym, że zarówno producenci, jak i użytkownicy radaru nie kontrolują wszystkich parametrów urządzenia, w szczególności charakterystyki wewnątrzimpulsowej generowanego sygnału (tzw. parametrów niemających „żadnego” wpływu na jakość pracy i parametry taktyczno-techniczne radaru). W związku z powyższym, w sygnale generowanym przez konkretny egzemplarz radaru występują nieintencjonalne modulacje, które stanowią jego cechą dystynktywną, umożliwiającą jego rozpoznanie (wyodrębnienie) na tle pozostałych egzemplarzy tego samego typu.

Identyfikację emiterów przeprowadzono z wykorzystaniem przekształcenia KL, często wykorzystywanego do rozwiązywania złożonych zadań klasyfikacji, zwłaszcza zadań niespełniających warunku liniowej separowalności oraz procedur normowania ocen zgodności badanego obiektu z wyróżnionymi klasami. Zastosowanie procedur umożliwia porównywanie otrzymanych ocen i następnie podejmowanie decyzji o przynależności badanego obiektu do określonej klasy.

Korelacja cech wzorca i analizowanego obiektu stanowi podstawę standardowych metod rozpoznawania. Zasadniczym problemem w tym zadaniu jest właściwy dobór przestrzeni cech, czyli określenie, na podstawie jakich cech obiektów jest realizowane rozpoznawanie. Oczywistym dążeniem jest wybór możliwie małej liczby wykorzystywanych cech. Redukcja cech polega na pominięciu w procesie identyfikacji tych cech, które przyjmują jednakowe (mało różniące się) wartości dla wszystkich obiektów [2]. Jako skuteczne narzędzie umożliwiające wyeliminowanie mało informatywnych (dystynktywnych) cech wykorzystuje się przekształcenie KL, przy czym możliwość tę uzyskuje się dzięki dekorelacji cech. Przekształcenie KL umożliwia także unormowanie pomiaru różnicy poszczególnych cech i przejście w naturalny sposób do stosowania odległości Mahalanobisa. Wykorzystanie tej odległości zamiast odległości euklidesowej pozwala uzyskać satysfakcjonujące rozwiązania wielu zadań klasyfikacji oraz grupowania.

2. Transformata Karhunena-Loeve’a

Istotą przekształcenia KL jest eliminacja cech słabo rozróżniających rozpoznawane obiekty z określonego wektora (zbioru, na podstawie którego definiowany jest wzorzec).

Przekształcenie KL definiuje się dla zadanej klasy sygnałów $\mathbf{u}^{(1)}, \mathbf{u}^{(2)}, \dots, \mathbf{u}^{(p)}$ poprzez obliczenie wektora średniego

$$\bar{\mathbf{u}} = \frac{1}{p} \sum_{i=1}^p \mathbf{u}^{(i)} \quad (1)$$

oraz macierz kowariancji

$$\mathbf{R} = \sum_{i=1}^p \mathbf{r}^{(i)} \left[\mathbf{r}^{(i)} \right]^T \quad \text{gdzie } \mathbf{r}^{(i)} = \mathbf{u}^{(i)} - \bar{\mathbf{u}}. \quad (2)$$

Następnie wyznacza się ortonormalne wektory własne $\mathbf{t}_1, \mathbf{t}_2, \dots, \mathbf{t}_N$ i odpowiadające im wartości własne $\lambda_1, \lambda_2, \dots, \lambda_N$ macierzy kowariancji \mathbf{R} spełniające zależność

$$\mathbf{R} \mathbf{t}_n = \lambda_n \mathbf{t}_n \quad n = 1, 2, \dots, N. \quad (3)$$

Macierz kowariancji \mathbf{R} jest dodatnio określona, zatem jej wektory własne są rzeczywiste, a wartości własne, rzeczywiste i nieujemne. Dodatkowo zostało przyjęte, że wartości i wektory własne są uporządkowane według malejących wartości własnych λ_n . Następnie wyznaczono macierz przekształcenia według zależności

$$\mathbf{T} = \begin{bmatrix} \mathbf{t}_1^T \\ \mathbf{t}_2^T \\ \dots \\ \mathbf{t}_N^T \end{bmatrix}. \quad (4)$$

Przekształcenie KL przyporządkowuje sygnałowi $\mathbf{u}^{(i)}$ transformatę $\mathbf{y}^{(i)} = \mathbf{T} \mathbf{u}^{(i)}$. Wartość transformaty $\mathbf{y}^{(i)}$ określa sygnał oryginalny $\mathbf{u}^{(i)}$ w nowym układzie współrzędnych [3]

$$\mathbf{u}^{(i)} = \mathbf{T}^{-1} \mathbf{y}^{(i)} = [\mathbf{t}_1, \mathbf{t}_2, \dots, \mathbf{t}_N] \begin{bmatrix} y_1^{(i)} \\ y_2^{(i)} \\ \dots \\ y_N^{(i)} \end{bmatrix} = \sum_{n=1}^N y_n^{(i)} \mathbf{t}_n. \quad (5)$$

Przedstawienie sygnału $\mathbf{u}^{(i)}$ w sposób określony powyższym wzorem jest nazywane rozkładem KL. Następnie oblicza się macierz kowariancji transformaty KL

$$\mathbf{P} = \sum_{i=1}^p \left[\mathbf{y}^{(i)} - \bar{\mathbf{y}} \right] \left[\mathbf{y}^{(i)} - \bar{\mathbf{y}} \right]^T, \quad \text{gdzie } \bar{\mathbf{y}} = \frac{1}{p} \sum_{i=1}^p \mathbf{y}^{(i)} = \frac{1}{p} \sum_{i=1}^p \mathbf{T} \mathbf{u}^{(i)} = \mathbf{T} \bar{\mathbf{u}}. \quad (6)$$

Macierz \mathbf{T} składa się z ortonormalnych wektorów własnych macierzy \mathbf{R} , więc otrzymujemy zależność:

$$\begin{aligned}
\mathbf{P} &= \sum_{i=1}^p [\mathbf{T}\mathbf{u}^{(i)} - \mathbf{T}\bar{\mathbf{u}}] [\mathbf{T}\mathbf{u}^{(i)} - \mathbf{T}\bar{\mathbf{u}}]^T = \mathbf{T} \sum_{i=1}^p [\mathbf{u}^{(i)} - \bar{\mathbf{u}}] [\mathbf{u}^{(i)} - \bar{\mathbf{u}}]^T \mathbf{T}^T = \\
&= \mathbf{T}\mathbf{R}\mathbf{T}^T = \begin{bmatrix} \mathbf{t}_1^T \\ \mathbf{t}_2^T \\ \dots \\ \mathbf{t}_N^T \end{bmatrix} \mathbf{R} [\mathbf{t}_1, \mathbf{t}_2, \dots, \mathbf{t}_N] = \begin{bmatrix} \mathbf{t}_1^T \\ \mathbf{t}_2^T \\ \dots \\ \mathbf{t}_N^T \end{bmatrix} [\mathbf{R}\mathbf{t}_1, \mathbf{R}\mathbf{t}_2, \dots, \mathbf{R}\mathbf{t}_N] = \\
&= \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_N).
\end{aligned} \tag{7}$$

Zależność powyższa oznacza, że współrzędne $\mathbf{y}_n^{(i)}$ transformaty KL $\mathbf{y}^{(i)}$ są nieskorelowane ($n = 1, 2, \dots, N$). Istota przekształcenia KL polega więc na dekorrelacji wektora cech, bowiem macierz kowariancji w wyniku transformacji jest macierzą diagonalną. Ocena zgodności badanej cechy z klasą \mathbf{K} polega na obliczeniu różnicy badanej cechy \mathbf{u} i wartości oczekiwanej $\bar{\mathbf{u}} = \mathbf{E}\mathbf{u}$ cech w klasie, tzn. wartości $\tilde{\mathbf{u}} = \mathbf{u} - \bar{\mathbf{u}}$, a następnie na zastosowaniu do otrzymanej różnicy przekształcenia KL [3]

$$\mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_n \end{bmatrix} = \mathbf{T}\tilde{\mathbf{u}} = \begin{bmatrix} \mathbf{t}_1^T \tilde{\mathbf{u}} \\ \mathbf{t}_2^T \tilde{\mathbf{u}} \\ \dots \\ \mathbf{t}_n^T \tilde{\mathbf{u}} \end{bmatrix}. \tag{8}$$

Ujednolicenie oceny zgodności polegało na unormowaniu poszczególnych komponentów transformaty KL w następujący sposób [4]:

$$\mathbf{z} = \begin{bmatrix} z_1 \\ z_2 \\ \dots \\ z_n \end{bmatrix} = \begin{bmatrix} \frac{y_1}{\sqrt{\lambda_1}} \\ \frac{y_2}{\sqrt{\lambda_2}} \\ \dots \\ \frac{y_n}{\sqrt{\lambda_n}} \end{bmatrix}. \tag{9}$$

Uzyskany w ten sposób wektor \mathbf{z} jest unormowany w tym sensie, że ma macierz korelacji równą macierzy jednostkowej

$$\begin{aligned}
\mathbf{E}(\mathbf{z} \mathbf{z}^T) &= \mathbf{E} \begin{bmatrix} z_1 z_1 & z_1 z_2 & \dots & z_1 z_n \\ z_2 z_1 & z_2 z_2 & \dots & z_2 z_n \\ \dots & \dots & \dots & \dots \\ z_n z_1 & z_n z_2 & \dots & z_n z_n \end{bmatrix} = \\
&= \mathbf{E} \begin{bmatrix} \frac{y_1 y_1}{\lambda_1} & \frac{y_1 y_2}{\sqrt{\lambda_1 \lambda_2}} & \dots & \frac{y_1 y_n}{\sqrt{\lambda_1 \lambda_n}} \\ \frac{y_2 y_1}{\sqrt{\lambda_2 \lambda_1}} & \frac{y_2 y_2}{\lambda_2} & \dots & \frac{y_2 y_n}{\sqrt{\lambda_2 \lambda_n}} \\ \dots & \dots & \dots & \dots \\ \frac{y_n y_1}{\sqrt{\lambda_n \lambda_1}} & \frac{y_n y_2}{\sqrt{\lambda_n \lambda_2}} & \dots & \frac{y_n y_n}{\lambda_n} \end{bmatrix} = \text{diag}(1, 1, \dots, 1). \quad (10)
\end{aligned}$$

Funkcjonał $\mathbf{d}(\mathbf{u})$ oceny zgodności wektora cech \mathbf{u} z klasą \mathbf{K} zdefiniowano następująco:

$$\begin{aligned}
\mathbf{d}(\mathbf{u}) &= \mathbf{z}^T \mathbf{z} = \sum_{k=1}^n z_k^2 = \sum_{k=1}^n \frac{y_k^2}{\lambda_k} = \sum_{k=1}^n \frac{(\mathbf{t}_k^T \tilde{\mathbf{u}})^2}{\lambda_k} = \sum_{k=1}^n (\tilde{\mathbf{u}}^T \mathbf{t}_k) \frac{1}{\lambda_k} (\mathbf{t}_k^T \tilde{\mathbf{u}}) = \\
&= \tilde{\mathbf{u}}^T \begin{bmatrix} \lambda_1^{-1} & 0 & \dots & 0 \\ 0 & \lambda_2^{-1} & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & \lambda_n^{-1} \end{bmatrix} \begin{bmatrix} \mathbf{t}_1^T \\ \mathbf{t}_2^T \\ \dots \\ \mathbf{t}_n^T \end{bmatrix} \tilde{\mathbf{u}} = \\
&= (\mathbf{u} - \bar{\mathbf{u}})^T \mathbf{T} \mathbf{\Lambda}^{-1} \mathbf{T}^T (\mathbf{u} - \bar{\mathbf{u}}) = (\mathbf{u} - \bar{\mathbf{u}})^T \mathbf{R}^{-1} (\mathbf{u} - \bar{\mathbf{u}}). \quad (11)
\end{aligned}$$

Odległość badanej cechy od wzorca klasy jest więc ważoną odległością w przestrzeni cech i nazywana jest odległością Mahalanobisa [3]. Funkcjonał $\mathbf{d}(\mathbf{u})$ jest zatem wykorzystany w niezależnych kanałach oceny zgodności badanego obiektu z zadaną klasą.

3. Opis metody badawczej

Realizowany w badaniach proces identyfikacji emiterów polegał na:

- określeniu przestrzeni cech,
- określeniu reprezentantów klas (określeniu w przestrzeni cech jednego wzorca dla każdej klasy — każdego egzemplarza),

- określeniu powierzchni rozdzielających reprezentantów w przestrzeni cech (określeniu metryki w przestrzeni cech, służącej do oceny odległości klasyfikowanego obiektu od wzorca).

W przeprowadzonych badaniach identyfikacja emiterów polegała na obliczeniu, dla każdego wzorca, jego odległości od klasyfikowanego obiektu i na zakwalifikowaniu obiektu do klasy reprezentowanej przez wzorzec położony najbliżej (identyfikacja w zbiorze zamkniętym, ang. *closed-set identification*) [2].

W badaniach wykorzystano metody obejmujące technikę grupowania oraz transformację KL. Przebieg procesu identyfikacji realizowany był w dwóch etapach. W pierwszym etapie, będącym etapem ekstrakcji charakterystyk sygnału (proces uczenia), celem było zbudowanie opisu sygnału, pozwalającego na jego prawidłową identyfikację (konstruowanie wzorców). Drugim etapem był właściwy proces identyfikacji, w którym poszczególne sygnały zarejestrowane w zbiorach pomiarowych podlegały rozpoznawaniu na podstawie charakterystyk sygnału wyznaczonych w pierwszym etapie [2].

3.1. Ekstrakcja charakterystyk

3.1.1. Wzorcowa próba pomiarowa

Ekstrakcja charakterystyk sygnału jest oparta na wzorcowej próbie pomiarowej. Próba ta składała się z ciągu kilkunastu lub kilkudziesięciu próbek sygnału (dla różnych parametrów sygnału radarowego), z których tworzone wzorzec klasy wykorzystywany w procesie rozpoznawania. Wzorzec klasy w powyższych badaniach był definiowany na podstawie rzeczywistych danych pomiarowych (rejestracji sygnału radarowego), więc przeprowadzano wstępną analizę danych w celu eliminacji zjawisk niezwiązanych bezpośrednio z samym procesem generacji i odbioru sygnału od radaru (np. proces wielotorowości propagacji sygnału).

3.1.2. Obserwacja, reprezentacja próby pomiarowej

Obserwację stanowi wektor \mathbf{a} złożony z próbek sygnału, wyciętych oknem czasowym z wzorcowej próby pomiarowej

$$\mathbf{a} = [a(1), a(2), \dots, a(p)]^T, \quad (12)$$

gdzie p — rząd predykcji (długość okna analizy wyrażona w liczbie próbek).

Informacje uzyskane dla kolejnych okien czasowych stanowią skończony ciąg obserwacji — próbę pomiarową \mathbf{A}

$$\mathbf{A} = \begin{bmatrix} A(1,1) & A(1,2) & \dots & A(1,n) \\ A(2,1) & A(2,2) & \dots & A(2,n) \\ \dots & \dots & \dots & \dots \\ A(p,1) & A(p,2) & \dots & A(p,n) \end{bmatrix}, \text{ gdzie } \mathbf{a}_k = \begin{bmatrix} A(1,k) \\ A(2,k) \\ \dots \\ A(p,k) \end{bmatrix}, \quad (13)$$

gdzie n jest liczbą obserwacji wydzielonych w próbie pomiarowej.

3.1.3. Grupowanie

W celu rozpoznawania wzorców, próba pomiarowa była traktowana jako zbiór wektorów \mathbf{a}_k . Następuje tu świadome zatracenie informacji o kolejności czasowej obserwacji. Zbiór obserwacji A był poddawany procesowi grupowania. Celem grupowania był podział zbioru obserwacji sygnału radarowego na grupy (klastry, skupienia) złożone z obiektów jednorodnych bądź podobnych. W badaniach wykorzystano algorytm grupowania do zadanej liczby grup ISODATA (ang. *Iterative Self-Organizing Data Analysis Techniques*) [5].

Dane wejściowe procesu grupowania stanowiły zbiór wektorów \mathbf{X} . Proces grupowania polegał na utworzeniu L grup (klastrów, skupień) G_k o następujących właściwościach:

- grupa G_k zawiera L_k wektorów ze zbioru X , grupy są rozłączne i w sumie wyczerpują zadany zbiór X ,
- dla każdej grupy wyznaczany jest jej środek z_k , $z_k = \frac{1}{L_k} \sum_{x \in G_k} x$, gdzie: k oznacza numer grupy, $L_k = \text{card } G_k$ — licznosc grupy G_k ,
- jako wskaźnik jakości każdego etapu grupowania przyjmuje się sumę odległości składników grup od środków odpowiednich grup, tzn.

$$Q = \sum_{k=1}^L \sum_{x \in G_k} d(\mathbf{x}, \mathbf{z}_k). \quad (14)$$

Wynik grupowania stanowi M grup obserwacji. Każda grupa zostaje zapisana jako macierz $\mathbf{A}^{(x)}$ utworzona z obserwacji $\mathbf{a}^{(x)}$ należących do grupy x [5]:

$$\mathbf{A}^{(x)} = \begin{bmatrix} A^{(x)}(1,1) & A^{(x)}(1,2) & \dots & A^{(x)}(1,n) \\ A^{(x)}(2,1) & A^{(x)}(2,2) & \dots & A^{(x)}(2,n) \\ \dots & \dots & \dots & \dots \\ A^{(x)}(p,1) & A^{(x)}(p,2) & \dots & A^{(x)}(p,n) \end{bmatrix}, \text{ gdzie } \mathbf{a}_k^{(x)} = \begin{bmatrix} A^{(x)}(1,k) \\ A^{(x)}(2,k) \\ \dots \\ A^{(x)}(p,k) \end{bmatrix}. \quad (15)$$

3.1.4. Ekstrakcja parametrów grupy obserwacji

Dla każdej grupy obserwacji wyznaczano cztery przedstawione poniżej elementy, opisujące grupę obserwacji:

- wektor wartości średnich obserwacji przez uśrednienie wierszy macierzy $\mathbf{A}^{(x)}$

$$\overline{a^{(x)}}(i) = \frac{1}{k} \sum_{j=1}^k \mathbf{A}^{(x)}(i, j) \quad i = 1, 2, \dots, p, j = 1, 2, \dots, k \quad (16)$$

będący reprezentantem grupy x danej próby,

- macierz transformacji KL, oznaczana przez $\mathbf{T}^{(x)}$, jest to macierz modalna złożona z wektorów własnych macierzy kowariancji wektorów \mathbf{a}_k ,
- wektor wartości własnych, złożony z wartości własnych macierzy kowariancji wektorów \mathbf{a}_k , oznaczany przez $\lambda^{(x)}$

$$\lambda^{(x)} = \begin{bmatrix} \lambda^{(x)}(1) \\ \lambda^{(x)}(2) \\ \dots \\ \lambda^{(x)}(p) \end{bmatrix}, \quad (17)$$

- wskaźnik rozproszenia obserwacji z grupy zdefiniowany jako

$$r^{(x)} = \sum_{i=1}^p \lambda^{(x)}(i). \quad (18)$$

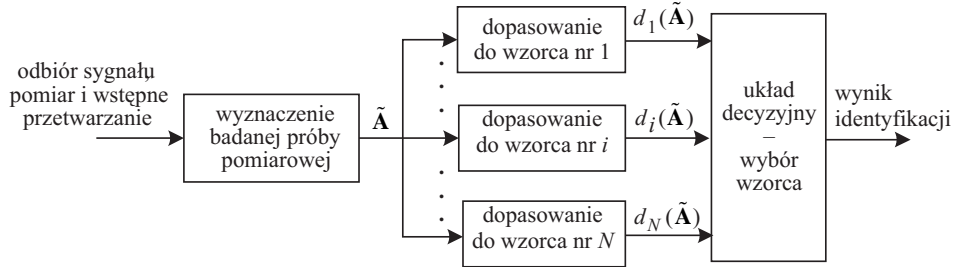
W wyniku ekstrakcji charakterystyk sygnału (procesu uczenia) każdy wzorek źródła emisji otrzymuje opis w postaci M czwórek $(\overline{\mathbf{a}}^{(x)}, \mathbf{T}^{(x)}, \lambda^{(x)}, r^{(x)})$.

4. Identyfikacja

Na wejście układu identyfikacji podawana była badana próba sygnału. Pierwszym etapem było wyznaczenie reprezentacji $\tilde{\mathbf{A}}$

$$\tilde{\mathbf{A}} = \begin{bmatrix} \tilde{\mathbf{A}}(1,1) & \tilde{\mathbf{A}}(1,2) & \dots & \tilde{\mathbf{A}}(1,n) \\ \tilde{\mathbf{A}}(2,1) & \tilde{\mathbf{A}}(2,2) & \dots & \tilde{\mathbf{A}}(2,n) \\ \dots & \dots & \dots & \dots \\ \tilde{\mathbf{A}}(p,1) & \tilde{\mathbf{A}}(p,2) & \dots & \tilde{\mathbf{A}}(p,n) \end{bmatrix}, \quad \text{gdzie } \tilde{\mathbf{a}}_k = \begin{bmatrix} \tilde{\mathbf{A}}(1,k) \\ \tilde{\mathbf{A}}(2,k) \\ \dots \\ \tilde{\mathbf{A}}(p,k) \end{bmatrix} \quad (19)$$

oraz p — długości obserwacji wydzielonych z próby (szerokość okna czasowego), n — liczba obserwacji wydzielonych z próby.



Rys. 1. Układ niezależnej identyfikacji (detekcji) sygnałów o SDCPS

Następnie dla każdego wzorca i wyznaczano wskaźnik dopasowania do badanej próby pomiarowej $d_i(\tilde{\mathbf{A}})$, a w bloku wyboru wzorca następowało podjęcie decyzji o identyfikacji radaru, dla którego wskaźnik dopasowania przyjmował wartość minimalną [6]

$$d_i(\tilde{\mathbf{A}}) = \min \{ d_1(\tilde{\mathbf{A}}), d_2(\tilde{\mathbf{A}}), \dots, d_N(\tilde{\mathbf{A}}) \}. \quad (20)$$

Zasadnicze znaczenie w zaprojektowanym układzie identyfikacji radarów odgrywał blok dopasowania do wzorca. Obserwacje ze zbioru $\tilde{\mathbf{A}}$ były klasyfikowane na zasadzie minimalnej odległości względem reprezentantów $\bar{\mathbf{a}}^{(x)}$. Następnie dla każdej niezerowej klasy obserwacji przeprowadzana była ocena zgodności.

Najpierw, w układzie dopasowania, następowało obliczenie macierzy odchyień $\tilde{\mathbf{A}}_{\Delta}^{(x)}$ dla zbioru obserwacji $\tilde{\mathbf{A}}$ względem $\bar{\mathbf{a}}^{(x)}$

$$\tilde{\mathbf{A}}_{\Delta}^{(x)} = \begin{bmatrix} \tilde{\mathbf{A}}^{(x)}(1,1) - \bar{\mathbf{a}}^{(x)}(1) & \tilde{\mathbf{A}}^{(x)}(1,2) - \bar{\mathbf{a}}^{(x)}(1) & \dots & \tilde{\mathbf{A}}^{(x)}(1,k) - \bar{\mathbf{a}}^{(x)}(1) \\ \tilde{\mathbf{A}}^{(x)}(2,1) - \bar{\mathbf{a}}^{(x)}(2) & \tilde{\mathbf{A}}^{(x)}(2,2) - \bar{\mathbf{a}}^{(x)}(2) & \dots & \tilde{\mathbf{A}}^{(x)}(2,k) - \bar{\mathbf{a}}^{(x)}(2) \\ \dots & \dots & \dots & \dots \\ \tilde{\mathbf{A}}^{(x)}(p,1) - \bar{\mathbf{a}}^{(x)}(p) & \tilde{\mathbf{A}}^{(x)}(p,2) - \bar{\mathbf{a}}^{(x)}(p) & \dots & \tilde{\mathbf{A}}^{(x)}(p,k) - \bar{\mathbf{a}}^{(x)}(p) \end{bmatrix}, \quad (21)$$

następnie obliczana była transformata KL dla wszystkich obserwacji z każdej klasy x ($x = 1, 2, \dots, M$)

$$\mathbf{Y}^{(x)} = (\mathbf{T}^{(x)})^T \tilde{\mathbf{A}}_{\Delta}^{(x)}. \quad (22)$$

W bloku decyzyjnym wyznaczany był wskaźnik dopasowania $d^{(x)}$ na podstawie zależności

$$d^{(x)} = \frac{\mathbf{k} \tilde{\mathbf{r}}^{(x)}}{\mathbf{n} \mathbf{r}^{(x)}}, \quad (23)$$

gdzie: k — liczba obserwacji w klasie x ; n — liczba obserwacji w całej próbie; $r^{(x)}$ — wskaźnik rozproszenia wyznaczony w procesie uczenia oraz $\tilde{r}^{(x)}$ — wskaźnik rozproszenia dla rozpatrywanej klasy obserwacji x

$$\tilde{r}^{(x)} = \text{tr} ((\mathbf{Y}_s^{(x)})^T \mathbf{Y}_s^{(x)}), \text{ gdzie } \text{tr} \text{ — ślad macierzy} \quad (24)$$

oraz

$$\mathbf{Y}_s^{(x)}(i,j) = \mathbf{Y}^{(x)}(i,j) / \lambda^{(x)}(i) \text{ dla } i = 1, 2, \dots, p, j = 1, 2, \dots, k. \quad (25)$$

5. Wyniki badań

W trakcie badań zostały zarejestrowane 424 zbiory testowe pochodzące od 9 egzemplarzy tego samego typu radaru. Jako reprezentatywną próbę do badań umożliwiających ocenę skuteczności wykorzystania SEI do identyfikacji emiterów, wybrano trzy rejestracje: dwie pochodzą od egzemplarza A badanego typu radaru, przy czym zostały one tak dobrane, aby wstępne wyniki porównania sygnałów dały najgorsze współczynniki klasyfikacji (pierwsza rejestracja W_1 — listek główny, druga rejestracja W_2 — listki boczne i tylny). Trzecia rejestracja pochodziła od egzemplarza B badanego typu radaru, przy czym została wybrana tak, aby wstępne wyniki porównania struktury sygnałów z pierwszą rejestracją były jak najlepsze (trzecia rejestracja W_3 — listek główny, ten sam poziom sygnału jak w rejestracji pierwszej).

Proces identyfikacji przeprowadzono na podstawie danych zarejestrowanych z wyjścia detektora FM, w oparciu o wyznaczone wektory sygnału (reprezentantów cech). Proces identyfikacji zrealizowano w oparciu o:

- pomiar odległości i pomiar podobieństwa,
- podjęcie decyzji w oparciu o kryterium klasyfikacji minimalno-odległościowej.

Odległość między elementami $x, y \in V$ była definiowana jako wartość funkcji $d(x, y)$ (miara odległości) tak, że

$$d: V \times V \rightarrow \{ r \in R^1 : r \geq 0 \}, \quad (26)$$

przy czym

$$\forall_{x,y \in V} d(x,x) \leq d(x,y) \quad \forall_{x,y \in V} d(x,y) = d(y,x) \quad \forall_{x,y,z \in V} d(x,z) \leq d(x,y) + d(y,z).$$

Podobieństwo między elementami $x, y \in V$ było definiowane jako wartość funkcji $h(x, y)$ (miara podobieństwa), tak że

$$h: V \times V \rightarrow \{ r \in R^1 : 0 \leq r \leq 1 \} \quad (27)$$

i spełniało warunki

$$\forall_{x,y \in V} \mathbf{h}(x,y) \leq \mathbf{h}(x,x), \quad \forall_{x,y \in V} \mathbf{h}(x,y) = \mathbf{h}(y,x).$$

Do badań zostały wykorzystane następujące miary odległości i podobieństwa [3, 7]:

(1) miara separacji cech

$$D_{xAB} = \frac{|\mu_{xA} - \mu_{xB}|}{\sqrt{(\sigma_{xA}^2 + \sigma_{xB}^2)}} \quad (28)$$

(2) odległość euklidesowa

$$d_E^2(x,y) = (\mathbf{x} - \mathbf{y})^T (\mathbf{x} - \mathbf{y}), \quad \forall x,y \in V \quad (29)$$

(3) odległość Mahalanobisa

$$d_M^2(x,y) = (\mathbf{x} - \mathbf{y})^T \mathbf{C}^{-1} (\mathbf{x} - \mathbf{y}), \quad \forall x,y \in V \quad (30)$$

(4) odległość Hamminga

$$d_H(x,y) = \frac{1}{m} \sum_{i=1}^m |x[i] - y[i]|, \quad \forall x,y \in V^m \quad (31)$$

(5) odległość Canberra

$$d_C(x,y) = \sum_{i=1}^m \frac{|x[i] - y[i]|}{x[i] + y[i]}, \quad \forall x,y \in V^m \quad (32)$$

(6) miara podobieństwa typu cosinus

$$h_C(x,y) = \frac{\mathbf{x}^T \mathbf{y}}{\sqrt{\mathbf{x}^T \mathbf{x} \mathbf{y}^T \mathbf{y}}}, \quad \forall x,y \in V^m \quad (33)$$

Po wyznaczeniu miar odległości między poszczególnymi sygnałami zastosowano odpowiednie funkcje decyzyjne, które umożliwiły przydzielenie badanego sygnału do jednego z zaimplementowanych wzorców.

Jako kryterium klasyfikacji zostało zastosowane jedno z podstawowych kryteriów progowych — kryterium „najbliższego sąsiada” [7]

$$\forall_{V_k \in Q_{opt}} \forall_{x \in V_k} \exists_{\substack{y \neq x \\ y \in V_k}} \mathbf{d}(x,y) \leq \mathbf{d}_{\max}. \quad (34)$$

TABELA 1

Wyniki miar odległości i podobieństwa między badanymi rejestracjami

	$d^{(x)}$	D_{KAB}	d_E	d_M	d_H	d_C	h_C
W_1-W_2	63,31	0,5621	2 686,00	13,2400	0,8855	0,0360	1,0000
W_1-W_3	352,48	0,6615	2 123 690,00	10 468,0000	33,2290	0,1618	0,9986
W_2-W_3	377,88	0,0994	2 161 896,00	11 277,0000	33,5378	0,1629	0,9985
W_1-W_4	65,27	0,2957	671,50	3,3100	0,4428	0,0018	1,0000
W_2-W_4	66,51	0,2665	671,50	3,5100	0,4428	0,0018	1,0000
W_1-W_5	70,17	0,6615	84 770,00	417,8500	5,8897	0,0239	0,9996
W_2-W_5	73,19	0,0994	77 112,00	402,2400	5,6387	0,0229	0,9996
W_5-W_4	89,77	0,3659	80 270,00	422,0000	5,7584	0,0234	0,9996
$W_{11}-W_{21}$	4,99	0,5257	3,64	0,0174	0,4011	0,0016	1,0000
$W_{11}-W_{51}$	7,47	0,8919	535,96	2,5631	5,7810	0,0231	0,9999
$W_{21}-W_{51}$	7,59	0,3664	478,06	2,4092	5,4709	0,0223	0,9999

Należy ono do grupy klasyfikatorów minimalno-odległościowych. Sprawdza się w zastosowaniach, w których odległość pomiędzy wzorcami jest dostatecznie duża. Klasyfikator ten wytwarza granice decyzyjne w postaci prostych i hiperpłaszczyzn, a w tych badaniach problem rozdzielania wzorców sygnałów należał do separowalnych liniowo. Wyniki złożonej analizy (realizującej klasyfikację dla przypadków nieseparowalnych liniowo) są reprezentowane w postaci wskaźnika dopasowania $d^{(x)}$, będącego klasyfikatorem bazującym na transformacji KL.

W przypadku identyfikacji kolejnych wektorów (reprezentujących kolejne impulsy w danej rejestracji), pochodzących z tej samej rejestracji, uzyskano dla wszystkich 3 wzorców 100% prawidłowych rozpoznań.

Przeprowadzono również eksperyment polegający na utworzeniu wzorca W_4 , który powstał z uśredniania próbek w ramach wektora W_1 oraz W_2 . Wyniki identyfikacji były również zgodne dla wszystkich przypadków. Kolejny eksperyment polegał na odpowiednim przeskalowaniu wektora pochodzącego od innego egzemplarza (W_3-W_5) do warunków zgodnych dla wzorców W_1 i W_2 . Odległości między wzorcami znacznie się zmniejszyły, ale nie doprowadziło to do żadnego nieprawidłowego rozpoznania.

Następnie przeprowadzono eksperyment polegający na usunięciu wzorca W_2 . Badaniu poddano ponownie wszystkie wektory. Wszystkie wektory pochodzące z rejestracji W_1 i W_2 zostały prawidłowo zaklasyfikowane do wzorca powstałego z W_1 (w następnej kolejności do W_4), natomiast wektory drugiego egzemplarza zostały zaklasyfikowane do W_3 (następnie do W_5). Przeprowadzone badania obejmowały przetwarzanie znacznych zbiorów pomiarowych (1 wektor składał się

z 3-5 tysięcy próbek), więc przeprowadzono eksperyment polegający na redukcji danych do zadanej liczby okien, w ramach których wszystkie próbki zostały uśrednione. Przeprowadzono redukcję do 15 okien. Nowe wzorce reprezentowane były przez wektory 15-elementowe (W_1-W_{11} , W_2-W_{21} , W_5-W_{51}). Identyfikacja na podstawie zredukowanych wektorów również przyniosła prawidłowe wyniki rozpoznania wszystkich wektorów.

6. Podsumowanie

W obecnych czasach pojawia się problem związany nie tylko z rozpoznawaniem samego typu ZE, ale także z identyfikowaniem poszczególnych jego egzemplarzy. Niezbędna staje się umiejętność rozróżniania egzemplarzy tego samego typu radaru, dzięki której możliwe staje się dowiązywanie historii pracy obiektu do jego rzeczywistego reprezentanta, a nie do klasy, której jest przedstawicielem. Zalety takich „dodatkowych” informacji związanych z obserwowaniem rozróżnianych ZE pracujących w ramach jednego systemu (na ogół używany ten sam typ radaru) są oczywiste. Tak postawiony problem rozpoznawania jest określany mianem specyficznej identyfikacji źródeł emisji radarowych. Klasyczne metody identyfikacji, opierające się na cechach uzyskanych w procesach uśredniania, w tych przypadkach się nie sprawdzają.

Zaproponowana w artykule metoda identyfikacji, bazująca na przekształceniu ortogonalnym KL, stanowi kolejny krok w obszarze szczegółowych badań sygnałów radarowych dla celów SEI, czyli w wyznaczaniu cech, na podstawie których egzemplarze są rozdzielne, a co za tym idzie — bez problemu rozróżniane. Celem badań, których wyniki zaprezentowano w artykule, było oszacowanie możliwości identyfikacji egzemplarzy radarów na podstawie analizy zmian częstotliwości wewnątrz impulsu. Przeprowadzone badania jednoznacznie potwierdzają możliwość identyfikacji radarów w oparciu o te cechy.

Podczas analizy zgromadzonych rejestracji nie zauważono żadnego wpływu czynników przestrzennych (miejsca pomiarów) oraz czasu pomiaru sygnałów, które negatywnie wpływałyby na realizowany proces identyfikacji. Daje to szansę na wyeliminowanie, z procesu przetwarzania sygnałów radarowych, trudnych i nie zawsze efektywnych procedur filtracji zakłóceń w ciągach pomiarowych okresu powtarzania impulsów i częstotliwości nośnej.

Podczas badań zaobserwowano zjawiska umożliwiające wykorzystanie SEI w procesie sortowania (rozplatania) emisji radarowych. W procesie rozwoju tego kierunku badań, należy doprowadzić do automatyzacji całego procesu, szczególnie etapu przetwarzania wstępnego. Należy również rozszerzyć przestrzeń analizowanych informacji do tych, zawartych w postaci radiowej sygnału.

Artykuł wpłynął do redakcji 20.10.2005 r. Zweryfikowaną wersję po recenzji otrzymano w marcu 2006 r.

LITERATURA

- [1] R. OWCZAREK, *Analiza międzyimpulsowa w klasyfikatorze sygnałów radarowych*, materiały IV Konferencji Naukowo-Technicznej „Systemy rozpoznania i walki radioelektronicznej”, Rynia, 29.11-1.12.1999, str. 166-173.
- [2] R. OWCZAREK, *Specyficzna identyfikacja radarów na podstawie cech sygnałów mierzalnych w dziedzinie czasu*, rozprawa doktorska WAT, Warszawa 2004.
- [3] W. KWIATKOWSKI, *Klasyfikacja Karhunen-Loeve'a*, Biul. Instytutu Automatyki i Robotyki, nr 13, WAT, Warszawa 2000, str. 37-48.
- [4] R. O. DUDA, P. E. HART, D. G. STORK, *Pattern classification*, John Wiley & Sons, Inc, New York 2000.
- [5] A. K. JAIN, R. C. DUBES, *Algorithms for Clustering Data*, Prentice Hall, 1988.
- [6] K. FUKUNAGA, *Introduction to statistical pattern recognition*, II ed., Academic Press, New York 1990.
- [7] S. THEODORIDIS, K. KOUTROUMBAS, *Pattern recognition*, Academic Press, San Diego 1999.

A. KAWALEC, R. OWCZAREK, T. RAPACKI, S. WNUCZEK

Specific radar emitter identification based on principal component analysis

Abstract. One of the most difficult tasks in the radar signal processing is optimal features extraction and classification. The multifunction radar systems cannot be classified and precisely recognized in the real time. In most cases, the modern ESM/ELINT systems cannot recognize the different devices of the same type or class. New method of the radar identification with a high quality of recognizing is the Specific Emitter Identification (SEI). The main task is to find non-intentional modulations in the receiving signals. This paper provides an overview of the new methods of measurement emitter signal features parameters and their transformation. This paper presents some aspects of radar signal features processing using Karhunen-Loeve's expansion as a feature selection and classification transform.

Keywords: warfare electronic, radar signal feature classification, specific emitter identification, Karhunen-Loeve expansion

Universal Decimal Classification: 621.396.96