



BIULETYN WAT
VOL. LV, NR 1, 2006

Zastosowanie metod fuzji danych w zarządzaniu zasobami radaru wielofunkcyjnego

WOJCIECH KOMORNICZAK, ADAM KAWALEC,
JERZY PIETRASIŃSKI

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

Streszczenie. W referacie poruszono tematykę związaną z zarządzaniem zasobami radaru wielofunkcyjnego. Jako jeden z elementów tego procesu wyróżniono priorytetyzację (rangowanie) zadań realizowanych przez radar. Rangowanie jest wymuszone przez potencjalnie niedostateczne zasoby wymagane do realizacji wszystkich zadań radaru, stąd konieczność szeregowania obsługiwanych przezeń obiektów zgodnie z ich istotnością. W referacie scharakteryzowano dane źródłowe zasilające proces rangowania oraz przedstawiono algorytmy przetwarzania tych danych. Zaprezentowane algorytmy oparto na wybranych metodach fuzji danych. Przedstawiono przebieg i wyniki badań procesu rangowania oraz wyniki badań wpływu zastosowania rangowania na niektóre parametry zarządzania zasobami radaru wielofunkcyjnego.

Słowa kluczowe: radar wielofunkcyjny, fuzja danych, sieci neuronowe, systemy rozmyte

Symbole UKD: 621.396.96

1. Wprowadzenie

Jednym z istotniejszych aspektów kierowania pracą radaru wielofunkcyjnego (RW) jest zarządzanie jego zasobami. Trudność, na jaką można się tu natknąć, związana jest z faktem, iż radar ten, będąc fizycznie pojedynczym urządzeniem, musi realizować funkcje wykonywane do tej pory przez zespoły składające się z kilku dedykowanych sensorów. Rezultatem tego jest ograniczona ilość zasobów możliwych do skonsumowania przez RW (głównie czasowych i energetycznych), przy niezmienionej liczbie obiektów podlegających obsłudze.

W zależności od rodzaju, liczby i tempa wykonywanych przez radar zadań, zużywana jest określona ilość jego zasobów. Jest rzeczą oczywistą, iż zasoby te


są limitowane w zależności od charakterystyki radaru, a w szczególności jego bloków odpowiedzialnych za parametry czasowo-energetyczne. Wynikiem tego ograniczenia może być sytuacja, gdzie dostępne w RW zasoby okażą się niewystarczające do poprawnej obsługi obiektów znajdujących się w obszarze odpowiedzialności radaru. Taka sytuacja jest określana mianem pracy w przeciążeniu w sensie energetycznym lub czasowym. Tego typu problem może się pojawić w przypadku zbyt dużej liczby obiektów lub wtedy gdy ich właściwości spowodują potrzebę zastosowania częstszego odświeżania informacji.

Z oczywistych względów w militarnym zastosowaniu radaru należy się liczyć z możliwością wystąpienia takich sytuacji. Dlatego też w celu zabezpieczenia się przed ich negatywnymi skutkami stosuje się strategię przeszukiwania przestrzeni [1, 2] oraz dokonuje się szeregowania zadań radaru zgodnie z ich istotnością, uprzywilejowując zadania o wyższym priorytecie [3, 4, 5, 6, 7, 8, 11]. Proces szeregowania zadań zgodnie z ich priorytetem jest określany mianem rangowania. Rangowanie realizowane jest w oparciu o zbiór parametrów charakteryzujących obsługiwane obiekty, a następnie poprzez skojarzenie określonych grup zadań do wykonania na rzecz obiektów tworzona jest tzw. lista zadań.

Ze względu na zbiór analizowanych danych w ramach procesu rangowania, należy podkreślić po pierwsze różnorodność źródeł i charakteru danych, a po drugie skojarzone z nimi odmienne sposoby modelowania niedoskonałości. Występują tu co najmniej dwa typy niedoskonałości: dane niejednoznaczne (jak na przykład dane identyfikacyjne) oraz dane o charakterze probabilistycznym (wszelkie dane opisujące lokalizację i parametry dynamiki ruchu obiektu). Charakter danych wejściowych dla procesu rangowania sprawia, iż intuicyjnym wyborem wydają się być narzędzia fuzji danych. Z analizy dostępnej literatury oraz dotychczasowych doświadczeń wynika, że narzędzia, takie jak między innymi: sieci neuronowe, systemy logiki rozmytej, matematyczna teoria ewidencji Dempstera-Shafera po odpowiedniej ich adaptacji, mogą być z powodzeniem wykorzystywane do wspomaganie procesu rangowania w zarządzaniu zasobami radaru wielofunkcyjnego.

2. Charakterystyka procesu rangowania

W warunkach pracy radaru w tzw. przeciążeniu, czyli gdy wskaźnik wykorzystania zasobu czasu $L_{tot} \rightarrow 1$ bądź wskaźnik wykorzystania zasobu energii $W_E \rightarrow 1$, konieczne staje się wytypowanie tych zadań, które powinny być zrealizowane oraz wskazanie tych zadań, których niewykonanie będzie obciążone najniższym kosztem. W rozpatrywanym modelu systemu zarządzania zasobami radaru, odpowiedzialnym za to jest proces *rangowania (priorytetyzacji)* zadań. Niezależnie od zastosowanego algorytmu przetwarzania informacji w procesie priorytetyzacji, ogólna istota procesu rangowania przedstawia się następująco (rys. 2.1).



Rys. 2.1. Ogólna idea procesu rangowania

Obsługiwane przez radar obiekty $\{O_1, O_2, \dots, O_m\}$ opisane są zbiorem wektorów parametrów pomiarowych $\{x_1, x_2, \dots, x_m\}$. W oparciu o dane w postaci wektorów pomiarowych dokonuje się możliwie pełnego opisu dostępnych parametrów obiektów, tak aby w procesie rangowania można było wypracować zbiór wartości rang Y każdego z obiektów.

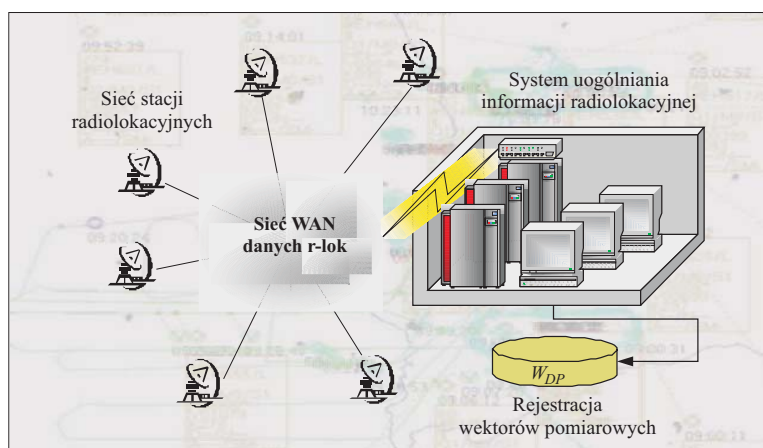
Proces priorytetyzacji związany jest z dwoma głównymi problemami. Pierwszym z nich jest dobór odpowiednich źródeł danych wejściowych, a drugim — opracowanie właściwych algorytmów przetwarzania tych danych. O ile pierwsze zagadnienie jest ściśle zależne od systemu bazowego — radaru i skojarzonych z nim sensorów, o tyle problematyka przetwarzania danych jest znacznie bardziej złożona.

3. Źródła danych

Wykorzystane w badaniach zarejestrowane dane pomiarowe spełniają szczególnie istotną, bo podwójną rolę. Głównym ich przeznaczeniem jest doświadczalna weryfikacja poprawności zaprojektowanych algorytmów rangowania. Niemniej ważną rolę jest wykorzystanie rzeczywistych danych pomiarowych wraz ze skojarzoną z nimi wiedzą ekspercką w procesie wykształcania bazy reguł oraz trenowania poszczególnych algorytmów rangowania.

Oryginalna koncepcja procesu badań stanowi próbę przeprowadzenia weryfikacji eksperymentalnej algorytmu zarządzania zasobami radaru (a w tym rangowania) bez rzeczywistego dostępu do radaru wielofunkcyjnego. Do pozyskania danych pomiarowych wykorzystano pracujący system uogólniania informacji radiolokacyjnej wraz z współpracującymi z nim radarami.

Dane pomiarowe uzyskano w wyniku rejestracji rzeczywistych tras statków powietrznych obserwowanych nad terytorium RP oraz tras symulowanych. W rezultacie, dla całej rejestracji (rys. 3.1) uzyskano ponad 120 tysięcy wektorów pomiarowych, przy czym wektorem pomiarowym jest zbiór parametrów obsługiwanego obiektu w punkcie wykonania pomiaru. Każdy z wektorów pomiarowych może stanowić parę uczącą dla procesu trenowania i/lub wykształcania baz wiedzy algorytmów oraz jako element weryfikujący poprawność pracy działającego sterownika.



Rys. 3.1. Schemat procesu rejestracji danych pomiarowych

Każdy z zarejestrowanych punktów pomiarowych stanowił fragment trasy obsługiwanego obiektu. Wiedza ekspercka związana z punktami pomiarowymi i trasami pochodzi z procedur operacyjnych, według których pracował system uogólniania oraz od oficerów identyfikacji, którzy dokonywali ręcznej identyfikacji obiektów.

Po wstępnej konwersji wektor pomiarowy przyjmuje postać:

$$W_{DP} = [DD_{pom}, TT_{pom}, ID_{ref}, NZ_{ob}, MOD_1, MOD_2, MOD_{3A}, MOD_{SM}, Callsign, \alpha_{ob}, R_{ob}, H_{ob}, V_{ob}, Q_{ob}, a_{max}, V_{max}, S_a, \Delta T_{pom}], \quad (1)$$

gdzie:

1. DD_{pom} — data realizacji pomiaru;
2. TT_{pom} — czas realizacji pomiaru;
3. ID_{ref} — cecha identyfikacji obiektu wypracowana przez system uogólniania informacji radiolokacyjnej, na podstawie informacji z wszystkich dostępnych źródeł danych;
4. NZ_{ob} — binarny wskaźnik, informujący o tym, że obiekt jest nośnikiem zakłóceń radioelektronicznych;
5. MOD_1 do MOD_{SM} — wartość kodu odpowiedzi systemu Q&A IFF w odpowiednim modzie, która w wyniku porównania z aktualnie obowiązującą wartością kodu zamieniana jest na binarny wskaźnik zgodności;
6. $Callsign$ — parametr identyfikujący konkretny przelot samolotu — wskazuje na skojarzenie z planem lotu;
7. α_{ob} — kierunek azymutalny wykrycia obiektu;

8. R_{ob} — odległość wykrycia obiektu;
9. H_{ob} — wysokość n.p.m. wykrycia obiektu;
10. V_{ob} — moduł wektora prędkości obiektu w ramach trasy;
11. Q_{ob} — kierunek kursowy trasy (wektora prędkości) odniesiony do kierunku północnego;
12. a_{max} — maksymalna zarejestrowana wartość modułu wektora przyspieszenia obiektu w ramach trasy (parametr wypracowany na podstawie serii pomiarów);
13. V_{max} — maksymalna zarejestrowana wartość modułu wektora prędkości obiektu w ramach trasy (parametr wypracowany na podstawie serii pomiarów);
14. ΔT_{pom} — czas od ostatniego pomiaru wartości charakteryzujących cechy kinematyczne obiektu.

Zarówno każdy wektor pomiarowy, jak i jego element, są cechowane identyfikatorem trasy oraz kolejnym numerem wektora w ramach trasy.

4. Algorytmy rangowania

Przedstawione w referacie algorytmy rangowania są oparte na zgromadzonej w nich wiedzy (ang. *knowledge based*). Podejście to opiera się na wykorzystaniu informacji a priori stanowiącej wiedzę ekspercką w dziedzinie priorytetyzacji obiektów. Wiedza ta została przetworzona w sformalizowany sposób, tak aby utworzyła zbiory uczące i weryfikujące dla procesu trenowania algorytmów rangowania. Same algorytmy rangowania powstały w oparciu o następujące narzędzia fuzji danych:

- sieci neuronowe,
- sterownik wykorzystujący logikę zbiorów rozmytych,
- sterownik neuronowo-rozmyty,
- sterownik probabilistyczno-rozmyty.

Wspomniane narzędzia posiadają zdolność uczenia się i uogólniania zdobytej wiedzy na obszary nieeksponowane podczas uczenia. Sieci neuronowe i logika zbiorów rozmytych są relatywnie dobrze reprezentowane w dostępnej literaturze, jednakże brak dokładniejszych opisów w zakresie możliwości ich wykorzystania w problemie rangowania zadań zachęcił autorów referatu do przebadania ich możliwości w rozpatrywanym aspekcie. Podejście neuronowo-rozmyte, jako łączące zalety obydwu poprzednich wydaje się szczególnie interesujące, natomiast podejście probabilistyczno-rozmyte, jako z jednej strony najsłabiej reprezentowane w literaturze, a z drugiej najlepiej dopasowane do problemu rangowania, wydaje się szczególnie godne uwagi.

4.1. Rangowanie z wykorzystaniem sieci neuronowych

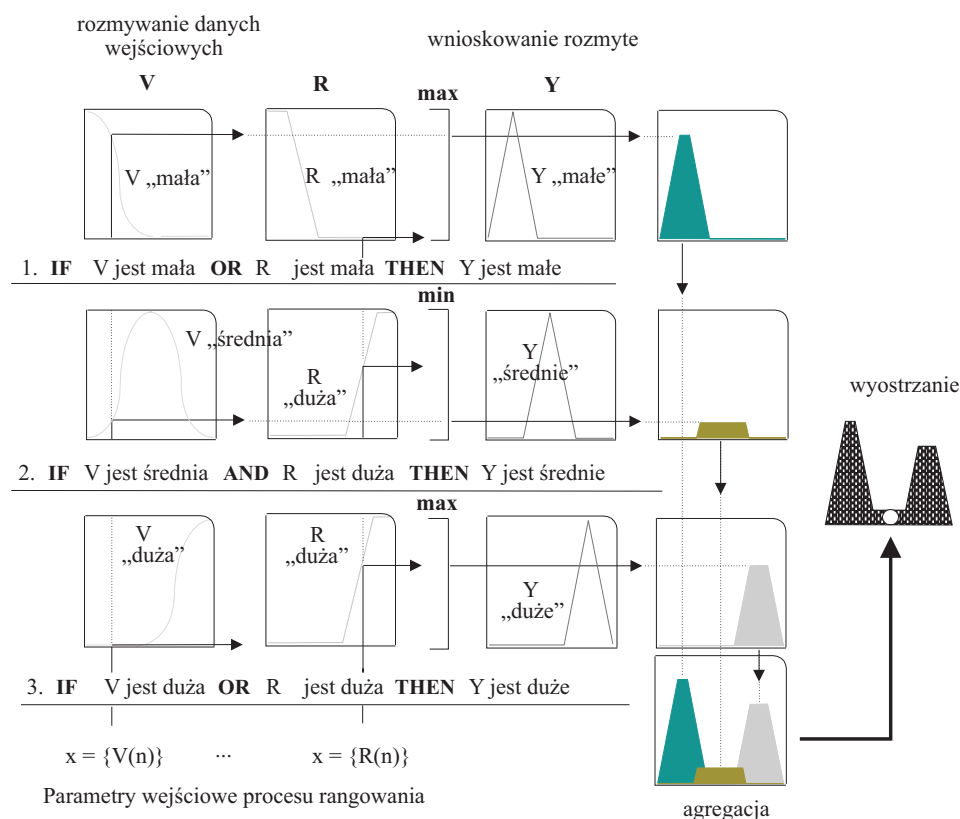
Sztuczne sieci neuronowe stanowią specyficzny rodzaj oprogramowania stanowiący nieliniowy model rozpatrywanego problemu [13, 3, 4]. Szczególnie cenną cechą sieci neuronowych jest ich zdolność do uczenia się, między innymi na podstawie ekspozycji przykładowych par uczących. Czyni to sieci neuronowe interesującym narzędziem, służącym do rozwiązywania nieliniowych, złożonych problemów, trudnych do formalnego opisu metodami klasycznymi.

W dalszych badaniach zdecydowano się wykorzystać jednokierunkową, wielowarstwową sieć neuronową (ang. *feed forward*). Wybór takiego typu sieci podyktowany jest charakterem problemu rangowania. Prezentacja wektorów danych wejściowych jest bowiem procesem statycznym, stąd nie ma konieczności analizy zależności czasowych. Jest to sieć neuronowa z połączeniami jednokierunkowymi, co oznacza, że sygnały wejściowe są niezależne od sygnałów pojawiających się na wyjściu. Sieci takie są czasem nazywane heteroasocjacyjnymi i można je rozpatrywać jako statyczne, gdyż ewentualne procesy przejściowe, zachodzące w sieci podczas jej pracy, nie mają znaczenia z punktu widzenia celu funkcjonowania sieci i mogą być pomijane. Zastosowana sieć neuronowa posiadała 3 warstwy, zmienną liczbę wejść i zmienne liczby neuronów w warstwach. Zastosowano 3 warianty funkcji aktywacji neuronów. Uczenie sieci odbywało się z wykorzystaniem algorytmu wstecznej propagacji błędu. Zastosowano dwa podejścia: trenowanie sieci przeprowadzono w oparciu o quasi-newtonowski algorytm optymalizacji (autorstwa: Broyden, Fletcher, Goldfarb i Shanno) oraz algorytm Levenberga-Marquardta.

4.2. Rangowanie z wykorzystaniem sterowników rozmytych

Wychodząc naprzeciw potrzebie przejrzystej prezentacji wiedzy eksperckiej wykorzystywanej w procesie rangowania, w referacie rozpatrzono zastosowanie teorii zbiorów rozmytych [15, 7, 9, 10]. Atrakcyjną cechą zbiorów rozmytych, z uwagi na możliwość wykorzystania w procesie rangowania, jest ich zdolność do formalnego definiowania pojęć nieprecyzyjnych i wieloznacznych. Na tak zdefiniowanych zbiorach pojęć można przeprowadzać operacje logiczne będące składnikami reguł opisujących istotę modelowanego zjawiska. Zupełnie intuicyjne wydaje się sformułowanie reguły decyzyjnej, np.: *JEŻELI obiekt porusza się szybko, TO jego priorytet jest wysoki*. Trudno jednak sobie wyobrazić zastosowanie tak niejasnych pojęć, jak: „szybko” czy „wysoki” w urządzeniu, od którego wymaga się niezawodności i wiarygodności dostarczanej informacji. Teoria zbiorów rozmytych dostarcza matematycznych narzędzi sformalizowanego opisu tak nieprecyzyjnych pojęć. Dzięki temu wiedza ekspercka może zostać wyrażona w postaci zbioru reguł oraz formalnego opisu przynależności przedmiotowych określeń do charakterystycznych dla nich zbiorów rozmytych.

Teoria działań na zbiorach rozmytych, podobnie jak sieci neuronowe, jest dobrze reprezentowana w literaturze. W badaniach wykorzystano sterownik rozmyty z doбором *ad hoc* parametrów funkcji przynależności. Chodzi tu o taką metodę określania funkcji przynależności, która nie wykorzystuje wiedzy o obserwowanych zjawiskach, a jedynie zbiory uczące (podobnie jak w przypadku sieci neuronowych). Strukturę sterownika przedstawiono na rysunku 4.1.



Rys. 4.1 Sterownik rozmyty z doбором *ad hoc* parametrów funkcji przynależności

Wnioskowanie rozmyte w proponowanym sterowniku przebiega w oparciu o zbiór logicznych reguł rozmytych. Przyjęto, że każda z reguł posiada dwa warunki w poprzedniku.

Proces uczenia sterownika rozmytego polega na realizacji następujących kroków:

- przygotowanie zbioru uczącego — podział przestrzeni rozważań wartości wyjściowych (cechy identyfikacji mapowane na rangi),

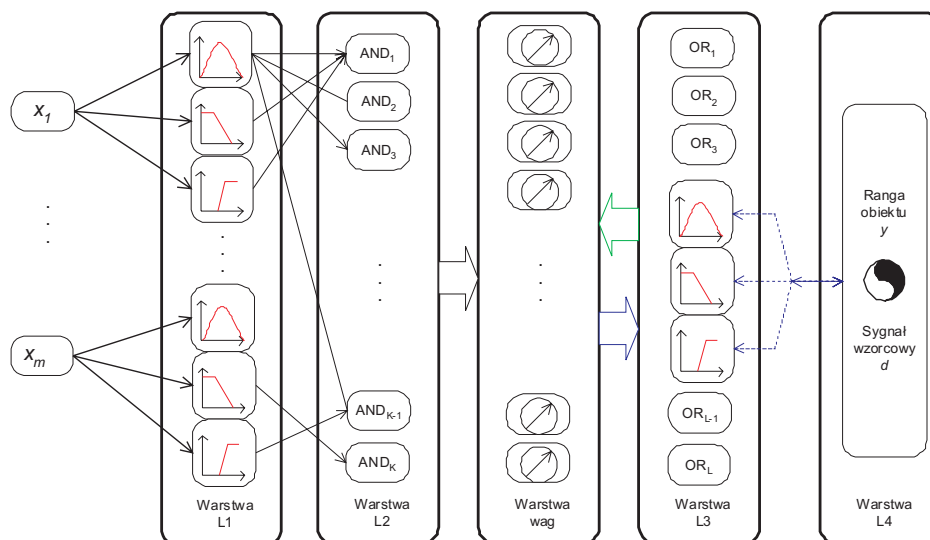
- podział przestrzeni rozważań wybranych parametrów zbioru uczącego identycznie jak w trenowanym sterowniku rozmytym,
- przygotowanie tablicy reguł rozmytych — tablica składająca się z wszystkich możliwych kombinacji reguł (z operatorami iloczynu rozmytego) powiększonej o tzw. przesłanki puste,
- prezentacja par uczących i zliczanie przesłanek do odpalenia reguły każdej z reguł rozmytych,
- określenie progu klasyfikacji reguły i wybór tych reguł, których liczba potencjalnych odpaleń przekroczyła próg,
- łączenie reguł rozmytych, które przekroczyły próg decyzyjny z wykorzystaniem wybranego operatora sumy rozmytej.

Przez odpalenie reguły rozumie się osiągnięcie takich wartości rozmytych warunków poprzednika, że po uwzględnieniu zastosowanego operatora logicznego dojdzie do spełnienia przesłanek zajścia następnika. Przesłanka pusta oznacza możliwość wystąpienia tylko jednego warunku w poprzedniku.

Zaletą zaproponowanej metody jest jej niewątpliwa zdolność do aplikacji, bez względu na kształt funkcji opisującej rozpatrywane zjawisko — nie jest tu wymagane spełnienie warunku różniczkowalności funkcji, jak ma to miejsce w przypadku trenowania przedstawionej wcześniej sieci neuronowej. Z drugiej zaś strony należy się spodziewać degradacji jakości przetwarzania spowodowanej niedopasowaniem parametrów funkcji przynależności rozmywanych parametrów do ich specyficznego charakteru.

4.3. Rangowanie z wykorzystaniem sterowników neuronowo-rozmytych

Dotychczas opisane narzędzia fuzji danych posiadają zarówno wiele interesujących i zachęcających do dalszych badań cech, jak i wady zmuszające do rezygnacji z danej metody w określonych aplikacjach. Sieci neuronowe ze swoją zdolnością uczenia się i uwolnieniem projektanta od wymogu znajomości formalnego modelu zjawiska są niedopuszczalne w wymagających dużej wiarygodności zastosowaniach. Jest to spowodowane rozproszeniem wiedzy pomiędzy wagami połączeń neuronowych. Z drugiej strony systemy bazujące na logice rozmytej oferują dużą przejrzystość w zakresie prezentacji wiedzy, możliwość intuicyjnego, jakościowego opisu przedmiotu rozważań, ale wciąż wymagają od konstruktora pewnej wiedzy o modelu zjawiska już na etapie projektowania. Rozwiązaniem łączącym zalety powyższych metod jest hybrydowy sterownik rozmyto-neuronowy, zwany również neuronowym sterownikiem rozmytym. Rozwiązania tej klasy, jakkolwiek wzmiankowane w literaturze, rzadko wychodzą poza ogólnikowe, teoretyczne sformułowania.



Rys. 4.2. Struktura hybrydowego sterownika neuronowo-rozmytego

Przedstawiony sterownik (rys. 4.2) jest rozwinięciem koncepcji opisanej w [12, 14] i stanowi kontynuację prac przedstawionych w [8]. Sterowniki zaprezentowane we wspomnianych pracach posiadały bazy reguł wykształcone z wykorzystaniem sztucznie wygenerowanych zbiorów uczących. To samo dotyczy zbiorów weryfikujących jakość działania algorytmu. W niniejszej rozprawie, dzięki możliwości osadzenia sterownika w procesie zarządzania zasobami radaru oraz wykorzystaniu dostępu do bogatego i reprezentatywnego zbioru danych uczących, uzyskanych z pomiarów rzeczywistej sytuacji radiolokacyjnej, zaistniała możliwość optymalizacji istniejącego algorytmu w aspekcie doboru jego kluczowych parametrów. Dodatkowo, zweryfikowany z wykorzystaniem zbioru bazującego na pomiarach rzeczywistych, przedstawiony sterownik nabiera istotnego charakteru aplikacyjnego.

Przedstawiony neuronowy sterownik rozmyty charakteryzuje się pięcioma warstwami, z których każda spełnia istotne funkcje, różne podczas modelowania — uczenia i podczas zasadniczego trybu pracy. Ponadto, proces uczenia przebiega dwuetapowo: w pierwszym podejściu realizowane jest uczenie samoorganizujące, mające na celu (dla wstępnie ustalonych funkcji przynależności) wykształcenie bazy reguł rozmytych, prowadzące do uczenia nadzorowanego, którego celem jest szczegółowe zdefiniowanie funkcji przynależności.

4.4. Rangowanie probabilistyczno-rozmyte

Dotychczas przedstawione algorytmy wykorzystane w procesie rangowania charakteryzują się jednolitym sposobem przetwarzania danych w poszczególnych kanałach (wejściach), niezależnie od charakteru specyficznych dla nich niedoskonałości. Tymczasem specyfika informacji przetwarzanej w procesie rangowania obiektów wskazuje na co najmniej dwa typy niedoskonałości, które należałoby zamodelować. Otóż dane pomiarowe dostarczane do procesu rangowania charakteryzują się niedoskonałością typu probabilistycznego i jako takie modeluje się je z wykorzystaniem np. funkcji gęstości rozkładu prawdopodobieństwa. Z drugiej strony, każdy z dotychczas przedstawionych algorytmów wykorzystywał ekspercką wiedzę a priori, dla której najwłaściwszym sposobem modelowania niedoskonałości jest opis wykorzystujący logikę zbiorów rozmytych. Dla tak określonych danych wejściowych powstaje problem opracowania metody ich fuzji.

Definiując problem rangowania obiektów jako zadanie klasyfikacji, można posłużyć się m.in. metodą bayesowską wykorzystującą funkcje wiarygodności oraz gęstości rozkładu prawdopodobieństwa. Zakłada się, iż zbiór wszystkich możliwych zdarzeń rozpatrywanego obszaru jest znany oraz że zdarzenia są niezależne. Niech przestrzeń obserwacji X zawiera n klas C_i z określonym prawdopodobieństwem wystąpienia danej klasy π_i , gdzie $i \in \{1, \dots, n\}$. Dodatkowo, zakłada się możliwość estymacji prawdopodobieństwa warunkowego $P(x|C_i)$. W takiej sytuacji, korzystając z kryterium największego prawdopodobieństwa a posteriori, można wskazać klasę, do której należy zmienna x :

$$C = \arg \max_{C_i} (\pi_i P(x|C_i)). \quad (2)$$

Z przedstawionego kryterium wynika możliwość przynależności danego elementu x wyłącznie do jednej klasy w przestrzeni obserwacji. Oznacza to ostry podział przestrzeni obserwacji pomiędzy klasy C_i i brak możliwości uwzględnienia niedoskonałości danych (np. niejednoznaczności). Ze względu na potrzebę modelowania tego typu danych, poszukuje się metod rozszerzenia przedstawionego kryterium na tzw. podział rozmyty przestrzeni obserwacji na klasy. Podejście to zwane również klasyfikacją rozmytą, zakłada podział przestrzeni obserwacji X zawierającej n klas C_i , z których każda posiada skojarzoną wartość przynależności μ_i , gdzie $i \in \{1, \dots, n\}$. Dla każdego zdarzenia x definiuje się wartość jego przynależności do każdej z klas. Stąd właściwa dla zdarzenia x klasa wskazywana jest zależnością:

$$C = \arg \max_{C_i} (\mu_i(x)). \quad (3)$$

Główne różnice pomiędzy podejściem bayesowskim i rozmytym to fakt, iż dla tego pierwszego konieczne jest obliczenie prawdopodobieństwa wystąpienia

zdarzenia x w danej klasie, natomiast w podejściu rozmytym x jest rezultatem obserwacji, a wartość jego przynależności do danej klasy stanowi posiadaną wiedzę a priori. Podejście rozmyte, jakkolwiek bliższe problematyce procesu rangowania, powinno być wzbogacone o możliwość obsługi danych typu probabilistycznego. W rezultacie możliwe byłoby wnioskowanie w oparciu o stwierdzenia, np. typu: *JEŻELI odległość JEST duża, TO ...*, gdzie zmienna odległość jako wielkość uzyskana z pomiaru jest opisana funkcją gęstości prawdopodobieństwa, natomiast klasa *duża* jest dana w postaci miary przynależności.


Jako punkt wyjścia do rozważań można przyjąć koncepcję prawdopodobieństwa zdarzeń rozmytych (ang. *probability of fuzzy events*) [10] oraz podziału rozmytego (ang. *fuzzy partition*) (rys. 4.3). Jeżeli A jest zbiorem rozmytym w przestrzeni R^n , którego funkcja przynależności wyraża się zależnością:

$$\mu_A (\mu_A : R^n \rightarrow [0, 1]), \tag{4}$$

to prawdopodobieństwo zdarzenia rozmytego A jest definiowane całką Lebesgue-Stieltjesa:

$$P(A) = \int_{R^n} \mu_A(x) dP = E(\mu_A), \tag{5}$$

gdzie x jest punktem w R^n . Z powyższej zależności wynika, iż prawdopodobieństwo zdarzenia rozmytego jest wyrażane wartością oczekiwaną miary przynależności x do zbioru A .




Rys. 4.3. Probabilistyczny i rozmyty podział obszaru rozważań

Dokonując odpowiednich przekształceń oraz generalizacji dla zbioru M klas $\{C_1, C_2, \dots, C_M\}$, otrzymuje się kryterium wyboru klasy zgodnie z zależnością:

$$C \rightarrow C_m : \max_{C_m} \arg\{ [2\mu_{C_m}(x_2) - 1] \cdot f_{x_1/C_m}(x_1) \cdot \pi_m \} \quad m = 1, 2, \dots, M. \tag{6}$$

Zaprezentowana metoda klasyfikacji danych rozmytych i probabilistycznych została wykorzystana oraz zweryfikowana eksperymentalnie w sterowniku roz-

mytym (rys. 4.4). Sterownik posiada dwa wejścia. Pierwsze z nich przetwarza informację o typie odpowiedzi systemu IFF pracującego w modzie 3A (nośnik bogatej informacji o przynależności sojuszniczej oraz typie w sensie cywilny–wojskowy). Wejście wykorzystuje wiedzę a priori w postaci zbioru funkcji gęstości prawdopodobieństwa $f_{\text{mod}3\text{typ}/C_m}(\text{mod}3\text{typ}_{\text{wart}})$. Parametry funkcji gęstości prawdopodobieństwa zostały wykształcone z wykorzystaniem algorytmu analizującego zbiór danych uczących.



Rys. 4.4. Aplikacja sterownika probabilistyczno-rozmytego


Drugie wejście sterownika przetwarza dane w postaci parametru *Callsign* będącego nośnikiem informacji o skojarzeniu z planem lotu, co z kolei sugeruje sojuszniczą przynależność obiektu. Przyjęto, iż ze względu na ekspercki charakter takiej informacji (brak jednoznacznych reguł tworzących relację *Callsign* — cecha ID), wygodnie jest ją opisać w postaci funkcji przynależności. Stąd opisywane wejście sterownika ma charakter rozmyty i wymaga zdefiniowania funkcji przynależności $\mu_{C_m}(Callsign)$. Parametry funkcji $\mu_{C_m}(Callsign)$ wyznaczono w oparciu o analizę zbioru danych uczących.

5. Przebieg i wyniki badań


Badania podzielono na dwa etapy: w pierwszym wykształcono bazy wiedzy sterowników i oceniono jakość ich wytrenowania, natomiast w drugim etapie oceniono działanie algorytmów rangowania jako elementu procesu zarządzania zasobami radaru. Obydwa etapy wykorzystywały zbiór zarejestrowanych danych pomiarowych, podzielony losowo tak, że jedna część służyła trenowaniu sterowników, a druga weryfikacji jakości ich działania.

Proces wykształcania baz wiedzy sterowników przebiegał w oparciu o układ, którego ogólną strukturę przedstawia rysunek 5.1.

Zakres danych uczących podzielono na dwa obszary: kinematyczny i identyfikacyjny. Graficzną reprezentację fragmentu danych kinematycznych przedstawia rysunek 5.2.



Rys. 5.1. Schemat dostarczania danych do procesu uczenia sterownika



Rys. 5.2. Powierzchnia wzorcowa rangi obiektu do procesu wykształcania sterownika kinematyczno-położeniowego

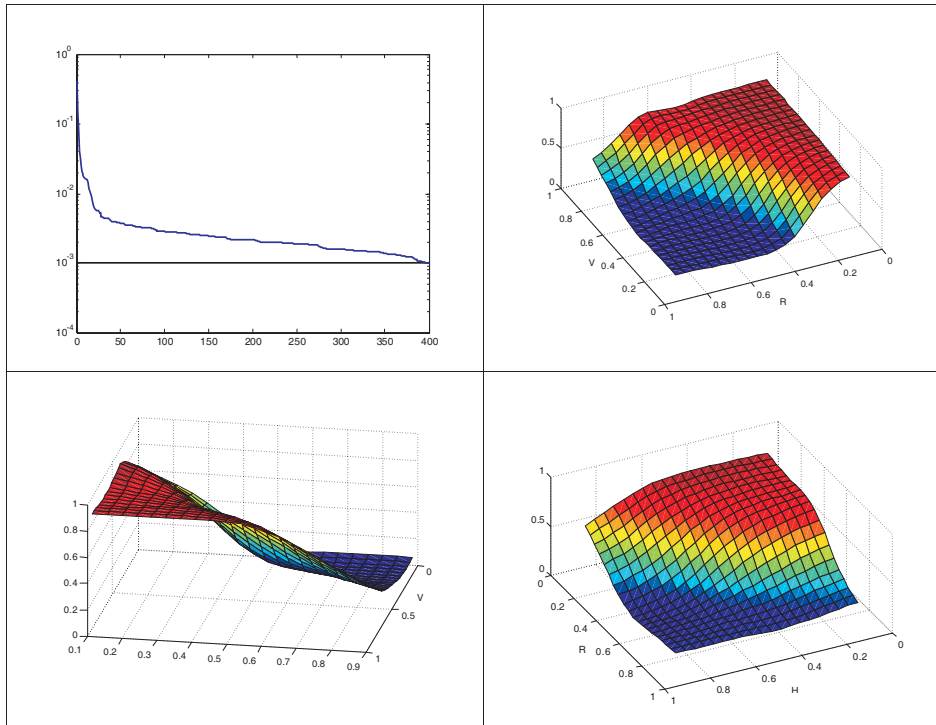
Przykładowy przebieg i rezultaty trenowania neuronowego układu rangującego przedstawiono na rysunku 5.3.

Proces weryfikacji wyuczonych sterowników realizowany był w układzie przedstawionym na rysunku 5.4.

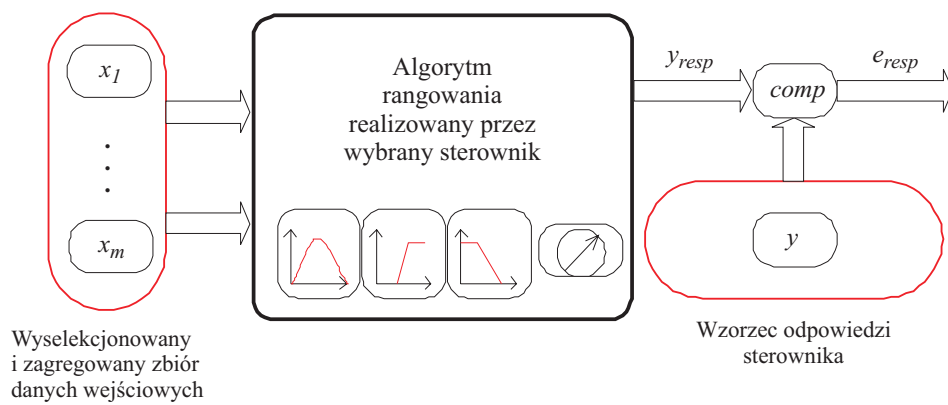
Z analizy otrzymanych wyników można wyciągnąć wniosek o zbieżności z wartościami błędu średniokwadratowego uzyskanego na etapie wykształcania sterowników. Jak już wcześniej wspomniano, wartość błędu dla sterowników odpowiedzialnych za klasyfikację cechy identyfikacji obiektu nie jest krytyczna. Z kolei sterowniki kinematyczno-położeniowe cechują się bardzo wiernym odwzorowaniem zbioru uczącego (niski błąd na etapie uczenia) oraz dobrą generalizacją wiedzy (niski błąd na etapie testowania).

Badanie procesu zarządzania zasobami radaru zrealizowano w układzie pomiarowym przedstawionym na rysunku 5.5. Zdefiniowany uprzednio podzbiór danych pomiarowych (tak jak dla procesu uczenia sterowników rangujących) stanowi wejście procesu rangowania obsługiwanych przez radar obiektów.

Proces rangowania rekomenduje zadania do usunięcia bądź przesunięcia w ramach listy zadań, co przy osiągnięciu przez L_{tot} wartości l zaczyna być realizowane. W rezultacie, przy wykorzystaniu zaproponowanego algorytmu zarządza-



Rys. 5.3. Rezultaty trenowania sterownika neuronowego rozwiązującego problem określania rangi na podstawie zbioru cech kinematycznych (algorytm BFGS)

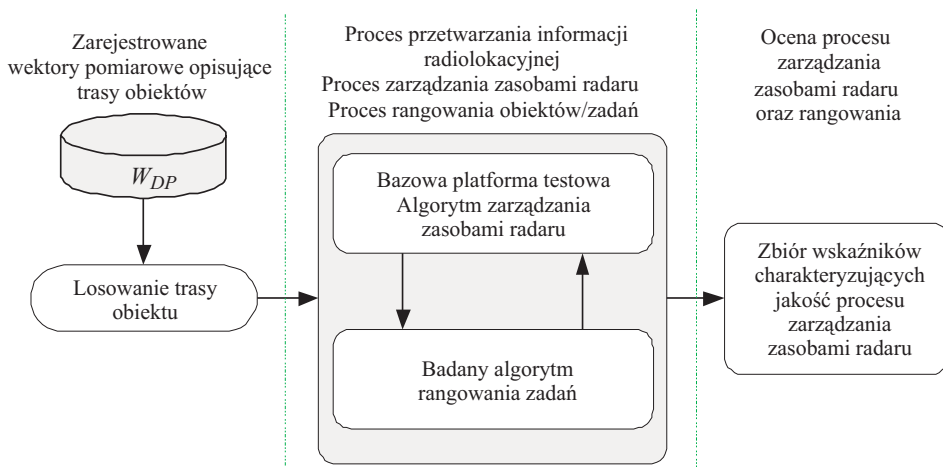


Rys. 5.4. Schemat procesu badania algorytmów rangowania w kontekście oceny stopnia ich wytrenowania

TABELA 5.1

Wyniki testowania wytrenowanych sterowników

Typ sterownika	Funkcja	Błąd etapu uczenia	Błąd etapu testowania
Sieć neuronowa LM	RHV	0,000350	0,000413
Sieć neuronowa BFGS	RHV	0,000999	0,001055
Sieć neuronowa BFGS	cecha ID	0,077500	0,090124
Rozmyty <i>ad hoc</i>	RHV	0,007512	0,007934
Rozmyty <i>ad hoc</i>	cecha ID	0,634300	0,627800
Neuronowo-rozmyty	RHV	0,001041	0,001165
Probabilistyczno-rozmyty	cecha ID	0,096533	0,091453

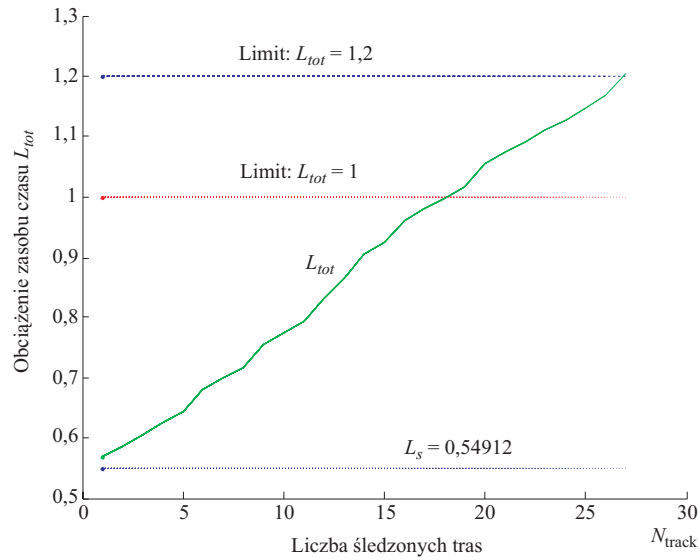


Rys. 5.5. Schemat układu pomiarowego dla badań procesu zarządzania zasobami radaru

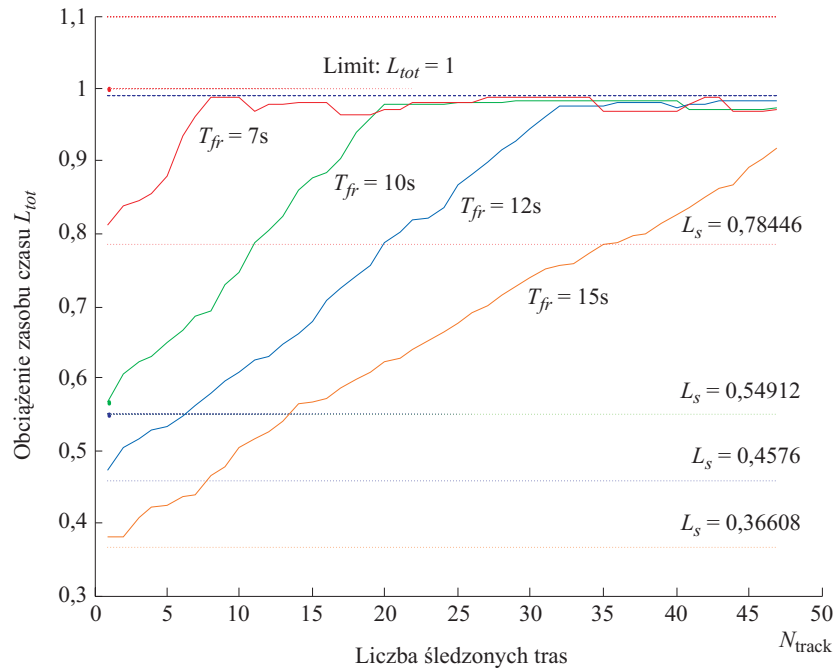
nia zasobami radaru L_{tot} nigdy tej wartości nie przekroczy. Dla zobrazowania sytuacji obsługi tras z wyłączonym procesem zarządzania zasobami radaru wykonano eksperyment, w którym graniczna wartość L_{tot} wstrzymująca obsługę tras wyniosła 1,2. Jak widać z rysunku 5.6, symulowany proces pracy radaru przechodziłby w tryb przeciążenia ($L_{tot} > 1$) przy obsłudze 18 tras.

W momencie uruchomienia procesu zarządzania zasobami nie dojdzie do przeciążenia radaru, za co odpowiedzialny jest zastosowany algorytm rangowania oraz usuwania i przeszerogowywania zadań, natomiast $L_{tot} \rightarrow 1$ (rys. 5.7).

Ostateczną weryfikacją zaproponowanych algorytmów rangowania zadań jest badanie polegające na obliczeniu sumy kosztów usunięcia zadania z listy C_{del} oraz przesunięcia zadania w ramach listy C_{mov} w funkcji obciążenia radaru. Jako punkt odniesienia, pierwsze sprawdzenie przeprowadzono z wyłączonym procesem rangowania. W tym przypadku każdy kolejny wykryty obiekt jest obsługiwany pod warunkiem zwolnienia zasobów (np. zakończenia obsługi innego obiektu).




Rys. 5.6. Czasowe obciążenie radaru w funkcji liczby obsługiwanych obiektów (bez zarządzania zasobami radaru)




Rys. 5.7. Czasowe obciążenie radaru w funkcji liczby wprowadzonych do procesu obiektów dla różnych wartości czasu ramki

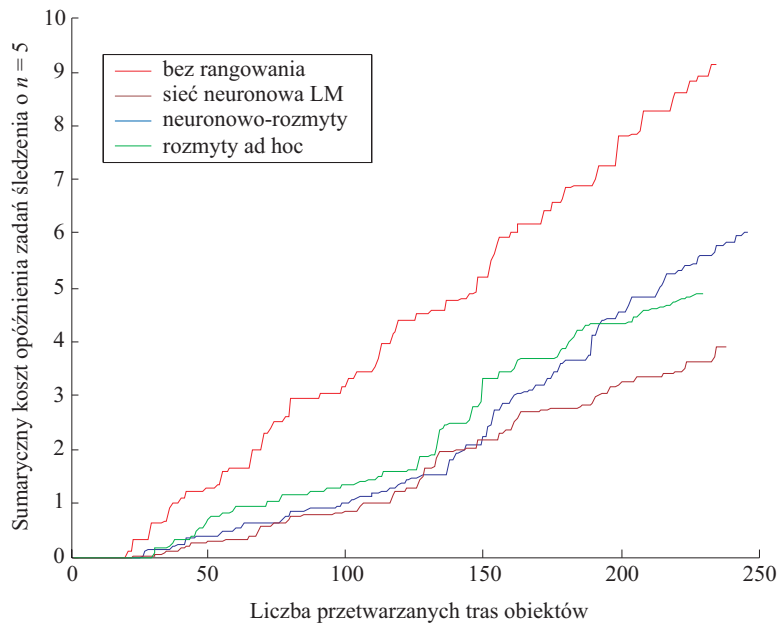
tu). Nieobsłużenie obiektu było traktowane jako jego usunięcie z kolejki (zwiększenie wartości sumarycznego kosztu usunięcia zadań z listy). Natomiast opóźnienie jego obsługi w granicach dopuszczalnych przez proces śledzenia było traktowane jako przeszerogowanie zadania w czasie (zwiększenie wartości sumarycznego kosztu opóźnienia realizacji zadania w ramach listy). Rezultaty porównania poszczególnych algorytmów dla sumarycznego kosztu usunięcia zadania z listy przedstawiono na rysunku 5.8, natomiast wyniki dla sumarycznego kosztu opóźnienia realizacji zadania przedstawiono na rysunkach 5.9 i 5.10. Badania przeprowadzono w ten sposób, że najpierw wybrano dający najlepsze wyniki sterownik wskazujący *cechę ID* (przekładający się na wyniki w zakresie C_{del}), a następnie dla wybranych sterowników rangujących (na podstawie cechy RVH) dokonano oceny wskaźnika C_{mov} .



Rys. 5.8. Sumaryczny koszt usunięcia zadań z listy $C_{del\ sum}$ dla poszczególnych algorytmów



Rys. 5.9. Sumaryczny koszt opóźnienia realizacji zadań $C_{mov\ sum}$ w ramach listy dla poszczególnych algorytmów rangowania przy opóźnieniu zadania o $n = 1$ kroków



Rys. 5.10. Sumaryczny koszt opóźnienia realizacji zadań $C_{mov\ sum}$ w ramach listy dla poszczególnych algorytmów rangowania przy opóźnieniu zadania o $n = 5$ kroków

6. Wnioski

Przedstawione wyniki badań potwierdzają założenia teoretyczne. Wzrost liczby obsługiwanych przez radar obiektów, przy niezmiennych charakterystykach urządzenia powoduje przyrost obciążenia zasobu czasu (rys. 5.6). Zastosowanie algorytmu zarządzania zasobami radaru pozwala na utrzymanie obciążenia czasowego L_{tot} na poziomie nieprzekraczającym możliwości urządzenia (rys. 5.7) przy równoczesnej kontroli w zakresie jakości realizowanych zadań. Za zapewnienie na odpowiednim poziomie wartości wskaźników jakościowych w warunkach będących przesłankami do pracy w przeciążeniu odpowiada algorytm rangowania. Oceny zarówno jakości pracy poszczególnych algorytmów rangowania, jak i pracy radaru bez rangowania dokonano z wykorzystaniem wskaźników kosztu usunięcia zadania z listy obsługiwanych zadań oraz kosztu przeszeregowania zadania w czasie. Jak widać (rys. 5.8), zastosowanie rangowania istotnie (około dwukrotnie) obniża wskaźnik kosztu usunięcia zadania z listy. Podobnie przedstawia się sytuacja dla przeszeregowania zadania w czasie. Widać tu wyraźnie (rys. 5.9 i 5.10), że późniejsze wykonanie zadania implikuje wzrost kosztu takiej operacji (porównanie 1 i 5 jednostek czasu). Przez jednostkę czasu rozumie się ustalony, minimalny okres czasu pomiędzy kolejnymi odświeżeniami informacji o trasie. Kolejny wniosek płynący z obserwacji uzyskanych wyników to fakt, iż poszczególne sterowniki rangujące zapewniają porównywalne rezultaty w zakresie zysku z procesu rangowania. Wynika z tego, iż dokładność odwzorowania zbioru uczącego nie jest krytyczna. O wiele istotniejsza jest tu zbieżność i stabilność algorytmu. Projekt i badania różnych typów sterowników znajdują tu swoje uzasadnienie. Otóż przebadane sterowniki rangujące charakteryzowały się różną jakością odwzorowania wyuczonej wiedzy. Jednakże różnice w jakości wskaźników oceniających zarządzanie zasobami RW nie były proporcjonalne do zależności charakterystyk pomiędzy poszczególnymi sterownikami. Największy zysk pochodził od zastosowania rangowania w ogóle i uwzględnienia w nim możliwie pełnego opisu cech obsługiwanego obiektu (rozłączne zbiory cech dla kosztu usunięcia i kosztu przeszeregowania zadania). Nasuwa się więc wniosek, że uprzywilejowane powinny być te algorytmy, które dobrze radzą sobie w warunkach niespójnych danych uczących (tu: probabilistyczno-rozmyte), ponad algorytmami gwarantującymi lepsze odwzorowanie wiedzy, ale kosztem gorszej zbieżności (tu: neuronowo-rozmyte).

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

LITERATURA

- [1] S. SABATINI, M. TARANTINO, *Multifunction Array Radar — System Design and Analysis*, Artech House, 1994.
- [2] D. BILLETER, *Multifunction Array Radar*, Artech House, 1989.

- [3] W. KOMORNICZAK, J. PIETRASIŃSKI, T. KUCZERSKI, *The Priority Assignment for Detected Targets in Multi-function Radar*, 13th International Conference on Microwave and Radar MIKON'2000, May 20-22, 2000, Wrocław, Poland, 244-248.
- [4] W. KOMORNICZAK, J. PIETRASIŃSKI, *The Selected Problems of Radar Resources Management*, IEEE International Conference on Information Fusion FUSION 2000, 10-13.07.2000 Paris, France, WeC1-9.
- [5] W. KOMORNICZAK, J. PIETRASIŃSKI, B. SOLAIMAN, *Data Fusion Approach to the Threat Assessment for the Radar Resources Management*, SPIE Sensor Fusion 2002, Orlando, USA, 196-203.
- [6] W. KOMORNICZAK, J. PIETRASIŃSKI, B. SOLAIMAN, *The Data Fusion Approach to the Priority Assignment in the Multi-function Radar*, 14th International Conference on Microwave and Radar MIKON'2000, May 20-22, 2002, Gdańsk, Poland, vol. 2, 647-650.
- [7] L. LECORNU, R. DEBON, W. KOMORNICZAK, B. SOLAIMAN, *Probabilistic and Fuzzy Information Fusion Applied to Radar System Ranking*, SPIE Sensor Fusion 2003, Orlando, USA, 123-132.
- [8] L. PAJĄK, W. KOMORNICZAK, L. LECORNU, *Fuzzy Logic Controller with Rule Base Learning In Multifunctional Radar Resources Management*, International Radar Symposium IRS 2004, 19-21.05.2004, Warszawa, Poland.
- [9] R. YAGER, D. FILEV, *Essentials of Fuzzy Modeling and Control*, John Wiley & Sons, 1994.
- [10] L. ZADEH, *Probability Measures of Fuzzy Events*, Journal of Mathematical Analysis and Applications 23, 1968, 421-427.
- [11] E. HANLE, *Multi-function Operation and Signal Processing with Electronically Steered Radar System*, International Conference on Radar, 4-8.12.1978, Paris, France, 546-550.
- [12] D. RUTKOWSKA, M. PILIŃSKI, L. RUTKOWSKI, *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, PWN 1997.
- [13] S. OSOWSKI, *Sieci neuronowe w ujęciu algorytmicznym*, WNT, Warszawa, 1996.
- [14] Ł. PAJĄK, *Hybrydowy neuronowo-rozmyty układ rangowania zadań w zarządzaniu zasobami radaru*, praca magisterska, WAT, 2004.
- [15] D. DUBOIS, H. PRADE, *Fundamentals of Fuzzy Sets*, Kluwer Academic Publishers, 2000.

W. KOMORNICZAK, A. KAWALEC, J. PIETRASIŃSKI

The Application of the Data Fusion Methods in the Multifunction Radar Resources Management

Abstract. The paper deals with the problem of the multifunction radar resources management (RRM). The objectives of RRM are: optimal (from the radar performance point of view) resources allocation and the device operation control. As a result of RRM, it is expected a matrix containing information for the execution systems: what, when, and how to do.

The main constraints to deal with in the radar work are: time and energy limitations. If it is enough resource to execute all the tasks, the tasks execution is feasible. But in real situation one should not expect such a comfort. Typically neither time nor energy is enough and the questions arises what to do in these circumstances. It is obvious that only selected tasks can be executed, the RRM should answer which of them and in what order. To answer these questions, the structure of the RRM was proposed. First of all it is necessary to rank the tasks in order of their priorities, then to select the most important of them and schedule their execution.

RRM is decomposed into two sub-problems, e.g.: ranking and task scheduling. The ranking belongs to the identification problems class, while the scheduling can be treated as an optimization task. The paper presents the data fusion approach to the task ranking. There are numerous examples of utilization of the data fusion tools in order to solve the identification problems. The conclusions from these examples can be following: the neural networks which have the ability to learn from the presented examples have also disadvantage of impossibility of extraction of the gathered knowledge. The internal processes of reasoning are neither well described nor studied, so they are not a good tool for military application, which the multifunction radar is. Fuzzy logic systems (based on the fuzzy sets theory and fuzzy logic) have the advantage of good and clear knowledge representation and ability to relatively easy implementation of the expert knowledge. The good side of the fuzzy systems is their possibility of maintaining and fusion of the imperfect knowledge. The disadvantage is the lack of ability to learn whole the knowledge from the examples. Some hybrid solutions are necessary. Four solutions are presented in the paper: neural, fuzzy, fuzzy — neural and probabilistic — fuzzy. In order to implement data fusion tools, the base test platform was designed and implemented. In fact, the test platform is a complex process of multifunction radar resources management, as well as it deals with the task scheduling problem.

In order to evaluate the algorithms presented in the paper, some factors of radar work performance were defined. Presented ranking algorithms have capability of learning with use of the registered data learning set. Algorithms with their knowledge bases were tested and compared. The conclusion is following: the use of ranking process gives approximately two times better performance in task removal/delay aspect. On the other hand, the quality of algorithm (its accuracy) has lower influence on the final result. It means that for the use in radar application the algorithm with the best convergence during learning process and stability should be recommended. It is also important that the algorithm should have clear knowledge representation. These requirements meet two of the presented algorithms: neural — fuzzy and probabilistic — fuzzy. The first one was used against the positional data, the second one gave the best results for identification data.

It is important, that overall performance of the presented RRM and ranking algorithms was tested with the use of real registered data, what makes it very interesting from the application point of view.

Keywords: multifunction radar, data fusion, neural networks, fuzzy logic

Universal Decimal Classification: 621.396.96