

Tadeusz Niedziela¹
Wydział Transportu Politechniki Warszawskiej

Metody syntezy informacji obrazowej z wielu źródeł

WPROWADZENIE

Wiele ośrodków badawczych próbuje rozwiązać problem automatycznego rozpoznania obiektów poprzez łączenie ich cech charakterystycznych uzyskiwanych z różnych źródeł. Istnieje podstawowy problem, jaki zestaw czujników należy wybrać dla budowanego systemu wieloczujnikowego i jaki zestaw cech obiektu dany czujnik ma ekstrahować. Kolejny problem, to z jakich czujników, jakie cechy i w jakiej kolejności należy łączyć, aby uzyskać określony poziom rozpoznania.

Zakończono dotychczas szereg programów badawczych nad zdefiniowaniem zestawu cech charakterystycznych obiektów dla różnych rodzajów czujników, które wykorzystano tam, gdzie liczba klasyfikowanych obiektów była niewielka i gdzie dopuszczalne było znaczne prawdopodobieństwo błędów przy ich identyfikacji.

Technika łączenia informacji z wielu czujników obrazu (źródeł informacji) jest obecnie kluczowym problemem w nowoczesnych urządzeniach automatycznie podejmujących ważne decyzje [1-7]. Istotną cechą tego typu urządzeń jest automatyczne potwierdzenie obiektu przez procesor syntezy bez potrzeby precyzyjnego określania, które czujniki i które ich poziomy ufności powinny być zaangażowane.

W ostatnich latach coraz bardziej docenia się syntezę informacji, szczególnie syntezę informacji obrazowej. Synteza informacji w dziedzinie obrazowej rozumiana jest jako łączenie informacji z różnych źródeł w celu uzyskania globalnej wiedzy o rozpoznawanym obiekcie. Dąży się do pozyskania nie tylko maksymalnej wiedzy o położeniu i geometrii obiektu ale o nadaniu mu stosownego znaczenia.

Syntezę informacji w dziedzinie obrazowej można rozpatrywać jako:

- syntezę na poziomie pikseli oraz syntezę na poziomie obiektów,
- syntezę w zależności od realizacji przetwarzania danych na poziomie: czujnika, centralnym lub mieszanym,
- syntezę w zależności od sposobu agregacji danych: globalną (od czujnika do czujnika) oraz lokalną (od sceny do sceny).

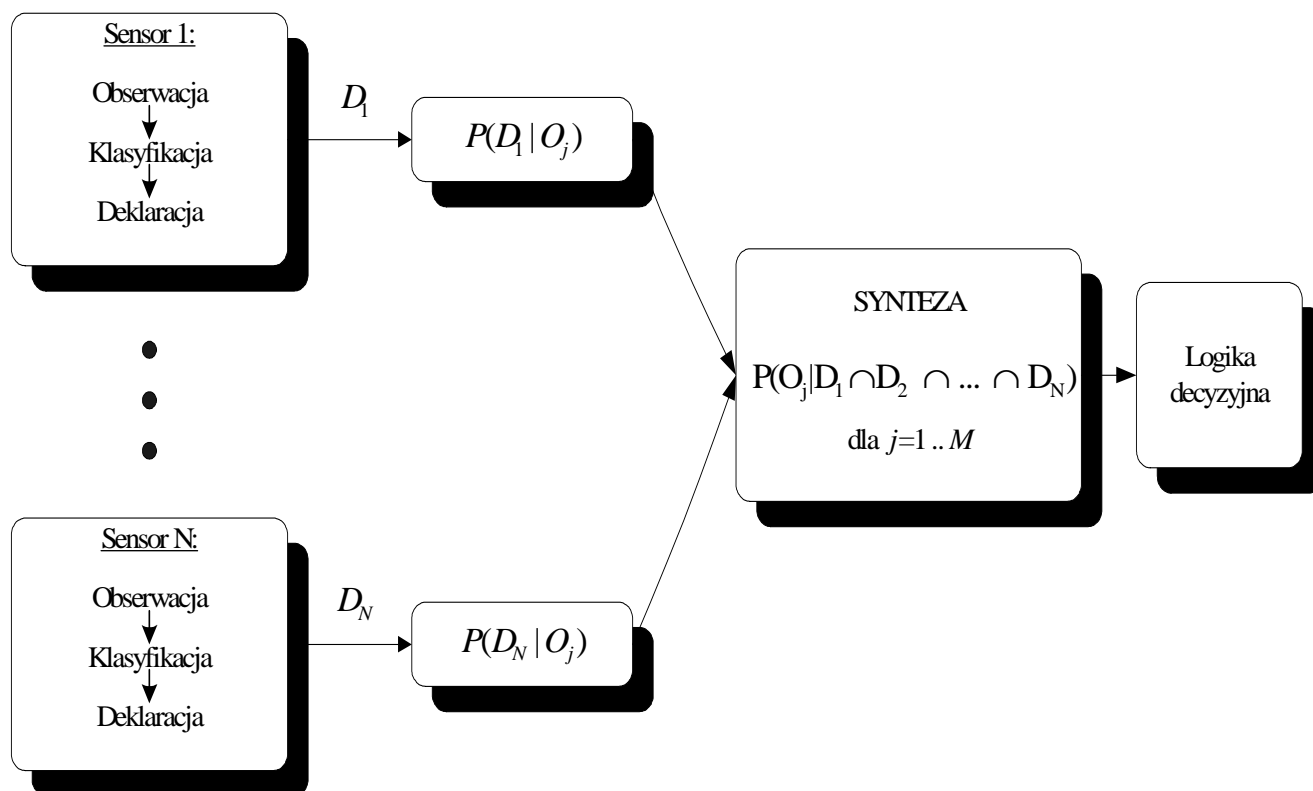
Podstawowym zagadnieniem w syntezie informacji jest problem wnioskowania.

1. SYNTEZA INFORMACJI OBRAZOWEJ Z WYKORZYSTANIEM WNIOSKOWANIA BAYESA

Na rys. 1 przedstawiono ideę systemu syntezy informacji obrazowej wykorzystującą regułę wnioskowania bayesowskiego [3].

System wyposażony jest w zaawansowane źródła informacji obrazowej (sensory), które oprócz akwizycji danych, realizują zadania wstępnego przetwarzania wyekstrahowanych cech charakterystycznych, dokonują klasyfikacji i generują deklarację D_i dotyczącą klasy obserwowanego obiektu O_i . Deklaracji jest przypisywana wartość prawdopodobieństwa *a priori* $P(D_i | O_j)$ (tzn. prawdopodobieństwa deklaracji przez i -ty sensor pod warunkiem, że jest to j -ty obiekt), a następnie w procesie syntezy danych wyznaczone jest zbiorcze prawdopodobieństwo *a posteriori* $P(O_j | D_1 \cap D_2 \cap \dots \cap D_N)$ (tzn. prawdopodobieństwo warunkowe, że jest to j -ty obiekt (O_j)) pod warunkiem deklaracji, która jest równa iloczynowi deklaracji ($D_1 \cap \dots \cap D_N$) z wszystkich N źródeł informacji.

¹ tadeuszniedziela@poczta.onet.pl



Rys. 1. Idea syntezy informacji obrazowej z wykorzystaniem reguły wnioskowania Bayesa

Wartość prawdopodobieństwa *a posteriori* wyznaczana jest z wyrażenia:

$$P(O_i | D_1 \cap \dots \cap D_N) = \frac{P(D_1 \cap \dots \cap D_N | O_i) P(O_i)}{\sum_{j=1}^M P(D_1 \cap \dots \cap D_N | O_j) P(O_j)} \quad (1)$$

Wychodząc z założenia, że deklaracje D_1, D_2, \dots, D_N są niezależne, można przyjąć:

$$P(D_1 \cap \dots \cap D_N | O_i) = \prod_{n=1}^N P(D_n | O_i) \quad (2)$$

Podstawiając powyższe wyrażenie do wzoru (1), otrzymujemy:

$$P(O_i | D_1 \cap \dots \cap D_N) = \frac{P(O_i) \prod_{n=1}^N P(D_n | O_i)}{\sum_{j=1}^M P(O_j) \prod_{n=1}^N P(D_n | O_j)} \quad (3)$$

Komentarza wymaga przyjęte przy konstruowaniu wyrażenia (3) założenie o niezależności deklaracji D_1, D_2, \dots, D_N . Otóż wynika ono z faktu niezależności zjawisk fizycznych leżących u podstaw doboru źródeł danych dla klasyfikacji. Sensory, pracując w niezależnych torach przetwarzania danych, dokonują akwizycji danych o różnym charakterze. Na podstawie posiadanej bazy wiedzy każdy z sensorów generuje deklarację D_n . W związku z tym dopuszczalne jest założenie niezależności deklaracji pochodzących z poszczególnych sensorów.

Ostatni element systemu stanowi moduł logiki decyzyjnej odpowiedzialny za wygenerowanie ostatecznej odpowiedzi określającej klasę obserwowanego obiektu. Najczęściej stosowanym kryterium decyzyjnym jest kryterium *MAP* (*maximum a posteriori*). Polega ono na wyborze tej deklaracji, dla której

prawdopodobieństwo $P(O_j | D_1 \cap D_2 \cap \dots \cap D_N)$ osiąga wartość maksymalną w danym cyklu klasyfikacji, czyli:

$$D_{MAP} = \arg \max_{i=1 \dots M} P(O_i | D_1 \cap D_2 \cap \dots \cap D_N) \quad (4)$$

Łatwo zauważyć, że do wyznaczenia deklaracji o największym prawdopodobieństwie *a posteriori* nie jest konieczne wyznaczanie mianownika równania (3). Pozwala to ograniczyć koszt związany z obliczeniami.

W trakcie projektowania systemów syntezy danych działających w oparciu o regułę wnioskowania Bayesa pojawia się problem doboru odpowiednich wartości prawdopodobieństwa *a priori* $P(O_i)$ oraz prawdopodobieństw warunkowych $P(D_n | O_i)$, które występują we wzorze (3). Dobór następuje najczęściej na drodze eksperymentalnej lub poprzez modelowanie zjawisk zachodzących w środowisku, w którym ma pracować system. W zależności od rodzaju tworzonego systemu, część danych może pochodzić z utworzonej w procesie projektowania bazy wiedzy lub być wyznaczana dynamicznie na podstawie danych dostarczanych przez sensory.

2. SYNTEZA INFORMACJI OBRAZOWEJ Z WYKORZYSTANIEM WNIOSKOWANIA DEMPSTERA-SHAFERA

Kolejną ze statystycznych metod pozwalających na przeprowadzenie syntezy informacji jest metoda oparta o algorytm Dempstera-Shafera. U podstaw tej metody leży matematyczna teoria ewidencji rozwinięta przez Dempstera i Shafera (Mathematical Theory of Evidence) zwana też teorią Dempstera-Shafera [4-7].

Dempster i Shafer zajęli się wyczerpującym zbiorem S wzajemnie wykluczających się wyników pewnego eksperymentu, określając go jako przestrzeń obserwacji (*frame of discernment*) oraz zdefiniowali przestrzeń deklaracji wyników eksperymentu jako zbiór zbiorów $\Omega = 2^S$. Przydzielili pewność (belief), $B(A)$, każdemu zbiorowi $A \subset \Omega$. Suma dowodów (jest niekiedy nazywana podstawowym przydzieleniem prawdopodobieństwa) spełnia następujące aksjomaty:

1. $m(\emptyset) = 0$
2. $m(A) > 0$ dla wszystkich $A \in \Omega$ (5)
3. $\sum_{A \subset \Omega} m(A) = 1$

Zauważmy, że aksjomaty te są w pewnym stopniu podobne do aksjomatów dla prawdopodobieństwa, jednak to nie są takie same. Pewność i prawdopodobieństwo nie są identyczne. Istotną różnicą jest fakt, iż aksjomat #3 przyrównuje do jedności masy prawdopodobieństw łącznie z nagromadzonymi dowodami przydzielonymi do wszystkich elementów zbioru Ω , natomiast aksjomaty prawdopodobieństwa przyrównują do jedności prawdopodobieństwa ze zbioru $S \in \Omega$.

Teoretycy teorii pewności interpretują zbiór S jako stan maksymalnej nieznanowości, a dowód dla zbioru S jest przenoszony na inne elementy zbioru Ω , ponieważ wiedza staje się oczywista wówczas, gdy nieznanowość znika. Stąd, przy braku jakichkolwiek dowodów, w stanie totalnej nieznanowości, przydzielamy $m(S) = 1$, a każdemu innemu elementowi Ω przydzielamy masę równą 0. Z czasem, kiedy wiedza powiększy się, większej ilości elementom zostanie przydzielona niezerowa masa dowodów. Wtedy, jeśli $m(A) > 0$ dla jakiegoś $A \in \Omega$, $m(S) < 1$ w zgodzie z redukcją niewiedzy (nieznanowości). Ta możliwość teorii pewności dla prostego i jasnego podejścia do nieznanowości jest często cytowana jako przydatna właściwość. Jednak, właściwość ta, nie jest unikalną dla teorii pewności.

Teoria pewności definiuje funkcję pewności (belief function) w pojęciu masy dowodów. Masa dowodów jest przydzielana konkretnemu zbiorowi, a nie elementom danego zbioru. Zatem, aby otrzymać

miarę całkowitej pewności powierzonej danemu zbiorowi, dodaje się masy dowodów powiązane ze wszystkimi zbiorami, które są podziorami danego zbioru. Dla wszystkich zbiorów A i B zawartych w Ω , definiujemy funkcję pewności $Bel(A)$ jako:

$$Bel(A) = \sum_{B \subseteq A} m(B) \quad (6)$$

Mając funkcję pewności $Bel(A)$, można utworzyć $m(B)$, czyli masę dowodów przydzielonych do zbioru B :

$$m(B) = \sum_{A \subseteq B} (-1)^{|B|-|A|} Bel(A) \quad (7)$$

$B \in \Omega$ jest "ogniskowym" elementem systemu pewności jeśli $m(B) > 0$. Połączenie wszystkich takich elementów systemu pewności nazywa się rdzeniem systemu pewności, oznaczanym jako C .

Oczywistym jest, że $Bel(A) = 1$ jeśli $C \subseteq A$; oraz jeśli wszystkie elementy są zdarzeniami atomowymi, wtedy $Bel(A)$ jest klasyczną miarą prawdopodobieństwa zdefiniowaną na S .

Funkcja pewności $Bel(A)$ (belief function) została nazwana funkcją wiarygodności a wsparcie (support) dla A , oznaczono $Su(A)$. Funkcja wiarygodności (plausibility function), oznaczona jako $Pl(A)$, może być zdefiniowana w pojęciu funkcji wsparcia (support function):

$$Pl(A) = 1 - Su(not - A) = 1 - \sum_{B \subseteq (\Omega - A)} m(B) = 1 - \sum_{A \cap B = \emptyset} m(B) = \sum_{A \cap B \neq \emptyset} m(B) \quad (8)$$

gdzie:

$Pl(A)$ – funkcja wiarygodności dla decyzji A , lub wiarygodność decyzji A ,

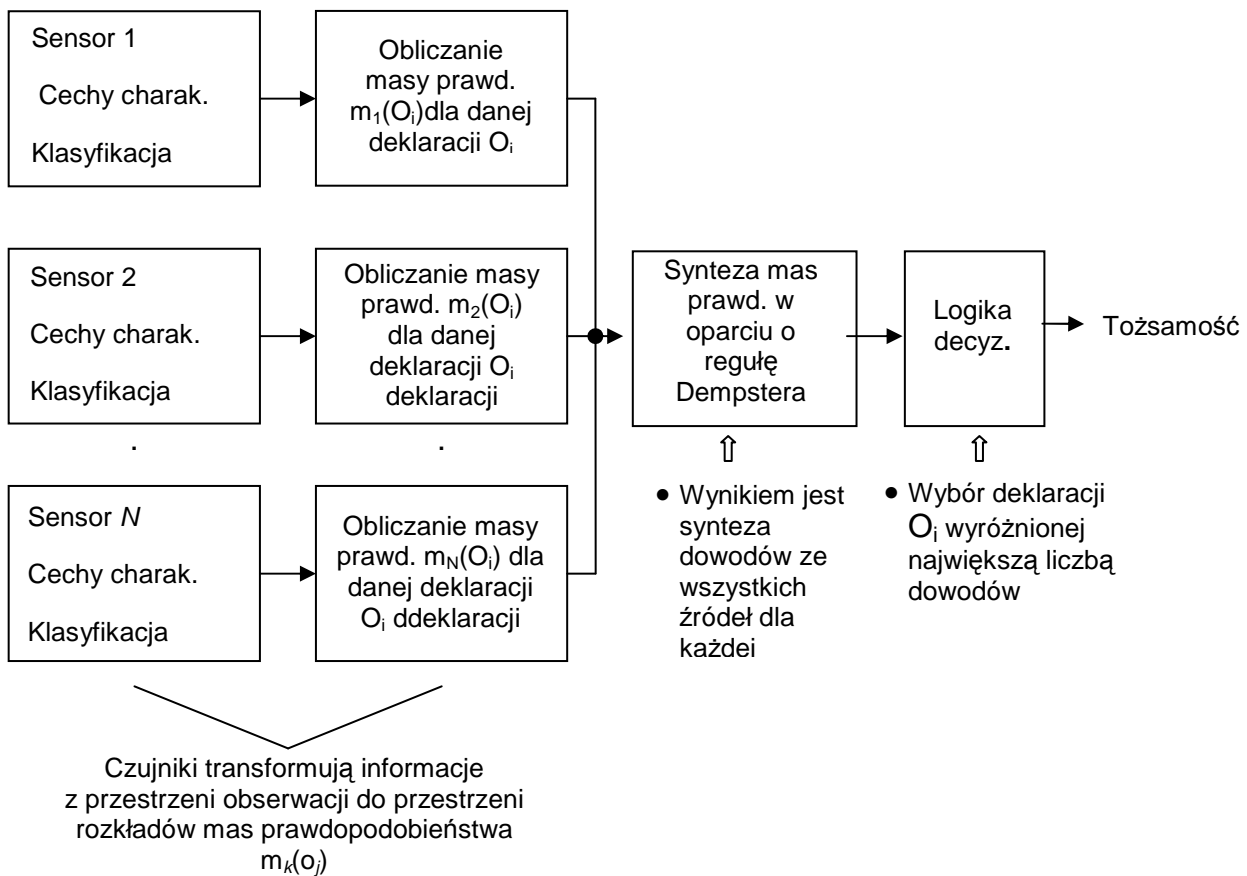
$Su(A)$ – funkcja wsparcia dla decyzji A .

W ten sposób wiarygodność A jest równa 1 minus suma masy dowodu przydzielona do wszystkich podziorów Ω , których iloczyn z A jest zbiorem pustym. Równoważnie, to jest sumie mas dowodów jaka została przydzielona dla wszystkich podziorów Ω , które mają niepuste iloczyny ze zbiorem A .

2.1. Wnioskowanie Dempstera-Shafera

Wnioskowanie Dempstera-Shafera jest statystycznym algorytmem klasyfikacyjnym danych. Stosowany jest gdy źródła informacji (czujniki) dostarczające informacje nie mogą zapewnić 100% pewności swoim decyzjom wyjściowym. Algorytm stwarza technikę, która zbiera i łączy informacje przy określonej pewności (ufności) w zdolności czujników do rozróżniania różnych obiektów. Pochodząca z wielu źródeł informacji wiedza o zdarzeniach (zwana deklaracjami lub hipotezami) jest łączona za pomocą reguły Dempstera, w celu znalezienia iloczynu, czyli koniunkcji deklaracji i związanego z nimi prawdopodobieństwa.

Istotę procesu syntezy danych według Dempstera-Shafera zilustrowano na rys. 2 [4]. Każdy sensor ekstrahuje zestaw cech charakterystycznych obiektów odpowiadających wykorzystywanym zjawiskom fizycznym, które stanowią informacje o obiektach i ich otoczeniu. Każdy czujnik działa na cechach charakterystycznych swoim szczególnym zbiorem algorytmów klasyfikacyjnych (synteza na poziomie czujnika). Poziom wiedzy gromadzonej przez k -ty czujnik, gdzie $k = 1, \dots, N$, wiąże się z deklaracją klasy obiektu (oznaczony na rysunku jako obiekt O_i , gdzie $i = 1, \dots, n$) z przypisaną masą prawdopodobieństwa $m_k(O_i)$ pomiędzy 0 a 1. Masa prawdopodobieństwa wyraża pewność decyzji. Masy prawdopodobieństwa bliższe jedności charakteryzują decyzje podjęte przy bardziej określonej wiedzy lub mniejszej niepewności co do natury obiektu. Masy prawdopodobieństwa dla decyzji podjętych przez każdy czujnik są następnie łączone za pomocą reguł decyzyjnych Dempstera.



Rys. 2. Idea procesu syntezy informacji obrazowej z wnioskowaniem Dempstera-Shafera.

Reguła Dempstera pozwala na sformalizowanie zasad integracji danych z kilku sensorów:

$$m(c) = K \sum_{a_i \cap b_j = c} [m_A(a_i)m_B(b_j)] \quad (9)$$

gdzie:

- c – deklaracja będąca wynikiem integracji deklaracji bazowych;
- $m_A(a_i), m_B(b_j)$ – deklaracje pochodzące od sensorów A i B

$$K^{-1} = 1 - \sum_{a_i \cap b_j = \emptyset} [m_A(a_i)m_B(b_j)] \quad (10)$$

Hipoteza wyróżniona największym zgromadzeniem dowodów i dająca największy wkład ze wszystkich czujników jest wybierana jako najbardziej prawdopodobny rezultat procesu syntezy informacji. Oprócz danych z czujników działających w czasie rzeczywistym, w bazie informacyjnej można zgromadzić inne informacje lub reguły, aby usprawnić całkowitą zdolność do podejmowania decyzji lub rozróżniania obiektów.

Proces syntezy informacji z wykorzystaniem reguły wnioskowania Dempstera-Shafera związany jest ze znalezienia iloczynu dwóch lub więcej danych z czujników oraz zastosowaniem reguły D-S.

Streszczenie

W pracy zaprezentowano wnioski bayesowskie oraz algorytm Dempstera - Shafera do syntezy informacji. Przedstawiono podstawy i cele syntezy informacji. Omówiono syntezę danych z kilku źródeł wiedzy oraz wskazano na reguły decyzyjne niezbędne do realizacji wniosku. Omówiono algorytm Dempstera - Shafera, który pozwala na realizację syntezy informacji metodami statystycznymi.

Słowa kluczowe: synteza informacji, reguła Bayesa, algorithm of Dempster - Shafer.

Methods for synthesis of image information from multiple sources

Abstract

Application of Bayes' rule in data synthesis systems is very promising on account of the possibility of including *a priori* information gathered in the course of designing the system in data classification outcome. This information, which is of statistical character, allows for obtaining good classification outcomes provided that its selection is proper. The Dempster-Shafer theory enables efficient realization of data synthesis in the process of modern recognition conducted within multi-sensor system. The knowledge of probabilities with which each sensor is able to assign the object observed to one of probable classes is nevertheless indispensable. Maximum efficiency of the system is basically dependent on proper selection of classification in particular conversion chains generating, if possible, declarations which do not exclude each other with possibly high probability.

Key words: synthesis of information, Bayes' rule, algorithm Dempstera - Shafera.

LITERATURA

- [1] Klein L. A.: Sensor and Data Fusion Concepts and Applications. SPIE Optical Engineering Press, Bellingham, Washington 1999.
- [2] Hall D. L., Llinas J.: Handbook of Multisensor Data Fusion CRC Press. New York 2001.
- [3] Baron G., Niedziela T.: Zastosowanie wnioskowania bayesowskiego do syntezy informacji. Prace Naukowe Instytutu Technicznego Wojsk Lotniczych, 18, 2004, s. 5-18.
- [4] Baron G., Niedziela T.: Synteza informacji z wnioskowaniem Dempstera-Shafera. Prace Naukowe Instytutu Technicznego Wojsk Lotniczych, 16, 2003, s. 5-21.
- [5] Dempster A. P.: Upper and lower probabilities inducted by a multi-valued mapping. Ann. Math. Stat. **38**, 1967, 325-339.
- [6] Dempster A. P.: A generalization of Bayesian inference. J. R. Stat. Soc. Ser. B 30, 1968, 205-247.
- [7] Shafer G.: A mathematical theory of evidence. Princeton University Press, Princeton 1976.