

Katarzyna TOPOLSKA*

ANALIZA LOGISTYCZNA STACJI OBSŁUGI POJAZDÓW Z ELEMENTAMI TEORII DEMPSTERA-SHAFERA

Z każdym miesiącem przybywa pojazdów na drogach, a co za tym idzie, zwiększa się liczba aut w stacjach diagnostycznych zarówno autoryzowanych, jak i prywatnych. Każdy właściciel samochodu chce mieć sprawnie, rzetelnie i w przystępnej cenie przeprowadzony przegląd techniczny auta (okresowy, główny czy sezonowy). W referacie przedstawiono zagadnienia logistycznego aspektu przeprowadzania przeglądów samochodowych w autoryzowanej stacji obsługi pojazdów. Analizie zostały poddane 204 samochody. Zebranie i przeanalizowanie danych z autoryzowanego serwisu samochodowego (z trzech miesięcy) miało na celu zaproponowanie usprawnień w funkcjonowaniu stacji obsługi zarówno pod kątem technicznym, jak i organizacyjnym.

SŁOWA KLUCZOWE: przeglądy samochodowe, bezpieczeństwo, wymiana podzespołów.

1. WSTĘP

Sektor motoryzacyjny musi posiadać system logistyczny ściśle powiązany z kanałami marketingowymi, aby zapewnić maksymalizację obecnych i przyszłych zysków oraz najbardziej efektywną realizację zamówień. Źródłem przewagi nad konkurencją jest przede wszystkim zdolność do odróżnienia się od niej w oczach nabywcy oraz operowanie niższymi kosztami, a co za tym idzie - uzyskiwanie wyższych zysków. Nie wystarczy zakładać, że „dobry produkt sprzeda się sam”, tak jak nie wolno wierzyć, że dzisiejszy sukces oznacza powodzenie w przyszłości. Spełniając oczekiwania klientów, powinno się im również przedstawić dobrze zorganizowaną ofertę serwisową oraz zachęcić do korzystania z naszego serwisu. Większość właścicieli samochodów uważa przeglądy okresowe za niepotrzebne. Tymczasem więcej tracą pieniędzy i czasu na usuwanie awarii spowodowanych zaniedbaniami przeglądów, niż oszczędzają, unikając ich. Im starszy samochód, tym mniejszą przykładają wagę do przeglądów.

Zebranie i przeanalizowanie danych z serwisu samochodowego firmy Renault (z trzech miesięcy) miało na celu zaproponowanie logistycznych usprawnień w funkcjonowaniu stacji obsługi zarówno pod kątem technicznym, jak i organizacyjnym.

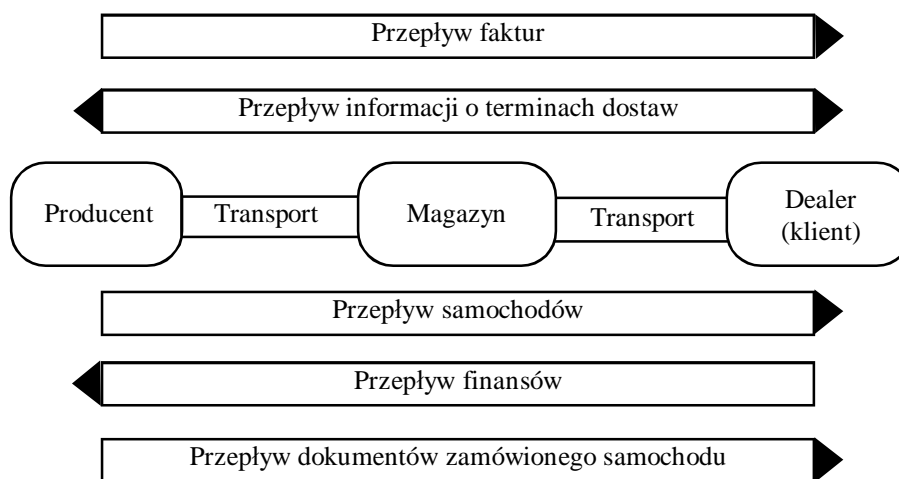
* Mgr inż. Katarzyna TOPOLSKA, Instytut Konstrukcji i Eksploatacji Maszyn, Zakład Pojazdów Samochodowych i Silników Spalinowych, Politechnika Wroclawska.

2. ANALIZA I OCENA JAKOŚCI OBSŁUGI KLIENTA W SERWISIE SAMOCHODOWYM

2.1. UWAGI OGÓLNE

W przedsiębiorstwie motoryzacyjnym w ciągły sposób zachodzi wymiana informacji w obydwu kierunkach w sferze dotyczącej zamówień, a dokładnie danych technicznych, jakie powinien posiadać konkretny pojazd. Również przepływ danych dotyczących planowanych dostaw jest bardzo ważnym elementem. Wynika to z konieczności zaspokojenia potrzeb i wymagań klienta.

Rys. 2.1. Procesy zachodzące w łańcuchu logistycznym badanego przedsiębiorstwa.
Fig. 2.1. Setting in logistic chain processes studied enterprise.



Source: Own study

Działanie serwisów samochodowych pozostawia niekiedy wiele do życzenia. Dlatego poniżej przedstawione zostały pewne propozycje, które mogą pozytywnie wpłynąć na naszą opinię.

2.2. ANALIZA LISTY CZYNNOŚCI WYKONYWANYCH PODCZAS PRZEGLĄDÓW SAMOCHODOWYCH

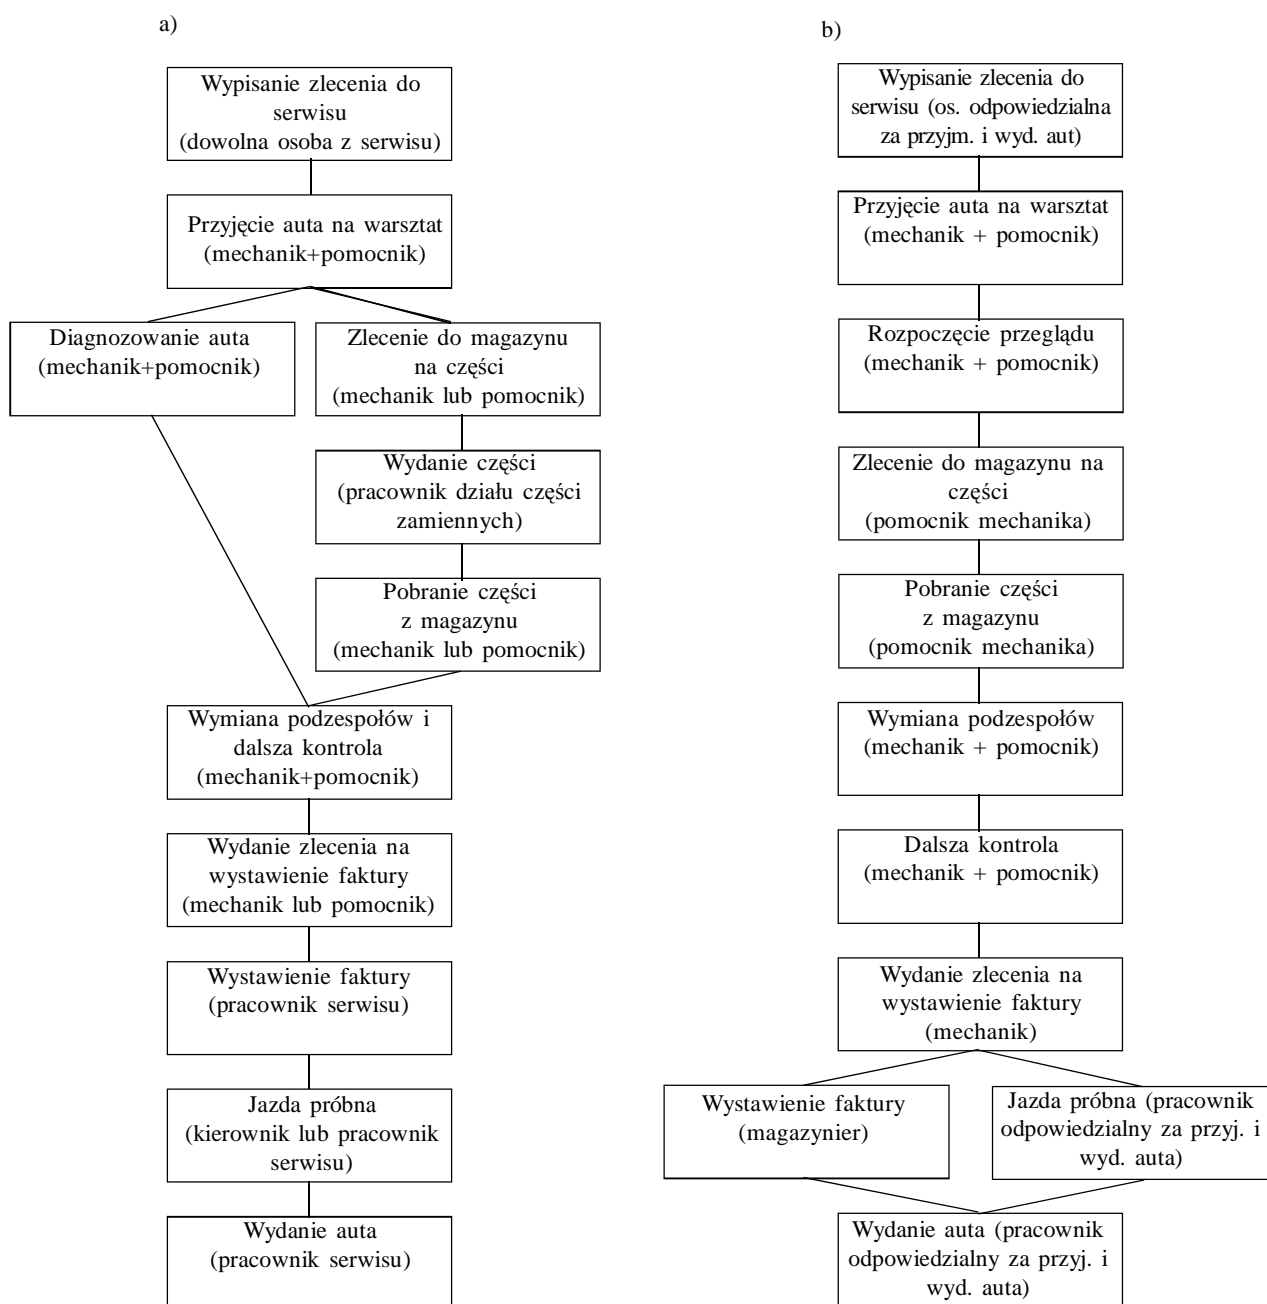
Przeglądy okresowe obejmują czynności, które dla każdej marki ściśle określa producent. Za pozostałe elementy i ich wymianę zleceniodawca jest zmuszony zapłacić. Najczęściej powtarzającymi się częściami do wymiany dodatkowej są: świece i klocki hamulcowe, rzadziej występują łożyska, sworzeń, pasek rozrządu, pasek klinowy, drążek.

Analiza przeglądów okresowych obrazuje, iż na liście czynności wykonywanych podczas tego diagnozowania powinny znaleźć się: sprawdzenie świec zapłonowych ewentualnie ich wymiana oraz wymiana klocków hamulcowych. Wiadomo, że każdy kierowca ma inną technikę jazdy i klocki hamulcowe zużywają się w różnym czasie. Z obserwacji mechaników wynika, że większe zużycie tych podzespołów ma miejsce w przypadku, kiedy auto prowadzone jest przez kobietę lub w cyklu miejskim. Natomiast w trakcie wykonywania przeglądów głównych w przypadku modelu Laguny wymiany świec zapłonowych dokonano w 21% diagnozowanych okresowo aut, u 11%

wymiany klocków hamulcowych, a po 5 % stanowiły czynności związane z wymianą paska rozrządu, paska klinowego, drążka, wieszaka, pompy wodnej i paska klinowego. Podczas przeglądów aut o dużym przebiegu lista czynności jest zbliżona do listy, według której wykonuje się przeglądy okresowe.

Rys. 4.1.a - Schemat dotychczasowej organizacji przeglądów samochodowych w serwisie
b - Schemat propozycji usprawnienia organizacji przeglądów samochodowych.

Fig. 4.1. a - Patern of hitherto exists organization of car reviews in service
b - Patern of proposal of improvement of organization of car reviews.



3. PROPOZYCJE USPRAWNIENIA PRZEGLĄDÓW SAMOCHODOWYCH

3.1. UWAGI WPROWADZAJĄCE

Modernizacja przeprowadzania przeglądów samochodowych pomogłaby w osiągnięciu lepszych wyników pracy, a tym samym zadowolenia klienta działu serwisu. Schemat usprawnienia przeglądów przedstawiono na rys. 4.1.

3.2. SYSTEM USPRAWNIENIA PRZEGLĄDÓW SAMOCHODOWYCH

Poniżej zaprezentowano model (algorytm systemu), za pomocą którego można optymalizować zadania serwisowe. Znajomość stanu technicznego w poprzednich etapach serwisowania może i ma wpływ na stan w etapie ostatnim. Ponadto jeżeli pojazd był serwisowany w różnych serwisach, to istnieje kilka historii serwisowania (ciągów uczących). Dlatego celowe okazuje się stworzenie modelu pozwalającego łączyć informacje pochodzące z różnych źródeł. Stworzono wiele algorytmów poprawy efektywności uczenia oraz wnioskowania. Niewiele z nich ingeruje w sam opis obiektu rozpoznawanego w celu poprawy jego zdolności przetwarzania informacji. W systemie sekwencyjnym, każdy obiekt reprezentowany jest za pomocą wektorów z wielowymiarowej przestrzeni wejściowej. W naszym przypadku będzie chodziło o zaklasyfikowanie za pomocą tych wektorów obiekt do pewnych kategorii, czyli klas. Załóżmy, że mamy do czynienia z zadaniem klasyfikacji i że model pojęciowy zawiera zbiór atrybutów A . Kontekst to zbiór atrybutów C nie zawarty w A i mający tę własność, że dodany do zbioru atrybutów A znacząco poprawia jakość klasyfikacji dokonywanej przez maszynę uczącą, zaś użyty sam nie zapewnia poprawnej klasyfikacji. Algorytm klasyfikacji obiektu (pojazdu) zaprezentujemy w formie etapów.

Etap 1. Fuzyfikacja

Założmy dla uproszczenia, że mamy utworzyć bazę reguł dla układu rozmytego o dwóch wejściach i jednym wyjściu. Dane uczące w postaci par możemy zapisać w formie:

$$(x_1(i), x_2(i), j(i)) \quad i = 1, 2, 3, \dots, n. \quad (3.1)$$

gdzie $x_1(i)$ i $x_2(i)$ (dane uczące ciągłe) są zmiennymi (cechami) podawanymi na wejście systemu rozpoznawania, $d(i) = \{1, 2, 3, \dots\}$ (dane uczące dyskretne-klasy decyzyjne). Klasy decyzyjne mogą zawierać informację, czy badany obiekt (pojazd, bądź podzespół pojazdu) jest zdalny do dalszej eksploatacji. W przypadku dwóch klas decyzyjnych np. 1 - oznacza zdalność obiektu do dalszej eksploatacji, a 0 - że obiekt nie jest zdalny do dalszej eksploatacji. W modelu rozpoznawania sekwencyjnego dane uczące występują w postaci:

$$S^{(i)} = (x_{m,1}, j_{m,1}, u_{m,1}), (x_{m,2}, j_{m,2}, u_{m,2}), \dots, (x_{m,N}, j_{m,N}, u_{m,N}), \quad (3.2)$$

gdzie ciąg $S^{(i)}$ $i=1, 2, 3, \dots, n$ jest realizacją zmiennych losowych (X_n, J_n) dla $n=1, 2, \dots, N$ wraz z wartościami sterowań w kolejnych taktach stanowi informację o N kolejnych obiektach powiązanych ze sobą za pomocą pewnych zależności.

Naszym zadaniem jest takie ustalenie reguł rozmytych, aby zbudowany za ich pomocą system rozpoznawania generował właściwe decyzje na wyjściu. Za pomocą zbioru uczącego zbudowano przesłanki (funkcje przynależności) np. za pomocą histogramów i każdej zmiennej lingwistycznej w odpowiednich cechach przyporządkowujemy literę np. M (mały), S (średni) i D (duży). Założono, że są dwa ciągi uczące. Należy więc skonstruować taki algorytm budowy bazy reguł, aby można było połączyć informacje zawarte w dwóch ciągach. W tym celu wydaje się rozsądne podejście wykorzystujące teorię ewidencji matematycznej Dempstera-Shafera.

Etap 2. Synteza

Do łączenia danych można zastosować teorię ewidencji matematycznej Dempstera-Shafera. Budując reguły rozmyte, wykorzystuje się np. ciąg uczący bądź wiedzę eksperta. W tym przypadku niech to będzie ciąg uczący.

Reguła kombinacji Dempstera pozwala na łączenie prawdopodobieństw wystąpienia klas, których łączna suma prawdopodobieństwa jest równa jeden. W przypadku wnioskowania rozmytego suma wartości funkcji przynależności do pewnej zmiennej lingwistycznej nie musi być równa jeden, zatem należy dokonać transformacji wartości $\mu(x_i)$, tak aby łączna suma:

$$\sum_{j=1}^M \mu_j^{T,L}(x_i) = 1, \quad (3.3),$$

gdzie: J- klasa decyzyjna
 T - transformacja do odcinka [0,1]
 L - zmienna lingwistyczna
 M - zbiór klas decyzyjnych.
 x_i - Zmienna wejściowa (cecha)

Przy czym należy odpowiednio transformować $\mu_j^{TL}(x_i)$, tak aby nie utracić właściwości tejsze wartości.

W celu wyznaczenia odpowiednich wartości $\mu_j^{TL}(x_i)$ spełniających warunek (3.3) można zastosować funkcję:

$$\mu_j^{T,L}(x_i) = \frac{\mu_j^L(x_i)}{\sum_{j=1}^M \mu_j^L(x_i)}. \quad (3.4)$$

Teraz można zastosować zgodnie z teorią Dempstera-Shafera syntezę danych $\mu_{j,p}^{TL}(x_i)$, gdzie p - numer zbioru ciągu uczącego bądź eksperta.

$$\mu_{j,p}^{T,L}(x_i) \oplus \mu_{j,p+1}^{T,L}(\phi) = 0, \quad (3.5)$$

$$\mu_{j,p}^{T,L} \oplus \mu_{j,p+1}^{T,L}(x_i^M) = \frac{\sum_{N \cap O=M} \frac{\mu_{j,p}^L(x_i) \cdot \mu_{j,p+1}^L(x_i)}{\sum_{j=1}^N \mu_{j,p}^L(x_i) \cdot \sum_{j=1}^N \mu_{j,p+1}^L(x_i)}}{\sum_{N \cap O=\phi} \frac{\mu_j^L(x_i) \cdot \mu_j^L(x_i)}{\sum_{j=1}^N \mu_{j,p}^L(x_i) \cdot \sum_{j=1}^N \mu_{j,p+1}^L(x_i)}}, \tag{3.6}$$

$$\mu_{j,p}^{T,L} \oplus \mu_{j,p+1}^{T,L}(x_i^M) = \sum_{N \cap O=M} \frac{\mu_{j,p}^L(x_i) \cdot \mu_{j,p+1}^L(x_i)}{\sum_{j=1}^N \mu_{j,p}^L(x_i) \cdot \sum_{j=1}^N \mu_{j,p+1}^L(x_i)} \cdot \left(\sum_{N \cap O=\phi} \frac{\mu_j^L(x_i) \cdot \mu_j^L(x_i)}{\sum_{j=1}^N \mu_{j,p}^L(x_i) \cdot \sum_{j=1}^N \mu_{j,p+1}^L(x_i)} \right)^{-1}, \tag{3.7}$$

Gdzie do budowy bazy reguł rozmytych wykorzystano zależność:

Tabela 1. Baza reguł rozmytych
Table 1. The rule base fuzzy

$x_1 \setminus x_2$	M	S	D
M	$L_{BR,K}^{MM}$	$L_{BR,K}^{MS}$	$L_{BR,K}^{MD}$
S	$L_{BR,K}^{SM}$	$L_{BR,K}^{SS}$	$L_{BR,K}^{SD}$
D	$L_{BR,K}^{DM}$	$L_{BR,K}^{DS}$	$L_{BR,K}^{DD}$

$$L_{BR,K}^{L_1,L_2} = \max \left[\mu_{j,p}^{T,L} \oplus \mu_{j,p+1}^{T,L}(x_i^M) \right] \tag{3.8}$$

Etap 3. Budowa reguł rozmytych z wykorzystaniem kontekstu oraz wyznaczenie rozmytych wartości wag klasom decyzyjnym na wyjściu każdego etapu wnioskowania.

Reguły zbudowano np. za pomocą ciągów uczących, zgodnie z regułą:

$$IF(x_i \text{ jest } L_1 \text{ AND } x_2 \text{ jest } L_2 \text{ AND } x_n \text{ jest } L_n) THEN (y \text{ jest } B)$$

Otrzymana baza reguł rozmytych ma następującą postać przedstawioną w tabeli 1.

gdzie: $L_{BR,K}^{L_1L_2}$ - oznacza zbiór klas decyzyjnych, które w wyniku budowy reguł wpadną do obszaru zmiennych lingwistycznych L_1 i L_2

BR - oznacza bazę reguł

K - oznacza k-tą postać bazy reguł

Zbiór $L_{BR,K}^{L_1L_2}$ możemy zdefiniować jako:

$$L_{BR,K}^{L_1L_2} = \{\varpi(J_1), \varpi(J_2), \dots, \varpi(J_M)\}. \quad (3.9)$$

$p_M^{(S)}$ jest estymatorem średnioczęstotliwościowym prawdopodobieństwa a priori wystąpienia odpowiednich klas decyzyjnych. Wyznaczono je, traktując model sekwencyjny jako stacjonarny i jednorodny według zależności:

$$p_M^{(S)} = \frac{n_M}{n}. \quad (3.10)$$

Dla dwóch klas decyzyjnych zbiór (4.9) będzie miał postać:

$$L_{BR,K}^{L_1L_2} = \{\varpi(J_1 = 1), \varpi(J_2 = 2)\}, \quad (3.11)$$

gdzie:

$\varpi(J_M)$ - jest „rozmytym” prawdopodobieństwem wystąpienia klasy zależnej od liczby elementów tej klasy, które wpadły do obszaru i zmiennych lingwistycznych. „Rozmyta” wartość prawdopodobieństwa spełnia zależność:

$$\varpi(J_1) + \varpi(J_2) = 1. \quad (3.12)$$

Zbudowana rozmyta baza reguł może być wykorzystywana do wnioskowania na każdym etapie systemu sekwencyjnego. Należy sobie jednak zdać sprawę, że serwisant, stawiając diagnozę, bierze pod uwagę nie tylko wyniki badań numerycznych, ale również inne czynniki, tj.: stan obiektu w poprzednim lub poprzednich etapach serwisowania, zastosowane naprawy w poprzednim stanie czy stanach. Powyższe cechy nazwijmy kontekstowymi i przetwarzając je będziemy nieco inaczej niż cechy podstawowe. W związku z powyższym należałoby zbudować system diagnostyczny, wykorzystujący na każdym etapie wnioskowania cechy wejściowe oraz połączone z nimi cechy kontekstowe. Zbudowana baza reguł rozmytych może stanowić podstawy szkielet bazy reguł. Za pomocą bazy reguł na każdym etapie będą modyfikowane wagi klas decyzyjnych, uwzględniając

zmienne kontekstowe. Zasadniczą cechą budowy analizowanego w pracy modelu jest odejście od pewnej zasady Markowa, mówiącej o jednorodności łańcucha. W budowie reguł rozmytych zakładamy jednorodność łańcucha obiektów. Różnica ta zaistnieje w określaniu wag występowania klas decyzyjnych dla każdego rozpoznawanego obiektu osobno, a nie dla całej populacji. Podejście takie ma pewien sens wynikający z eksploatacji pojazdów w różnych warunkach. Przykładowo zastosowane naprawy mogą wpływać na zmianę klasy decyzyjnej w różnym czasie itd... Pewne czynniki środowiskowe mogą wpływać różnie na różne podzespoły pojazdu. Wydaje się rozsądne podejście traktujące każdy pojazd oddzielnie. Baza danych (katalog) każdego pojazdu zawiera historię stanów technicznych oraz zastosowane naprawy. Na każdym etapie wnioskowania modyfikujemy wagi za pomocą bazy reguł rozmytych, wykorzystując cechy kontekstowe, tak aby na n-tym etapie wnioskowania uzyskać jak najdokładniejszą diagnozę, uzależnioną od całej trajektorii historii pojazdu.

Przyjmijmy, że mamy tylko jedną cechę kontekstową, a mianowicie klasę decyzyjną z poprzedniego etapu bądź etapów.

Uwzględnijmy teraz zależność decyzji na etapie wnioskowania n od cech podanych na wejście na tym etapie oraz od zmiennej kontekstowej stanowiącej decyzję na poprzednim etapie wnioskowania.

Jeżeli przyjmijmy powyższy model wnioskowania, to w pierwszej kolejności przydzielamy rozmyte wagi poszczególnym klasom decyzyjnym, uwzględniając tylko poprzedni etap wnioskowania. Niech na wejście pierwszego obiektu będą podawane cechy podstawowe $x_1(1)$ i $x_2(1)$. Na podstawie fuzyfikacji i zastosowanego łączenia reguł za pomocą reguły kombinacji Dempstera wyznaczamy zmienne lingwistyczne L_1 i L_2 , do których przynależą zmienne $x_1(1)$ i $x_2(1)$. Wskazują one na zbiór w bazie reguł rozmytych. Za ich pomocą można w pierwszym obiekcie wyznaczyć wagi poszczególnym klasom decyzyjnym:

$$ETAP1 \begin{bmatrix} KLASA1 \text{ z wagą } \varpi_{m,1}(J_{m,1}^1) \\ KLASA2 \text{ z wagą } \varpi_{m,1}(J_{m,1}^2) \end{bmatrix}^T \quad (3.13)$$

W drugim etapie wnioskowania przydzielono wagi klasom decyzyjnym tak jak w etapie pierwszym. Dodatkowo uwzględniono powiązanie decyzji na tym etapie wnioskowania z decyzją na etapie wcześniejszym. Niech wagi bez uwzględnienia etapu wcześniejszego będą miały postać:

$$ETAP2 \begin{bmatrix} KLASA1 \text{ z wagą } \varpi_{m,2}(J_{m,2}^1) \\ KLASA2 \text{ z wagą } \varpi_{m,2}(J_{m,2}^2) \end{bmatrix}^T \quad (3.14)$$

Jeżeli wiadomo, że w pierwszym etapie decyzją była KLASA1, to możemy wyznaczyć prawdopodobieństwo przejścia z KLASA1, do KLASA1 i KLASA2 w następujący sposób:

$$p_{1,1}^{BR} = \varpi_{m,1}(J_{m,1}^1) \cdot \varpi_{m,2}(J_{m,2}^1), \quad (3.15)$$

$$p_{1,2}^{BR} = \varpi_{m,1}(J_{m,1}^1) \cdot \varpi_{m,2}(J_{m,2}^2), \quad (3.16)$$

$$\varpi_{m,1}^*(J_{m,1}^1) = \frac{p_1^{(S)} \cdot p_{1,1}^{(BR)}}{p_1^{(S)} \cdot p_{1,1}^{(BR)} + p_2^{(S)} \cdot p_{2,1}^{(BR)}}, \quad (3.17)$$

$$\varpi_{m,2}^*(J_{m,2}^2) = \frac{p_1^{(S)} \cdot p_{1,2}^{(BR)}}{p_1^{(S)} \cdot p_{1,2}^{(BR)} + p_2^{(S)} \cdot p_{2,2}^{(BR)}}. \quad (3.18)$$

W powyższy sposób otrzymano nowe wagi, wykorzystując fakt, że w poprzednim etapie otrzymaliśmy na wyjściu KLASE1 w postaci:

$$ETAP2 \begin{bmatrix} \text{KLASA1 z wagą } \varpi_{m,1}^*(J_{m,1}^1) \\ \text{KLASA2 z wagą } \varpi_{m,1}^*(J_{m,2}^2) \end{bmatrix}^T. \quad (3.19)$$

$p_1^{(S)} = \frac{1}{2}$	$p_2^{(S)} = \frac{1}{2}$		
$p_{1,1}^{(S)}(1) = \frac{30}{80}$	$p_{1,1}^{(S)}(2) = \frac{17}{80}$	$p_{1,2}^{(S)} = \frac{10}{80}$	$p_{1,2}^{(S)} = \frac{23}{80}$
$p_{2,1}^{(S)} = \frac{10}{93}$	$p_{2,1}^{(S)} = \frac{39}{93}$	$p_{2,2}^{(S)} = \frac{26}{93}$	$p_{2,2}^{(S)} = \frac{18}{93}$

W diagnostyce podzespołów pojazdów ważną rolę odgrywa zastosowane serwisowanie. Logicznie rzecz ujmując, ma ono pośredni wpływ na decyzję. Istnieje więc dodatkowa zmienna (cecha kontekstowa), która może odgrywać ważną rolę w podejmowaniu decyzji. Możemy spotkać się z sytuacją, że serwisowanie przyczynia się do zmiany klasy decyzyjnej nie dla następnego obiektu, ale dwa obiekty (stany) dalej... Należałoby więc intuicyjnie zastosować taki mechanizm zmiany wag klasom decyzyjnym, aby uwzględnić również serwisowania zastosowane kilka etapów wcześniej. Możemy dysponować sterowaniami dyskretnymi, bądź możemy dysponować np. konkretnymi wartościami zastosowanego serwisowania. Rozważono model, który będzie zakładał tę pierwszą możliwość, w której dysponujemy tylko wartościami dyskretnymi.

Na podstawie zbioru uczącego wyznaczono estymatory średnioczęstotliwościowe odpowiednich prawdopodobieństw sterowań i sprzyjających im klas decyzyjnych. Założono, że otrzymane zostaną następujące przyporządkowania prawdopodobieństw:

Gdzie:

$$p_{M_1 M_2}^{(S)}(u):$$

M_1 i M_2 - klasy decyzyjne

u - sterowanie

Przyjęto model sekwencyjny w postaci:

$$S^{(i)} = (4,1,2), (\frac{3}{5},1,2), (\frac{1}{2},2,1), \dots, ((\frac{1}{3},1,2)) \quad (3.20)$$

Dla przypadku, w którym będziemy uwzględniali klasy decyzyjne występujące w etapie wcześniejszym oraz leczenie w etapie wcześniejszym, przyjęto od drugiego etapu następującą konstrukcję wag wygenerowaną za pomocą reguł rozmytych:

$$ETAP2 \left[\begin{array}{l} \text{KLASA1 z wagą } \varpi_{m,1}(J_{m,2}^1) \\ \text{KLASA2 z wagą } \varpi_{m,1}(J_{m,2}^2) \end{array} \right]^T \quad (3.21)$$

Jeżeli wiadomo np., że w pierwszym etapie decyzją była KLASA1 oraz że zastosowano leczenie 2, to możemy za pomocą prawdopodobieństwa warunkowego wykazać prawdopodobieństwo wystąpienia każdej klasy decyzyjnej w drugim etapie wnioskowania za pomocą wzoru (4.15) i (4.16) oraz:

$$\varpi_{m,1}^{2,u^*}(J_{m,1}^1) = \frac{p_1^{(S)} \cdot p_{1,1}^{(BR)} \cdot p_{1,1}^{(S)}(2)}{p_1^{(S)} \cdot p_{1,1}^{(BR)} \cdot p_{1,1}^{(S)}(2) + p_2^{(S)} \cdot p_{2,1}^{(BR)} \cdot p_{2,2}^{(S)}(1)}, \quad (3.22)$$

$$\varpi_{m,2}^{2,u^*}(J_{m,2}^2) = \frac{p_1^{(S)} \cdot p_{1,2}^{(BR)} \cdot p_{1,2}^{(S)}(2)}{p_1^{(S)} \cdot p_{1,2}^{(BR)} \cdot p_{1,2}^{(S)}(2) + p_2^{(S)} \cdot p_{2,2}^{(BR)} \cdot p_{2,2}^{(S)}(1)}. \quad (3.23)$$

W powyższy sposób otrzymano nowe wagi, wykorzystując fakt, że w poprzednim etapie otrzymano na wyjściu KLASĘ1 w postaci:

$$ETAP2 \left[\begin{array}{l} \text{KLASA1 z wagą } \varpi_{m,2}^{2,u^*}(J_{m,2}^1) \\ \text{KLASA2 z wagą } \varpi_{m,2}^{2,u^*}(J_{m,2}^2) \end{array} \right]^T \quad (3.24)$$

Na etapie 3 zbudowano wagi w następujący sposób:

$$\varpi_{m,1}^{3,u^*}(J_{m,1}^1) = \frac{p_1^{(S)} \cdot p_{1,1}^{(BR)} \cdot p_{1,1}^{(S)}(2)}{p_1^{(S)} \cdot p_{1,1}^{(BR)} \cdot p_{1,1}^{(S)}(2) + p_2^{(S)} \cdot p_{2,1}^{(BR)} \cdot p_{2,2}^{(S)}(1)}, \quad (3.25)$$

$$\varpi_{m,2}^{3,u^*}(J_{m,2}^2) = \frac{p_1^{(S)} \cdot p_{1,2}^{(BR)} \cdot p_{1,2}^{(S)}(2)}{p_1^{(S)} \cdot p_{1,2}^{(BR)} \cdot p_{1,2}^{(S)}(2) + p_2^{(S)} \cdot p_{2,2}^{(BR)} \cdot p_{2,2}^{(S)}(1)}. \quad (3.26)$$

W powyższy sposób otrzymujemy nowe wagi, wykorzystując fakt, że w poprzednim etapie otrzymaliśmy na wyjściu KLASĘ1 w postaci:


$$ETAP2 \left[\begin{array}{l} \text{KLASA1 z wagą } \varpi_{m,1}^{3,u^*} (J_{m,1}^1) \\ \text{KLASA2 z wagą } \varpi_{m,2}^{3,u^*} (J_{m,2}^2) \end{array} \right]^T \quad (3.27)$$

W podobny sposób wyznaczono wagi następnym obiektom rozpoznawanym. Podsumowując mechanizm wnioskowania poniżej przedstawiony został prosty przykład wnioskowania.

Przyjęto, że w zadaniu klasyfikacji mamy dwie klasy decyzyjne oraz dwie cechy $x_1(i)$ i $x_2(i)$. W pierwszym etapie wykonujemy proces fuzyfikacji dla dwóch ciągów uczących. W tym celu możemy dokonać analizy kształtu funkcji przynależności za pomocą histogramu. Przyjmijmy, że $x_1=20$ i $x_2=70$. Zgodnie z rysunkiem 4.3 przydzielamy cechom $x_1(i)$ i $x_2(i)$ wartości funkcji przynależności:

Rys.4.3 Przykładowe funkcje przynależności

Fig. 4.3 The instances of pertained functions.



W celu wykonania syntezy danych zastosujemy najpierw transformatę:

$$\mu_{2,(ciqi\ 1)}^{T,M}(x_1) = \mu_{2,(ciqi\ 1)}^{T,D}(x_1) = \frac{\frac{4}{9}}{\frac{4}{9} + \frac{4}{9}} = \frac{1}{2}, \quad (3.28)$$

$$\mu_{2,(ciqi\ 2)}^{T,M}(x_1) = \frac{\frac{1}{6}}{\frac{1}{6} + \frac{5}{9}} = \frac{18}{78}, \quad (3.29)$$

$$\mu_{2,(c1q1\ 2)}^{T,D}(x_1) = \frac{\frac{5}{9}}{\frac{1}{6} + \frac{5}{9}} = \frac{90}{117}. \quad (3.30)$$

Oczywiście wynika z tego $\frac{1}{2} + \frac{1}{2} = 1$ oraz $\frac{18}{78} + \frac{90}{117} = 1$.

Podobnie wyznaczono wartości transformaty dla cechy x_2

$$\mu_{2,(c1q1\ 1)}^{T,M}(x_2) = \frac{\frac{4}{5}}{\frac{4}{5} + \frac{3}{4}} = \frac{80}{155}, \quad (3.31)$$

$$\mu_{2,(c1q1\ 1)}^{T,D}(x_2) = \frac{\frac{3}{4}}{\frac{4}{5} + \frac{3}{4}} = \frac{60}{124}, \quad (3.32)$$

$$\mu_{2,(c1q1\ 2)}^{T,M}(x_2) = \frac{\frac{2}{3}}{\frac{2}{3} + \frac{3}{4}} = \frac{24}{51}, \quad (3.33)$$

$$\mu_{2,(c1q1\ 2)}^{T,D}(x_2) = \frac{\frac{3}{4}}{\frac{2}{3} + \frac{3}{4}} = \frac{36}{68}, \quad (3.34)$$

Oczywiście wynika z tego $\frac{80}{155} + \frac{60}{124} = 1$ oraz $\frac{24}{51} + \frac{36}{68} = 1$

$$p_{1,1}^{BR} = \frac{4}{5} \cdot \frac{30}{65} = \frac{24}{65}, \quad (3.35)$$

$$p_{1,2}^{BR} = \frac{4}{5} \cdot \frac{35}{65} = \frac{28}{65}, \quad (3.36)$$

$$p_{2,1}^{BR} = \frac{1}{5} \cdot \frac{30}{65} = \frac{6}{65}, \quad (3.37)$$

$$p_{2,2}^{BR} = \frac{1}{5} \cdot \frac{35}{65} = \frac{7}{65}. \quad (3.38)$$

Przyjęto, że prawdopodobieństwo a priori wystąpienia klas są równe: $p_1^{(S)} = p_2^{(S)} = \frac{1}{2}$

Prawdopodobieństwa wynikające z zastosowanego serwisowania na etapie wcześniejszym są dane w postaci:

$$\varpi_{m,1}^{3,u^*}(J_{m,1}^1) = \frac{p_1^{(S)} \cdot p_{1,1}^{(BR)} \cdot p_{1,1}^{(S)}(2)}{p_1^{(S)} \cdot p_{1,1}^{(BR)} \cdot p_{1,1}^{(S)}(2) + p_2^{(S)} \cdot p_{2,1}^{(BR)} \cdot p_{2,2}^{(S)}(1)} = \frac{\frac{1}{2} \cdot \frac{24}{65} \cdot \frac{17}{80}}{\frac{1}{2} \cdot \frac{24}{65} \cdot \frac{17}{80} + \frac{1}{2} \cdot \frac{6}{65} \cdot \frac{26}{93}} \approx 0.20 \quad (3.39)$$

$$\varpi_{m,2}^{3,u^*}(J_{m,2}^2) = \frac{p_1^{(S)} \cdot p_{1,2}^{(BR)} \cdot p_{1,2}^{(S)}(2)}{p_1^{(S)} \cdot p_{1,2}^{(BR)} \cdot p_{1,2}^{(S)}(2) + p_2^{(S)} \cdot p_{2,2}^{(BR)} \cdot p_{2,2}^{(S)}(1)} = \frac{\frac{1}{2} \cdot \frac{28}{65} \cdot \frac{23}{80}}{\frac{1}{2} \cdot \frac{28}{65} \cdot \frac{23}{80} + \frac{1}{2} \cdot \frac{7}{65} \cdot \frac{26}{93}} \approx 0.80 \quad (3.40)$$

Dla przyjętych $x_1=20$, $x_2=70$ widzimy, że po uwzględnieniu decyzji na poprzednim etapie oraz serwisowania zastosowanego poprzednio waga klasy $j=2$ jest dużo większa. Zatem jako decyzję na 15 etapie wnioskowania przyjmujemy ostatecznie $j=2$. Należy zaznaczyć, że powiązanie decyzji na 15 etapie wnioskowania z decyzją na 14 etapie nie jest wbrew pozorom uzależnione tylko od 14 etapu, lecz od całej trajektorii 14 etapów. Dzieje się tak dlatego, że na każdym etapie wnioskowania w sposób rozmyty zmienialiśmy wagi klas, uzależniając je od wcześniejszych etapów. Jeżeli klasa 1 oznacza fakt, że element jest zakwalifikowany, a klasa 2 oznacza, że element jest jeszcze zdalny do eksploatacji, to w wyniku takiego modelu otrzymaliśmy zoptymalizowaną decyzję o niezawodności obiektu.

4. WNIOSKI

Przeanalizowanie danych, jakie udało się zebrać, miało na celu wyciągnąć wnioski z przeprowadzanych przeglądów oraz nasunąć sposoby usprawnienia przeglądów samochodowych od strony widzianej oczyma klienta, jak i od strony warsztatowej. Analizie zostały poddane 204 samochody.

Proponowane usprawnienia przeglądów samochodowych: zmiana hali serwisowej, powołanie osoby odpowiedzialnej za przyjmowanie i wydawanie samochodów, przeorganizowanie osób na warsztacie, jakie zajmują się przeglądem samochodu, przeorganizowanie zadań, jakie mają obowiązek wykonać mechanik i pomocnik mechanika, zobowiązanie osoby do przyjmowania zamówień i wydawania części zamiennych, zobowiązanie jednej osoby do wystawiania faktur, przeorganizowanie kolejności zadań wykonywanych podczas przeglądów samochodowych. Wprowadzenie proponowanych modyfikacji powinno w istotny sposób wpłynąć na poprawę jakości pracy serwisu.

LITERATURA

- [1] DEMPSTER A. P. ,*Upper and lower probability induced by a multivalued mapping*. *Ann Math. Stat.*, 38, 325-339, 1967.
- [2] DEMPSTER A. P., *Upper and lower probability inference based on a sample from a finite uni variate population*. *Biometrika*, 54, 515-528, 1967.
- [3] KACPRZYK J., *Wieloetapowe sterowanie rozmyte*, Wydawnictwa Naukowo-Techniczne, Warszawa 2001.
- [4] FRĄTCZAK K., *Analiza przeglądów samochodowych i sposoby ich usprawnienia*, Praca dyplomowa.
- [5] WICHER J., *Bezpieczeństwo samochodów i ruchu drogowego*, Wydawnictwa Komunikacji i Łączności, 2004.
- [6] WIERZCHOŃ S.T., *Metody reprezentacji i przetwarzania informacji niepewnej w ramach teorii Dempstera-Shafera*, Instytut Podstaw Informatyki Polskiej Akademii Nauk, Warszawa 1996.
- [7] Materiały informacyjne firmy Renault.
- [8] Dokumentacja serwisu firmy Renault.

LOGISTIC ANALYSIS OF CAR SERVICE STATIONS USING ELEMENTS OF THE DEMPSTER-SHAFER THEORY

The number of authorised and unauthorised car service stations in Poland increases as a result of the continuous increase in the number of cars. Car owners would like to obtain a high-quality but cheap car service. In this paper some logistic aspects of car service in authorised car service stations are presented, based on a sample of 204 cars. The data collected, which cover a period of three months, are analysed with the aim to identify opportunities for improving the functioning of car service stations from a technical and organisational point of view.

KEY WORDS: car services, safety, replacement of subassemblies.