

Katarzyna TOPOLSKA*
Mariusz TOPOLSKI**

ZASTOSOWANIE ZBIORÓW ROZMYTYCH W PLANOWANIU ZAPASÓW W ŁAŃCUCHU DOSTAW

Artykuł prezentuje model planowania zapasów z wykorzystaniem miękkich metod obliczeniowych. Prognozowanie zapasów jest procesem bardziej stochastycznym niż deterministycznym. Zmieniający się popyt rynku, uwarunkowany różnymi czynnikami, niekiedy trudnymi do przewidywania, sprawia duże problemy w prognozowaniu. Zastosowanie podejścia opartego na zbiorach rozmytych sprawia, że wnioskowanie z danych niepewnych, niepełnych bądź nieprecyzyjnych daje lepsze rozwiązania w sensie poprawnych prognoz niż metody statystyczne. W pracy zaprezentowano sekwencyjny model planowania zapasów, uwzględniający pewną ustaloną trajektorię wcześniejszych obserwacji. Istotnym elementem modelu jest jego czułość na zmiany sezonowe oraz duża adaptacja do nowych pojawiających się niestabilnych zmian trendu. Kolejnym, istotnym elementem artykułu są wyniki badań opartych na danych eksperymentalnych, gdzie sprawdzono skuteczność poprawnych prognoz wraz z ich błędem.

1. WPROWADZENIE

W życiu codziennym bardzo często używamy pojęć nieprecyzyjnych. W badaniach naukowych czy technice mamy zazwyczaj do czynienia z pewną nieokreślonością, związaną zresztą często z błędami pomiarowymi. Niezmiernie często używamy pojęć przybliżonych. Ileż razy mówimy, że ktoś ma „około 180 cm wzrostu”, albo że coś waży „ze dwa kilogramy”. Właśnie w takich przypadkach używamy – intuicyjnie i nie zdając sobie z tego sprawy – pojęcia zbioru rozmytego. Zbiór rozmyty¹ – aby uściślić to intuicyjne określenie – to właśnie taki, w okolicy „krańców” którego zupełnie niewiadomo, czy dane elementy do niego należą, czy też nie. Zbiór rozmyty wchodzi w kolizję z klasyczną logiką, która przecież jest oparta na dychotomii tak-nie. Tertium non datur, trzeciego wyjścia nie ma – powiada prawo tej klasycznej logiki, znane jako prawo wyłącznego środka.

* Dr Katarzyna Topolska, Międzynarodowa Wyższa Szkoła Logistyki i Transportu we Wrocławiu

** Dr Mariusz Topolski, Międzynarodowa Wyższa Szkoła Logistyki i Transportu we Wrocławiu

¹ Łęski J., Zbiory rozmyte i ich interpretacja. Wprowadzenie do teorii możliwości, Wydawnictwa Politechniki Śląskiej, Gliwice 2001, s. 469-479

Rutkowska D., Piliński M., Rutkowski L., Sieci neuronowe, algorytmy genetyczne i systemy rozmyte, Wydawnictwo Naukowe PWN, Łódź 1999

Tymczasem w przypadku zbiorów rozmytych owo trzecie wyjście jest: przedmiot może należeć do zbioru w pewnym tylko stopniu. Zdanie może być częściowo prawdziwe i fałszywe.

Każdy, kto kiedykolwiek był uczony Kantorowskiej teorii mnogości, wie doskonale, że wiąże się ona niezwykle ściśle z klasycznym rachunkiem zdań; mówiąc dokładniej, formalizm klasycznego rachunku zdań jest po prostu tym samym formalizmem, który rządzi algebrą zbiorów; jest to zupełnie ta sama algebra Boole'a. Stworzenie takiej logiki ma głęboki sens. Przykładem może być planowanie dowolnego typu zapasów. Należy sobie zadać pytanie, gdzie w planowaniu zapasów występuje niepewność pomiarowa. Jest ona zauważalna już na poziomie obserwacji charakterystyki zużycia zapasów, która przejawia cechy deterministyczne i stochastyczne. Losowa, niejednokrotnie trudna do przewidzenia zmiana popytu, czasami nieprecyzyjne okresy dostaw wywierają istotny wpływ na planowanie zapasów.

Aktualny stan zapasu nie zależy tylko i wyłącznie od ostatniego pomiaru, ale zależy od pewnej trajektorii wcześniejszych obserwacji zużycia zapasów oraz czynników je determinujących, tj. czasu dostawy, współczynnika obsługi klienta itd. Niniejszy artykuł **nie zawiera optymalnego rozwiązania**. Jest on pierwszym krokiem w kierunku nowego podejścia, które będzie wykorzystywał rozmytą obserwację łańcucha sekwencji pomiarów do planowania zapasów². Takie podejście opiera się na pewnej metodzie sztucznej inteligencji, która będzie dostosowywała rozmyty sterownik sekwencyjny do zmieniających się **w funkcji czasu, trudnych do przewidzenia zmian popytu**. W rezultacie czego uzyskamy dokładniejsze w porównaniu z klasycznymi klasyfikatorami oszacowania zapasów niezbędnych do zaspokojenia rynku.

2. MATEMATYCZNY OPIS ZADANIA PROGNOZOWANIA SEKWENCYJNEGO

Zadanie rozpoznawania sekwencyjnego będzie traktowane jako pewien proces dynamiczny. Obiekt w k -tym taktcie znajduje się w stanie Y_k , który należy do ilościowego przedziału $y_k \in R_+$. Stan obiektu nie podlega bezpośredniemu pomiarowi. Jest on wynikiem obserwacji zużycia zapasów, a dokładniej pewnej trajektorii wcześniejszych pomiarów $Y_{k-1}, Y_{k-2}, \dots, Y_{k-l}$. Niech $x_k \in X$ będzie d -wymiarowym wektorem zmiennych (cech), jakie zostały zmierzone w poprzednich taktach. Zmienne te w przypadku zapasów to czas dostawy, współczynnik obsługi klienta i inne czynniki, które są predyktorami wielkości zapasów. Zmienne te podlegają rozmywaniu \tilde{T}_i zbiorami rozmytymi, gdzie:

$$\tilde{T}_i = \{ \tilde{T}_1, \tilde{T}_2, \tilde{T}_3, \dots, \tilde{T}_d \} \quad (1)$$

² Kurzyński M., *Sequential Classification Via Fuzzy Relations, Artificial Intelligence and Soft Computing – ICA-ISA2006*, 8th International Conference, Zakopane, Poland, June 2006

Łęski J., *Zbiory rozmyte i ich interpretacja. Wprowadzenie do teorii możliwości*, Wydawnictwa Politechniki Śląskiej, Gliwice 2001, s. 469-479

Topolski M., *Komputerowe algorytmy rozpoznawania sekwencyjnego z modelem łączącym teorię ewidencji matematycznej z teorią zbiorów rozmytych*, Praca doktorska, PRE 1/07 Politechnika Wroclawska 2007

Żołnierek A., *The pat tern recognition alghorithm for controlled Markov chains with learning and additional classifier*, [w]: *Advanced simulation of system. Proceedings of the XXVth International Autumn Colloquium*. Ed. Jan Stefan Sv. Hostyn, Czech Republic, September 8-10, 2003

Zbiorem rozmytym T w pewnej (niepustej) przestrzeni X , co zapisujemy jako $T \subseteq X$, nazywamy zbiór par³:

$$\tilde{T} = \{(x, \mu_{\tilde{T}}(x)); x \in \mathbf{X}\} \quad (2)$$

gdzie: $\mu_{\tilde{T}} : \mathbf{X} \rightarrow [0,1]$ jest funkcją przynależności zbioru rozmytego \tilde{T} .

Funkcja ta każdemu elementowi $x \in X$ przypisuje jego stopień przynależności do zbioru rozmytego \tilde{T} , przy czym można wyróżnić 3 przypadki:

- $\mu_{\tilde{T}}(x) = 1$ oznacza pełną przynależność do zbioru rozmytego \tilde{T} , tzn. $x \in \tilde{T}$,
- $\mu_{\tilde{T}}(x) = 0$ oznacza brak przynależności elementu x do zbioru rozmytego \tilde{T} , tzn. $x \notin \tilde{T}$,
- $0 < \mu_{\tilde{T}}(x) < 1$ oznacza częściową przynależność elementu x do zbioru rozmytego \tilde{T} .

W dalszych rozważaniach n oznaczać będzie n -tą regułę rozmytą:

$$n = \{1, 2, \dots, N\} \quad (2)$$

W analizowanym przypadku aktualny stan obiektu jest zależny od poprzednich stanów, czyli zastosowanego sterowania zapasami.

Łączenie aktualnej obserwacji cech obiektu z poprzednim stanem jest pewnym uproszczeniem. Można oczywiście analizować wszystkie dotychczasowe stany obiektu, ale taka interpretacja może być trudna do uwzględnienia.

Podjęcie decyzji o planowanym poziomie zapasów w momencie $k+1$ jest uzależnione od pomiaru opisujących go cech oraz wiedzy o związkach między kolejno występującymi pomiarami zapasów (trendu) i cech opisujących wielkość zapasów. Wiedza ta jest magazynowana w zbiorze uczącym S , który składa się z zestawu ciągów uczących:

$$S = \{S_1, S_2, S_3, \dots, S_L\} \quad (3)$$

Pojedynczy ciąg uczący można zapisać następująco:

$$S_k = (x_1, x_2, \dots, x_d, \bar{Y}) \quad (4)$$

gdzie: S_k - oznacza obserwację zużycia zapasów w k -tym takcie. W przypadku planowania zapasów S_k jest pomiarem cech opisujących wielkość zapasów, np. czas dostawy, współczynnik obsługi klienta, ... który można zapisać w szczególowej formie:

$$S_k = (t_k, \beta_k, \dots, \bar{Y}_k) \quad (5)$$

gdzie: t - czas dostawy, β - współczynnik obsługi klienta, \bar{Y} - rzeczywista wartość zużycia zapasów.


Zadanie rozpoznawania sekwencyjnego będzie polegało na tym, że klasyfikator rozmyty w k -tym takcie do podjęcia decyzji o prognozie zapasów na następny okres wykorzysta informacje w postaci poprzednich wielkości zapasów, czasów dostawy, współczynników obsługi klienta i innych cech determinujących zapas. Ostrą wartość zapasów uzyskuje się w bloku wyostrzania metodą środka ciężkości (ang. *center of gravity method* lub *center of area method*) według wzoru:

³ Topolski M., Komputerowe algorytmy rozpoznawania sekwencyjnego z modelem łączącym teorię ewidencji matematycznej z teorią zbiorów rozmytych, Praca doktorska, PRE 1/07 Politechnika Wroclawska 2007

$$Y_{k+1} = \frac{\int_Y \tilde{Y}_{k+1} \mu_{B'}(\tilde{Y}_{k+1}) d\tilde{Y}_{k+1}}{\int_Y \mu_{B'}(\tilde{Y}_{k+1}) d\tilde{Y}_{k+1}} = \frac{\int_Y \tilde{Y}_{k+1} \max_k \mu_{B^k}(\tilde{Y}_{k+1})}{\int_Y \max_k \mu_{B^k}(\tilde{Y}_{k+1})} \tag{6}$$

Ilustrację metody środka ciężkości przedstawiono na rys. 1.

Rys. 1. Metoda środka ciężkości (ang. center of gravity method lub center of area method)

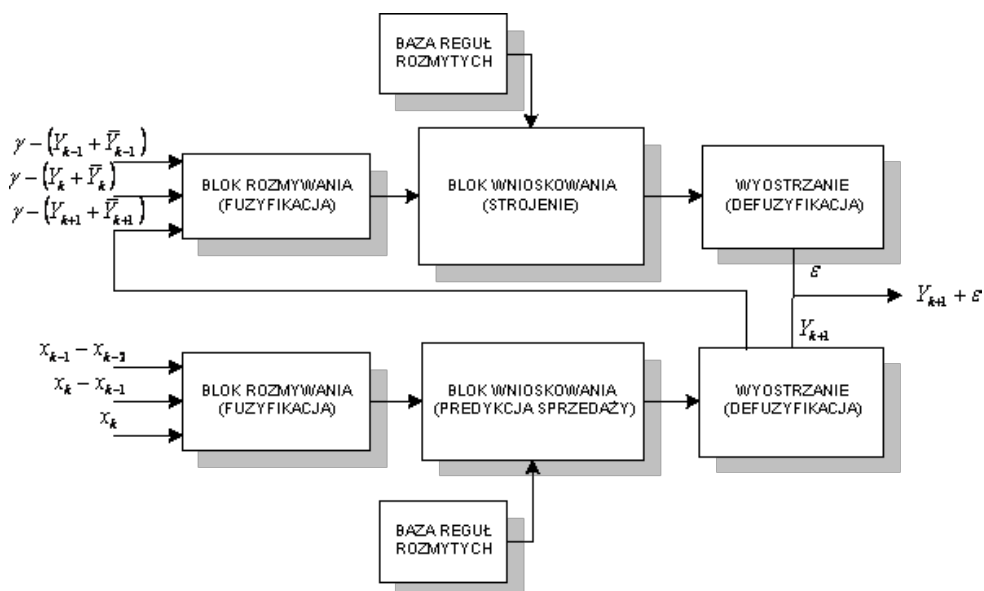


Klasyfikator rozmyty ogólnie można zapisać w postaci:

$$y_{k+1}((x_k, \bar{Y}_k)(x_{k-1}, \bar{Y}_{k-1})(x_{k-2}, \bar{Y}_{k-2})S) = Y_{k+1} \tag{7}$$

Algorytm (7) jest zapisany w postaci ogólnej, a jego argumenty są zależne od złożoności wykorzystanych parametrów do oceny wielkości zapasów. Proces rozpoznawania sekwencyjnego można ująć schematem podanym na rysunku 2.

Rys. 2. Budowa systemu rozpoznawania sekwencyjnego zapasów



W modelu (rys. 2) na wejściu **rozmywane** jest bieżące zużycie zapasów Y_k oraz różnice wektorów opisujących wielkość zużycia zapasów między k , a $k-1$ taktem oraz różnice między $k-1$, a $k-2$ taktami. Wielkości te podlegają procesowi fuzyfikacji (rozmywania). Następnie na podstawie całej dostępnej wiedzy zgromadzonej w zbiorze uczącym w bloku wnioskowania wyznaczone jest rozmyte odwzorowanie wielkości rozmytych \tilde{T}_k w zbiór rozmyty \tilde{Y}_{k+1} . W procesie defuzyfikacji (wyostrzania) zbiór rozmyty \tilde{Y}_{k+1} jest przekształcany w ostrą wartość Y_{k+1} . Aby algorytm mógł sam zapewnić stały poziom zapasu w magazynie niezależnie od jego wielkości, należy uzyskany wynik dostroić. Do realizacji strojenia rozmywa się prognozę Y_{k+1} . Różnica prognozy i wartości oczekiwanej \bar{Y}_{k+1} z ciągu uczącego jest miarą błędu. Współczynnik $\gamma \in R$ jest miarą ilościową, która ustalona jest optymalnie za pomocą algorytmu genetycznego⁴ na podstawie ciągu uczącego. Miara $\gamma \in R$ ma za zadanie ustalić taką wartość optymalną prognozy, aby zapas nie był na deficycie i nie kumulował się z czasem. Innymi słowy, jest to taki współczynnik, który steruje zapasem, utrzymując jego poziom na optymalnie stałym poziomie. Jest to ważny element planowania zapasów, gdyż w rzeczywistości ważne jest, aby na kolejny okres zaplanować taki zapas, który zaspokoi potencjalnych klientów i po tym okresie nadmiar zapasu będzie minimalny, ale większy od zera. Na wyjściu bloku dostrajania otrzymuje się wartość błędu ε . Po dodaniu tego błędu do prognozy otrzymujemy na wyjściu wartość zapasu, który jest podstawą następnego okresu.

3. BADANIA EKSPERYMENTALNE OPRACOWANEGO MODELU PREDYKCJI ZAPASÓW

Badania eksperymentalne wykonano na ciągu uczącym wygenerowanym losowo, ale według ściśle określonej reguły. Dane generowano według zależności:

$$S: \bar{Y}_k = tk + \beta k^2 + \omega, \quad (8)$$

gdzie współczynniki **czasu** dostawy $t = \{1, 2, \dots, 5\}$, a współczynnik obsługi klienta $\beta \in (0, 80 - 0, 99)$ są losowo wygenerowanymi parametrami, ω - jest losowym błędem estymacji na poziomie 0-30% (wartość ta symbolizuje trudne **do przewidzenia** zmiany na rynku).

Przyjęto arbitralnie trójkątne zbiory rozmyte zarówno na wejściu, jak i na wyjściu klasyfikatora⁵:

$$t(x; a, b, c) = \begin{cases} 0 & \text{dla } x \leq a \\ \frac{x-a}{b-a} & \text{dla } a \leq x \leq b \\ \frac{c-x}{c-b} & \text{dla } b \leq x \leq c \\ 0 & \text{dla } x \geq c \end{cases} \quad (9)$$

Parametry funkcji przynależności (9) tj a, b, c jak i wartość dostrajania klasyfikatora $\gamma = 52$ nie są przypadkowe, ale ich wartości są ustalone optymalnie dla wcześniej wygenerowanego ciągu

⁴ Rutkowska D., Piliński M., Rutkowski L., *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, Wydawnictwo Naukowe PWN, Łódź 1999

⁵ Topolski M., *Komputerowe algorytmy rozpoznawania sekwencyjnego z modelem łączącym teorię ewidencji matematycznej z teorią zbiorów rozmytych*, Praca doktorska, PRE 1/07 Politechnika Wroclawska 2007

uczącego (8), za pomocą algorytmu genetycznego⁶. Wszystkie zmienne wejściowe również arbitralnie podzielono na trzy zbiory rozmyte, którym nadano wartości lingwistyczne (M-mały, S-średni, D-Duży). Na podstawie wygenerowanego wcześniej ciągu uczącego (8) klasyfikator (7) poddano procesowi uczenia maszynowego⁷ zgodnie ze schematem rys. 2. Na podstawie uczenia uzyskano klasyfikator rozmyty, którego dane zawiera tabela 1.

Tabela 1. Dane klasyfikatora rozmytego uzyskane na drodze uczenia maszynowego

Rozmyte zmienne wejściowe			Parametry zbiorów rozmytych na wyjściu					
$x_k - x_{k-1}$	$x_{k-1} - x_{k-2}$	x_k	Średnia	N	Odchylenie stand.	Minimum	Maksimum	Mediana
M	M	M	177,000	8	75,650	55,000	294,00	175,000
M	M	S	547,917	12	53,468	407,000	606,00	552,500
M	M	D	830,083	12	77,365	689,000	945,00	832,500
M	S	M	267,300	10	83,015	80,000	375,00	272,500
M	S	S	467,179	7	81,916	400,000	575,00	406,000
M	S	D	760,500	4	40,829	721,000	814,00	753,500
M	D	M	256,125	8	83,340	131,000	378,00	279,000
M	D	S	530,533	15	85,304	400,000	629,00	560,000
M	D	D	858,250	16	144,420	633,000	1040,00	880,000
S	M	M	252,923	13	107,567	60,000	381,00	264,000
S	M	S	502,277	12	82,144	392,320	610,00	538,000
S	M	D	805,889	9	112,809	662,000	981,00	778,000
S	S	M	322,707	24	72,947	80,000	388,86	354,000
S	S	S	437,522	86	61,334	391,260	622,00	407,770
S	S	D	776,556	9	129,791	644,000	997,00	741,000
S	D	M	311,000	6	58,014	200,000	358,00	324,500
S	D	S	479,888	16	70,212	400,000	622,00	450,000
S	D	D	810,200	5	110,760	679,000	984,00	805,000
D	M	M	278,833	6	74,430	172,000	360,00	286,500
D	M	S	535,000	8	65,196	444,000	606,00	557,500
D	M	D	830,833	12	166,389	649,000	1117,00	832,000
D	S	M	258,429	7	76,118	134,000	331,00	294,000
D	S	S	502,325	21	74,213	403,300	620,00	495,000
D	S	D	830,083	12	138,086	648,000	1106,00	826,000
D	D	M	304,750	8	58,343	188,000	367,00	318,000
D	D	S	542,000	4	61,444	469,000	600,00	549,500
D	D	D	909,154	13	157,684	682,000	1171,00	925,000
Ogół grup			517,541	363	223,908	55,000	1171,00	446,000


⁶ Rutkowska D., Piliński M., Rutkowski L., *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, Wydawnictwo Naukowe PWN, Łódź 1999

⁷ Topolski M., *Komputerowe algorytmy rozpoznawania sekwencyjnego z modelem łączącym teorię ewidencji matematycznej z teorią zbiorów rozmytych*, Praca doktorska, PRE 1/07 Politechnika Wroclawska 2007

Žolnierka A., *The pat tern recognition alghorithm for controlled Markov chains with learning and additional classifier*. [w]: Advanced simulation of system. Proceedings of the XXVth International Autumn Colloquium. Ed. Jan Stefan [Sv. Hostyn, Czech Republic, September 8-10, 2003.

Następnym etapem był proces testowania nauczonego klasyfikatora. Na tym etapie, począwszy od taktu $k=3$, klasyfikator był testowany, w ten sposób, że uzyskana wartość zapasu w takcie $k+1$ była porównywana z rzeczywistą wygenerowaną wartością zapasu. W analizach klasyfikator został nazwany Fuzzy-ProgKM+dostrojanie. Uzyskane taką metodą zapasów wyniki zobrazowano na wykresie (rys. 3).

Rys. 3. Charakterystyka wygenerowanego ciągu uczonego i zdolności predykcji danych rzeczywistych klasyfikatora Fuzzy-Prog+dostrojanie




Na podstawie powyższego wykresu można zauważyć, że klasyfikator dość dokładnie pokrywa charakterystykę rzeczywistego ciągu uczonego. Średni błąd klasyfikacji wynosi 2.78%, co jest zadowalającą wielkością. W celu zobrazowania celowości zastosowania dostrojania (rys. 2) w klasyfikatorze wykonano analizy, wyłączając blok dostrajania. Uzyskane wyniki obrazuje wykres (rys. 4) Wykres ten wykazuje, że dostrojanie wpływa na polepszenie dokładności klasyfikatora. Ponadto bez zastosowania dostrajania błąd predykcji wynosi średnio 3.98%, co jest o ponad 1% większą wartością niż dla algorytmu z dostrajaniem. Zauważono pewną własność. Zastosowanie dostrajania spowodowało, że z taktu na takt utrzymuje się zapas w przedziale [2-65]. W przypadku braku strojenia, zapas ten kształtuje się w przedziale [-34; 112], co jest niepożądaną (krytyczną) sytuacją, gdyż nie możemy dopuścić do deficytu.


Na rysunku 5 zobrazowano charakterystykę wygenerowaną za pomocą zależności (8), wprowadzając losowo duże błędy na poziomie 80%.

Można zauważyć, że mimo tych losowych skoków w pierwszym momencie klasyfikator obarczony był dużym błędem mierzonym miarą różnicy prognozy i stanu rzeczywistego. Następnie w kolejnym takcie dostosowywał się do nowej sytuacji, stabilizując wartość zapasu na stałym poziomie. Ważnym atutem opracowanej metody jest ciągły proces uczenia z taktu na takt. W miarę napływu nowych zmiennych klasyfikator dostraja swoje parametry. W konsekwencji jest gotowy w przyszłości szybciej zareagować na sytuacje „kryzysowe” zilustrowane na rys. 5.

Rys. 4. Charakterystyka wygenerowanego ciągu uczącego i zdolności predykcji danych rzeczywistych klasyfikatora Fuzzy-Prog i Fuzzy-Prog+dostrojanie



Rys. 5. Charakterystyka wygenerowanego ciągu uczącego i zdolności predykcji danych rzeczywistych klasyfikatora Fuzzy-Prog i Fuzzy-Prog+dostrojanie



4. WYKORZYSTANIE EDI DO WYMIANY INFORMACJI PLANOWANYCH ZAPASÓW W ŁAŃCUCHU DOSTAW

W łańcuchu dostaw zamówienia od odbiorców do dostawców przekazywane mogą być poprzez protokół EDI. Odbiorcy wykorzystać mogą usługę ECOD, której dostawcą jest ComArch. Tą drogą przekazywane mogą być zamówienia, a w najbliższym czasie dostawcy będą przekazywać faktury. Z podstawowej usługi ECODconnector może korzystać bezpłatnie każdy z dostawców. Ta jednak wersja ma ograniczoną funkcjonalność. Można dokumenty oglądać na ekranie poprzez przeglądarkę internetową. Nie jest jednak możliwe przesyłanie dokumentów od dostawców do odbiorcy. Funkcjonalność tę można otrzymać po opłaceniu dodatkowych usług. Dane zgromadzone na tym serwerze byłyby dostępne dla wszystkich podmiotów uczestniczących w tym łańcuchu logistycznym.

Format przekazywanych na serwer dokumentów powinien być zbliżony do formatów stosowanych w serwerach ECOD. Dostawca, planując zapasy, musi uwzględnić prognozy tych zapasów u odbiorców. Klasyfikator taki można zapisać w postaci:

$$\Psi_{k+1}((x_k, \bar{Y}_k)(x_{k-1}, \bar{Y}_{k-1})(x_{k-2}, \bar{Y}_{k-2})S) = Y_{k+1} + G(X), \quad (10)$$

gdzie $G(X)$ jest prognozą zapasów pochodzącą od innych **odbiorców** towarów niż ci opisani dotychczas w ciągu uczącym S danego dostawcy.

Metoda ta jest elastyczna, gdyż w prosty sposób uaktualnia bazę wiedzy o nowych odbiorców łańcucha logistycznego bez konieczności modyfikacji całego modelu planowania zapasów.

5. PODSUMOWANIE

W pracy przedstawiono metodę planowania zapasów opierającą się na miękkich metodach obliczeniowych. Model taki opiera się na rozmytej analizie sekwencji wcześniejszych wielkości zapasów oraz czynników je determinujących, tj. poziomu obsługi klienta, czasu dostawy, itd. Istotną zaletą takiej metody jest jej elastyczność, która objawia się dobrym dostosowywaniem się do zmian charakterystyki zapasów, spowodowanej np. zmiennością rynku. Zastosowane zbiory rozmyte bardzo dobrze radzą sobie z nieprecyzyznością i niepełnością danych oraz stanowią narzędzie operowania danymi narażonymi na różne błędy pomiarowe. Atutem takiego podejścia jest ciągłe uczenie się klasyfikatora, przez co jest on coraz bardziej dokładny, do pewnego punktu zbieżności, którego na tym etapie badań nie ustalono. Zaletą opracowanego modelu jest to, że nie wymaga on pełnej specyfikacji matematycznej modelu, tak jak to jest w metodach statystycznych. W metodach klasycznych do wyznaczenia poziomu zapasów należy znać wzory matematyczne je określające. W przypadku proponowanego przez autorów podejścia nie musimy znać zależności między predyktorami a zapasami. W pracy nie skupiono się na sezonowości, testując algorytm, tylko i wyłącznie uwzględniając sekwencję obserwacji zapasów. Opracowany model z blokiem dostrajania ma tę własność, że utrzymuje poziom zapasu na pewnym poziomie.

Dalsze kierunki badań będą obejmowały opracowanie fuzji klasyfikatorów rozmytych, które będą optymalnie dyskryminowały przestrzeń obserwacji, co w konsekwencji przyczyni się do polepszenia predykcji zapasów. Głównym problemem będzie ustalenie takiej miary, na tyle czułej

na zmiany trendu, aby uzyskane klasyfikatory wykrywały najbardziej podobne cechy trendu, przez co możliwe będzie uzyskanie obrazu różnych charakterystyk tworzących trend. Przykładem takich charakterystyk są np. duży popyt na początku tygodnia na dany towar, który następnie maleje, by pod koniec tygodnia ponownie wzrosnąć, wzrost popytu w konkretnych miesiącach, a w innych ich spadek.

BIBLIOGRAFIA

- [1] Kurzyński M., *Benchmark of Approaches to Sequential Diagnosis*, Artificial Neural Networks in Medicine, Springer Verlag, Berlin, Heidelberg, New York 1998.
- [2] Kurzyński M., *Sequential Classification Via Fuzzy Relations*, Artificial Intelligence and Soft Computing – ICAIS2006, 8th International Conference, Zakopane, Poland, June 2006
- [3] Łęski J., *Zbiory rozmyte i ich interpretacja. Wprowadzenie do teorii możliwości*, Wydawnictwa Politechniki Śląskiej, Gliwice 2001, s. 469-479
- [4] Rutkowska D., Piliński M., Rutkowski L., *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, Wydawnictwo Naukowe PWN, Łódź 1999
- [5] Topolski M., *Komputerowe algorytmy rozpoznawania sekwencyjnego z modelem łączącym teorię ewidencji matematycznej z teorią zbiorów rozmytych*, Praca doktorska, PRE 1/07 Politechnika Wrocławska 2007
- [6] Żolnierek A., *The pat tern recognition alghorithm for controlled Markov chains with learning and additional classifier*, [w]: Advanced simulation of system. Proceedings of the XXVth International Autumn Colloquium. Ed. Jan Stefan [Sv. Hostyn, Czech Republic, September 8-10, 2003.

APPLICATION OF FUZZY SETS TO PLANNING OF CHAIN DELIVERY SUPPLIES

SUMMARY

The article shows supply planning model with using soft methods of calculation. Supplies prediction is rather stochastic process than deterministic one. The changing market demand influences by different factors which can be difficult to predict cause big problems in prognostic procedures. Applying solution based on fuzzy set cause that conclusions based on uncertain or imprecision data gives better solutions than statistics method (in the meaning of proper prognosis). In this work it has been shown sequential model of supply planning, which takes into account some predetermined trajectory of former observations. Very important element of such a model is sensitivity on season changes and big adaptation to new emerged predetermined trend changes. In the following part of the work it has been shown the results of investigations based on experimental data, which tried out efficacy of proposed prognosis (together with estimation error).

Recenzent: dr hab. inż. Andrzej Surowiecki