

ZIÓLKOWSKI Krzysztof¹
 BUJAK Andrzej²

Prognozowanie działalności logistycznej przy wykorzystaniu metod ilościowych

WSTĘP

W ostatnich dwóch dekadach miało miejsce wiele ważnych zmian w rozwoju metod statystycznych i ekonometrycznych. Wraz z rozwojem informatyki metody ilościowe znalazły nowe zastosowanie i zostały zaimplementowane w logistyce, głównie w planowaniu i prognozowaniu potrzeb materiałowych. W zarządzaniu potrzebami materiałowymi szczególnie ważne jest poprawne określenie popytu pierwotnego oraz wtórnego, który to głównie szacowany jest przy pomocy metod ilościowych [24, s.27]. Przez popyt pierwotny należy rozumieć popyt na wyroby i usługi ujawniony na określonym rynku, natomiast popyt wtórny jest to popyt na potrzeby materiałowe, podzespoły, etc. zgłaszany przez dane przedsiębiorstwo w odpowiedzi na zaspokojenie popytu pierwotnego (niezależnego) [7, s. 10].

Prawidłowe oszacowanie popytu pierwotnego jest kluczowe w procesie zarządzania procesami logistycznymi, ponieważ proces decyzyjny zarówno na poziomie operacyjnym jak i strategicznym oddziałuje na realny przepływ dóbr materialnych w sferze zaopatrzenia. Odpowiednie zdefiniowanie popytu niezależnego ułatwia rozwiązać sytuację problemową w przedsiębiorstwie typu „trade offs”, czy też „make or buy”³.

1. METODY SZACOWANIA POPYTU PIERWOTNEGO

Do szacowania popytu pierwotnego można zastosować metody zarówno nie-ilościowe jak i metody ilościowe. Do pierwszej grupy należą: intuicyjne (subiektywne), kolejnych przybliżeń, analogowe, które zostaną omówione w następnej części artykułu. Natomiast za najwłaściwsze metody ustalania popytu niezależnego szczególnie w bliskich horyzontach czasowych uważa się metody statystyczne i ekonometryczne, a szczególnie można do nich zaliczyć metody średniej ruchomej oraz modele tendencji rozwojowej. Wśród modeli adaptacyjnych przede wszystkim zalicza się modele [Chaberek, Jezierski, Mańkowski, Reszka, 2002, s. 10]:

- Browna,
- MA (Moving Average),
- Holta,
- ARIMA (Autoregressive Integrated Moving Average Process),
- Wintera.

Wybór w/w metod prognozowania zależy przede wszystkim od cech jakimi charakteryzuje się określony szereg czasowy (uporządkowany chronologicznie zbiór informacji dotyczących kształtowania się danej zmiennej w czasie). W przypadku szeregów stacjonarnych, lub zbliżonych do stacjonarnych można zastosować następujące metody [25, s. 56-75; 23, parsim]:

- arytmetyczna średnia ruchoma,

¹Wyższa Szkoła Bankowa w Gdańsku, kziolkowski.ek@wp.pl

²Wyższa Szkoła Bankowa we Wrocławiu, Instytut Logistyki, andrzej.bujak@interia.pl

³Sytuacja typu „trade offs”, czyli „coś za coś” została sformułowana w 1844 roku przez francuskiego inżyniera Juliesa Dupuit'a i polega na procesie decyzyjnym poświęcenia jednego dobra na rzecz innego, czy też wymiany jednej grupy kosztów na drugą, np.: wybór środków transportu – czy towary dostarczamy transportem kolejowym czy też samochodowym? Decyzje typu „make or buy” są ściśle związane z koncepcją Lean Management („odchudzania zarządzania”) i starają się odpowiedzieć na pytanie czy dotychczasową działalność prowadzoną w ramach własnej organizacji prowadzić dalej, czy też zlecić firmie zewnętrznej (outsourcing), np. czy prowadzić dostawy przy użyciu własnych samochodów czy też zlecić usługi odpowiedniemu operatorowi [3, s.3].

- średnia ruchoma ważona,
- tzw. prosty model Browna.

Natomiast w przypadku szeregów niestacjonarnych, czyli takich w których występują silne wahania w określonym czasie zaleca się stosowanie następujących metod:

- model Holta,
- model Wintera.

Oprócz wspomnianych metod można też zastosować klasyczny model regresji liniowej szacowany przy pomocy metody najmniejszych kwadratów (MNK) [17, 422].

Przechodząc do analizy i omówienia poszczególnych metod prognozowania popytu pierwotnego należy zacząć od omówienia arytmetycznej średniej ruchomej i jej ogólnej postaci, która przedstawia wzór [20, 2007]:

$$Y_t^* = \frac{1}{k} \sum_{i=t-k}^{t-1} Y_i ,$$

gdzie:

Y_t^* - prognoza w wyznaczonym okresie t,

Y_i - wielkość w okresie t,

k – stała wygładzenia.

Jak już wspomniano na początku przy dużych wahaniami przypadkowych zmiennej Y metody naiwne byłyby obarczone dość dużym błędem, w związku z tym w szeregu czasowym można zastosować metodę opartą na średniej ruchomej. Modele średniej ruchomej mogą być zarówno wykorzystywane do wygładzenia szeregu jak i do prognozowania. Metoda średniej ruchomej polega na „mechanicznym” wyrównaniu szeregu czasowego za pomocą średniej arytmetycznej, która jest obliczana sekwencyjnie dla wybranych kolejno obserwacji.

Przy prognozowaniu za pomocą średniej ruchomej zakłada się, że wartość zmiennej prognozowanej w następnym okresie będzie równa średniej arytmetycznej z k ostatnich wartości średniej.

Poniżej (Przykład 1) zaprezentowano metodę średniej ruchomej 3-elementowej oraz 5-elementowej, warto w tym miejscu wspomnieć, iż wraz ze wzrostem stałej wygładzenia rośnie efekt wyrównania. Ponadto im większa liczba obserwacji wykorzystanych do wygładzenia tym większy efekt wygładzenia.

Przykład 1

Sprzedż odbiorników telewizyjnych przedstawia poniższy szereg⁴. Na podstawie n/w szeregu wyznaczono prognozę w oparciu o średnią 3- i 5-elementową, policzono średni oraz względny błąd prognozy.

⁴Autorzy celowo we wszystkich modelach używają tych samych danych aby ułatwić czytelnikowi porównanie omawianych metod.

Tab. 1. Prognozowanie sprzedaży odbiorników w przedsiębiorstwie „X”. Źródło: opracowanie własne.

t	Y _t	Średnia ruchoma 3- elementowa Y _t [*]	Błąd $\frac{ Y_t - Y_t^* }{Y_t} * 100$	Średnia ruchoma 5- elementowa	Błąd $\frac{ Y_t - Y_t^* }{Y_t} * 100$
1	41				
2	38				
3	39				
4	40	39,33333	1,666667		
5	42	39	7,142857		
6	39	40,33333	3,418803	40	2,564103
7	38	40,33333	6,140351	39,6	4,210526
8	39	39,66667	1,709402	39,6	1,538462
9	41	38,66667	5,691057	39,6	3,414634
10	42	39,33333	6,349206	39,8	5,238095
11	40	40,66667	1,666667	39,8	0,5
12	38	41	7,894737	40	5,263158
13	39	40	2,564103	40	2,564103
14	39	39	0	40	2,564103
15	40	38,66667	3,333333	39,6	1
		39,33333		39,2	
			47,57718		28,85718

W rozpatrywanym przykładzie względny błąd prognozy dla średniej ruchomej 3- i 5-elementowej wynosi odpowiednio:

$$\Psi = \frac{1}{n-k} \sum_{t=n+1}^n \frac{|Y_t - Y_t^*|}{Y_t} * 100;$$

$$\Psi^3 = \frac{1}{n-k} \sum_{t=n+1}^n \frac{|Y_t - Y_t^*|}{Y_t} * 100 = 3,79\%;$$

$$\Psi^5 = \frac{1}{n-k} \sum_{t=n+1}^n \frac{|Y_t - Y_t^*|}{Y_t} * 100 = 2,88\%.$$

Metoda średnich ruchomych prostych ma dwie zasadnicze wady [7, s. 29]:

1. przy większej liczbie danych obliczenia się komplikują – należy pamiętać o uśrednieniu wszystkich danych,
2. metoda powyższa ignoruje efekt starzenia się danych, ponieważ wszystkie dane mimo iż są z różnych okresów czasowych mają tą samą wagę.

Jedną z metod, która usuwa wadę arytmetycznej średniej ruchomej jest budowanie prognoz na podstawie modelu średniej ruchomej ważonej. Najmniejsze błędy prognozy daje średnia z co najmniej 12 obserwacji (zob. tabela 2). We wspomnianej metodzie wraz ze starzeniem się obserwacji ich wagi maleją tworząc ciąg arytmetyczny (zob. rysunek 1).

Ogólną postać średniej ruchomej ważonej przedstawia następujący wzór [15]:

$$Y_t^* = \sum_{i=t-k}^{t-1} Y_i w_{i-t+k+1} ,$$


gdzie:

Y_t^* - prognoza w wyznaczonym okresie t ,

Y_i - wielkość w okresie t ,

k – stała wygładzenia,

$W_{i-t+k+1}$ - waga nadawana przez prognozę wartości zmiennej prognozowanej w okresie t .



Rys. 1. Wartość wag przy średniej ruchomej 3-elementowej oraz średniej ruchomej ważonej 3-elementowej.
Źródło: opracowanie własne.

Dla przykładu nr 1 przyjęto następujące wagi:

I 0,1;

II 0,2;

III 0,7.

Należy wziąć pod uwagę, że wagi powinny się mieścić w przedziale od zera do 1 włącznie, a suma wag powinna wynosić 1.

Tab. 2. Prognozowanie sprzedaży odbiorników w przedsiębiorstwie „X”. Źródło: opracowanie własne.

t	Y	Średnia ruchoma 3-elementowa	Błąd (bezwzględny ex post)	q
1	41			
2	38			
3	39			
4	40	39	1	1
5	42	38,9	3,1	9,61
6	39	39,2	-0,2	0,04
7	38	39,7	-1,7	2,89
8	39	39,3	-0,3	0,09
9	41	38,8	2,2	4,84
10	42	38,9	3,1	9,61
11	40	39,4	0,6	0,36
12	38	39,8	-1,8	3,24
13	39	39,5	-0,5	0,25
14	39	38,9	0,1	0,01
15	40	38,9	1,1	1,21
		39		
				33,15

W rozpatrywanym przykładzie średni kwadratowy błąd prognozy ex post dla średniej ważonej 3-elementowej wynosi odpowiednio:

$$S^* = \frac{1}{n-k} \sum_{t=n+1}^n [(Y_t - Y_t^*)^2]^{\frac{1}{2}} ;$$

$$S^* = \frac{1}{n-k} \sum_{t=n+1}^n [(Y_t - Y_t^*)^2]^{\frac{1}{2}} = 1,66.$$

W przypadku występowania w szeregu czasowym trendu liniowego można do konstrukcji prognozy użyć modelu podwójnej średniej ruchomej. Wygładzony wówczas szereg za pomocą średniej ruchomej ponownie wygładza się wspomnianą metodą (stąd nazwa - model podwójnej średniej ruchomej).

Kolejną propozycją prognozowania zmiennej Y jest metoda wygładzenia wykładniczego, która polega na wygładzeniu szeregu czasowego przy pomocy średniej ruchomej ważonej, jednakże wagi określane według prawa wykładniczego, np. program STATISTICA dysponuje kilkunastoma modelami wygładzenia.

Model Browna jest kolejnym sposobem wykorzystywanym w celu prognozowania popytu pierwotnego. Grecka litera α oznacza parametr wygładzenia wykładniczego z okresu t, który przyjmuje wartości od 0 do 1 włącznie. Kolejne obserwacje z okresów t-1, t-2, ..., t-i są liczbami będącymi kolejnymi wyrazami ciągu geometrycznego o ilorazie $(1-\alpha)$, czyli $\alpha(1-\alpha)$, $\alpha(1-\alpha)^2$, $\alpha(1-\alpha)^3$. Jak widać powyższy ciąg geometryczny i przypisane wagi maleją wraz z poruszaniem się w przeszłość stąd też model Browna jest nazywany modelem wyrównania wykładniczego [5, s. 1-15]. Model Browna zaprezentowany w przykładzie nr 2 ma dwie zalety [7, s. 32]:

1. do prognozowania niezbędne jest pamiętanie tylko jednej informacji z przeszłości,
2. w przeciwieństwie do średniej ruchomej n-elementowej, modelu Browna uwzględniony jest „efekt starzenia się”, tj. coraz starszym danym przypisuje się coraz mniejsze wartości wag.

Wartość parametru α dobierana jest w taki sposób aby wartości błędów prognozy były najmniejsze. α można również dobrać w sposób subiektywny – im większa wartość tego parametru tym większa waga przypisywana jest wartościom bieżącym Y. Wygodnym narzędziem do wyznaczenia wartości α jest moduł Solver z Excela.

Ogólną postać modelu Browna przedstawia następujący wzór [5, s. 15; 4, s. 4] :

$$Y_t^* = \alpha y_{t-1} + (1 - \alpha)y_{t-1}^*,$$

gdzie:

Y_t^* - prognoza w wyznaczonym okresie t,

Y_{t-1} - wielkość w okresie t-1,

α - parametr wygładzenia wykładniczego.

W omawianym przykładzie został obliczony względny błąd prognozy, który jest liczony wg. takiego samego wzoru jak dla średniej ruchomej 3- i 5-elementowej, tj.:

$$\Psi = \frac{1}{n-k} \sum_{t=n+1}^n \frac{|Y_t - Y_t^*|}{Y_t} * 100.$$

Przykład 2.

Tab. 3. Prognozowanie sprzedaży odbiorników w przedsiębiorstwie „X” (model Browna). Źródło: opracowanie własne.

t	Y	F	S	Y - F + S	(Y - F) ²
1	41	41	-3		
2	38	38	-3	38	0
3	39	38,6	-1,56	35	16
4	40	39,704	-0,4944	37,04	8,7616
5	42	41,72096	0,510144	39,2096	7,786332
6	39	39,32311	-0,65305	42,2311	10,44003
7	38	38,06701	-0,89427	38,67006	0,448976
8	39	38,81727	-0,23646	37,17273	3,338909
9	41	40,75808	0,634449	38,58082	5,852452
10	42	41,93925	0,853138	41,39253	0,369019
11	40	40,27924	-0,15212	42,79239	7,797448
12	38	38,21271	-0,91788	40,12712	4,524624
13	39	38,82948	-0,30402	37,29483	2,907615
14	39	38,95255	-0,13319	38,52546	0,225188
15	40	39,88194	0,291843	38,81936	1,393916
				40,17378	
					69,84611

$$\Psi = \frac{1}{n-k} \sum_{t=n+1}^n \frac{|Y_t - Y_t^*|}{Y_t} * 100 = 2,92\% .$$

W przypadku gdy w danym szeregu czasowym występuje trend i wahania przypadkowe można zastosować model Holta. Jest to model dwurównaniowy, w którym do opisu tendencji używa się wielomianu stopnia pierwszego. Model ten jest bardziej elastyczny od modelu Browna ponieważ występują w nim dwa parametry wygładzania: α i β , które można wyznaczyć podobnie jak w modelu Browna za pomocą Solvera z Excela [14].

Do opisu modelu Holta służy następujący układ równań [14]:

$$\begin{aligned} F_{t-1} &= \alpha y_{t-1} + (1 - \alpha)(F_{t-2} + S_{t-2}), \\ S_{t-1} &= \beta(F_{t-1} + F_{t-2}) + (1 - \beta)S_{t-2}, \end{aligned}$$

gdzie:

F_{t-1} - ocena wartości średniej w okresie t-1,

S_{t-1} - przyrostu trendu w okresie t-1,

α, β - parametry modelu o wartościach z przedziału (0,1].

Natomiast równanie prognozy ma następującą postać: $Y_t^* = F_n + (t - n)S_n$.

Poniżej zaprezentowano model Holta (zob. przykład nr 3). W omawianym modelu przyjęto arbitralnie $\alpha = 0,90$ oraz $\beta = 0,40$, przyjęto również, iż $F_1 = Y_1$ a $S_1 = Y_2 - Y_1$.

Przykład 3.

Tab. 4. Prognozowanie sprzedaży odbiorników w przedsiębiorstwie „X” (model Holta). Źródło: opracowanie własne.

			alpha	betha	gamma		
			0,5	0,3	0,4		śr. w 1. okresie 39,5
	t	Y	F	S	C	Y*	S+F
I kw	1	41				41	
II kw	2	38				38	
III kw	3	39				39	
IV kw	4	40				40	
I kw	5	42	39,5	1	25,6		
II kw	6	39	20,75	-4,925	30,1	53,825	40,5
III kw	7	38	7,4125	-7,44875	35,635	38,96375	15,825
IV kw	8	39	-0,51813	-7,59331	39,80725	31,888563	-0,03625
I kw	9	41	3,644281	-4,0666	30,30229	25,177684	-8,11144
II kw	10	42	5,738842	-2,21825	32,56446	33,620593	-0,42232
III kw	11	40	3,942796	-2,09159	35,80388	37,486208	3,520593
IV kw	12	38	0,021979	-2,64036	39,07556	37,188872	1,851208
I kw	13	39	3,039667	-0,94294	32,56551	32,399011	-2,61838
II kw	14	39	4,26613	-0,29212	33,43223	36,538472	2,096724
III kw	15	40	4,085064	-0,25881	35,8483	39,63014	3,974009

Do oceny dopuszczalności prognozy Y posłużono się błędami prognoz wygasłych. Przy pomocy wzoru zaprezentowanego poniżej obliczono wspomnianą dopuszczalność prognozy.

$$S^* = \frac{1}{n-k} \sum_{t=k+1}^n [(Y_t - Y_t^*)^2]^{\frac{1}{2}} = \left(\frac{69,84}{13}\right)^{\frac{1}{2}} = 2,31$$

W przypadku, gdy w szeregu czasowym oprócz wahań trendu występują też wahania sezonowe, najbardziej adekwatnym do ustalenia prognozy zmiennej Y jest model Wintera. Model Wintera może przybrać postać modelu addytywnego (zostanie on zaprezentowany w przykładzie nr 4) lub też modelu multiplikatywnego [22., s. 324 – 342].

Do opisu modelu addytywnego Wintera służy następujący układ równań [12]:

$$F_t = \alpha (Y_t - C_{t-r}) + (1 - \alpha)(F_{t-1} + S_{t-1}),$$

$$S_t = \beta (F_t - F_{t-1}) + (1 - \beta)S_{t-1},$$

$$C_t = \gamma (Y_t - F_t) + (1 - \gamma)C_{t-r}.$$

Natomiast do modelu multiplikatywnego Wintera służą poniższe równania:

$$F_t = \alpha \frac{Y_t}{C_{t-r}} + (1 - \alpha)(F_{t-1} + S_{t-1}),$$

$$S_t = \beta (F_t - F_{t-1}) + (1 - \beta)S_{t-1},$$

$$C_t = \gamma \frac{Y_t}{F_t} (Y_t - F_t) + (1 - \gamma)C_{t-r}.$$

gdzie:

F_t – oszacowanie części stałej szeregu podlegającej wahaniom przypadkowym,

S_t – oszacowanie części przyrostowej szeregu, również podlegającej wahaniom przypadkowym,

C_t – oszacowanie części sezonowej trendu, też nastawionej na działanie czynnika losowego,

Y_t – wartości empiryczne szeregu w okresie t ,

Y_t^* – wartości teoretyczne szeregu wygładzonego.

Stałe wygładzania: $0 \leq \alpha, \beta, \gamma \leq 1$

Dodatkowe oznaczenie: r - liczba sezonów w jednym cyklu.

Prognozę dla modelu Wintera oblicza się w sposób następujący:

Dla modelu addytywnego: $Y_T^* = F_t + (T-t) S_t + C_{t-r}$

Dla modelu multiplikatywnego: $Y_T^* = (F_t + (T-t) S_t) C_{t-r}$

Wartości początkowe F i S można obliczyć wykorzystując średnią ruchomą 3-elementową.

Przykład 4

Tab. 5. Prognozowanie sprzedaży odbiorników w przedsiębiorstwie „X” (addytywny model Wintera). Źródło: opracowanie własne.

			alpha	betha	gamma		
			0,5	0,3	0,4		śr. w 1. okresie 39,5
	t	Y	F	S	C	Y*	S+F
I kw	1	41				41	
II kw	2	38				38	
III kw	3	39				39	
IV kw	4	40				40	
I kw	5	42	39,5	1	25,6		
II kw	6	39	20,75	-4,925	30,1	53,825	40,5
III kw	7	38	7,4125	-7,44875	35,635	38,96375	15,825
IV kw	8	39	-0,51813	-7,59331	39,80725	31,888563	-0,03625
I kw	9	41	3,644281	-4,0666	30,30229	25,177684	-8,11144
II kw	10	42	5,738842	-2,21825	32,56446	33,620593	-0,42232
III kw	11	40	3,942796	-2,09159	35,80388	37,486208	3,520593
IV kw	12	38	0,021979	-2,64036	39,07556	37,188872	1,851208
I kw	13	39	3,039667	-0,94294	32,56551	32,399011	-2,61838
II kw	14	39	4,26613	-0,29212	33,43223	36,538472	2,096724
III kw	15	40	4,085064	-0,25881	35,8483	39,63014	3,974009

Do prognozowania szeregu czasowego z wykorzystaniem metody najmniejszych kwadratów (MNK) można zastosowania dodatek Analiza danych z Excela. Program Excel sam wyliczy prognozę na kolejne (wybrane przez prognostę) kwartały/okresy lecz wcześniej należałoby zastosować w/w metody w celu wygładzenia danych. Aby zastosować MNK w celu prognozowania popytu pierwotnego należałoby wziąć pod uwagę większy przedział czasowy z uwagi na konieczność sięgnięcia do przyczyn wpływających na popyt niezależny [16, parsim; 17, parsim].

2. METODY PLANOWANIA POPYTU WTÓRNEGO

Podstawowym narzędziem planowania popytu wtórnego jest harmonogram produkcji oraz bazy danych o zapasach. Planowanie popytu wtórnego jest wynikiem szacowania popytu pierwotnego zweryfikowanego stanem zapasów, możliwości produkcyjnych, kadrowych, finansowych, etc.

Planowanie potrzeb materiałowych jest podejściem, a jednocześnie systemem komputerowym przeznaczonym do odpowiedniego w czasie planowania zleceń produkcji, tak aby były one dostępne w wymaganych ilościach aby dostarczyć gotowy produkt – zrealizować główny plan produkcji [10]. Proces zaopatrzenia stanowi początek wewnętrznego łańcucha dostaw w przedsiębiorstwie.

Podstawowe problemy zarządzania zapasami materiałowymi obejmują następujące zagadnienia [11]:

1. określenie poziomu zapasów materiałowych, który zapewni ciągłość procesu produkcyjnego przy jednoczesnej minimalizacji kosztów utrzymania zapasów,
2. politykę dostaw, kształtującą strukturę ilościowo-jakościową zapasów, a poprzez ceny materiałów nabywanych z dostępnych źródeł,
3. wybór strategii ustalania zapotrzebowania na materiał oparty o zapotrzebowanie niezależne lub zależne,
4. minimalizowanie kosztów obsługi zapasów, na które wpływają stan zapasów oraz szybkość ich rotacji.

Schemat wykorzystania metody MRP został zaprezentowany na rysunku nr 2.

Struktura wyrobu

Dni	1	2	3	4	5	6	7	8	9	10
Element A				60	30			90	60	45
Element B				20	10			30	20	15
Element C				40	20			60	40	30

Zapotrzebowanie na wyrób finalny – ilości zamówione przez klientów

Dni	1	2	3	4	5	6	7	8	9	10
Zapotrzebowanie brutto na wyrób finalny				20	10			30	20	15

Czas realizacji produkcji – 2 dni, 50 sztuk

Dni	1	2	3	4	5	6	7	8	9	10
Zapotrzebowanie brutto				60	30			90	60	45
Dostępny zasap	40	40	40	90/30	30/0	0	50	100/10	60/0	50/5
Potrzeby netto				20	0	0	0	50	50	45
Zakończenie produkcji (dostawa)				50			50	50	50	50
Rozpoczęcie produkcji (realizacji dostawy)		50			50	50	50	50		

Rys. 2. Metody planowania potrzeb materiałowych. Źródło: [18].

Integralnym działaniem MRP/ERP jest ściśle określenie czasu produkcji oraz realizacji cyklu zamówienia na określony element. Podkreślić należy, iż algorytm wykorzystywany przez powyższe systemy oblicza ilość i czas dla każdego elementu, części, nawet najdrobniejszej, ale niezbędnej do pojawienia się wyrobu finalnego.

WNIOSKI

Obok metod ilościowych wykorzystywanych w logistyce w prognozowaniu popytu rynkowego stosowane są również metody intuicyjne do których można zaliczyć takie metody jak: ekspertów, delficka, „burzy mózgów”, scenariuszy oraz analogii historycznej [8, s. 458 – 467; 9, s. 350-369; 1, s. 108].

We współczesnej ekonomii, w tym i logistyce nie uciekniemy od metod ilościowych oraz coraz to bardziej zaawansowanych programów komputerowych [2, 2000]. Jednakże ekonomii nie można zredukować tylko do jej aspektów ilościowych, ponieważ wielu złożonych procesów, które odgrywają ważną rolę w życiu gospodarczym, nie da się wyrazić za pomocą języka matematyki. Zawsze należy wziąć pod uwagę granice możliwości poznawczych modelu [6, s. 7].

Tym nie mniej, również w owej współczesnej gospodarce światowej bardziej wyrafinowane podejście do procesu prognozowania wymaga stosowania aparatu ilościowego, który niewątpliwie prowadzić będzie do wykorzystywania rozbudowanych modeli przyczynowo-skutkowych na podstawie danych empirycznych, jednakże żadnej teorii ekonomicznej nie można wypracować bez koncepcji abstrakcyjnych, które opierają się na indukcji i dedukcji przy analizowaniu zjawisk ekonomicznych [6, s. 7].

Ta sytuacja powoduje, że mimo ułomności modeli zarówno matematyczno-statystycznych, jak i myślowych, póki co ludzkość nie dysponuje lepszymi narzędziami, które mogą służyć omawianym analizom, a jak to ułomne są metody niech czytelnikowi posłuży wyjaśnienie czym jest prognozowanie: *Forecasting is the art of saying what will happen, and then explaining why it didn't* [13].

Streszczenie

We współczesnej ekonomii, w tym i logistyce nie uciekniemy od metod ilościowych oraz coraz to bardziej zaawansowanych programów komputerowych. Jednakże ekonomii nie można zredukować tylko do jej aspektów ilościowych, ponieważ wielu złożonych procesów, które odgrywają ważną rolę w życiu gospodarczym, nie da się wyrazić za pomocą języka matematyki. Zawsze należy wziąć pod uwagę granice możliwości poznawczych modelu. W niniejszym artykule zaprezentowano podstawowe modele wykorzystywane w logistyce przy prognozowaniu popytu pierwotnego, jak i wtórnego.

Forecasting the logistics activity using quantitative methods

Abstract

In contemporary economy, including the logistics cannot get away from quantitative methods and more and more sophisticated computer programs. However, the economy cannot be reduced only to the quantitative aspects, because many of complex processes that play an important role in the economic life cannot be expressed by using the language of mathematics. Must always be take into consideration limits of what can cognitive model. In this paper presents basic models used in logistics in forecasting demand primary and secondary.

BIBLIOGRAFIA

1. Aaker, David A. (2001), *Strategic Market Management*, John Wiley & Sons , New York.
2. Michalewicz Z., Fogel D. B. (2000), *How To Solve It: Modern Heuristics*, Springer Verlag Berlin-Heidelberg.
3. Ballou R. H. (1992), *Business Logistics management*, Prentice Hall, Inc., Englewood Cliffs, New Jersey.

4. Brown, Robert Goodell (1963), *Smoothing Forecasting and Prediction of Discrete Time Series*, Prentice-Hall Englewood Cliffs, New York.
5. Brown, Robert G. (1956), *Exponential Smoothing for Predicting Demand*, Arthur D. Little Inc., Cambridge, Massachusetts.
6. Bogdanienko J. (2009), Rozważania nad rolą modelowania w prognozowaniu ekonomicznym, [w:] *Problemy zarządzania*, vol. 7, nr 4 (26), Wydział Zarządzania UW, Warszawa.
7. Chaberek M., Jezierski A., Mańkowski C., Reszka L. (2002), *Rachunek decyzyjny w logistyce zaopatrzenia*, Gdańska Wyższa Szkoła Humanistyczna, Gdańsk.
8. Dalkey N., Helmer O. (1963), *An Experimental Application of the Delphi Method to the use of experts*. *Management Science*, 9(3), Santa Monica, California.
9. Gallupe, R. B., Dennis, A. R., Cooper, W. H., Valacich, J. S., Bastianutti, L. M. and Nunamaker, J. F. (1992), *Electronic Brainstorming and Group Size*, *Academy of Management Journal*, Vol. 35, No. 2, New York.
10. http://www.ioz.pwr.wroc.pl/pracownicy/rudnicki/default_pliki/MRP.pdf.
11. <http://erp.rekord.com.pl/erp-artykuly/909-erp-white-paper/791-planowanie-potrzeb-materialowych-optimalizacja-zaopatrzenia-i-zapasz-materialowych>.
12. <http://janek.ae.krakow.pl/~czubekh/PiS/przyklady/model%20wintersa.ppt>.
13. <http://www1.secam.ex.ac.uk/famous-forecasting-quotes.dhtml>.
14. Holt, Charles C. (1957), *Forecasting Trends and Seasonal by Exponentially Weighted Averages*, *Office of Naval Research Memorandum 52*. reprinted in Holt, Charles C. (January–March 2004), *Forecasting Trends and Seasonal by Exponentially Weighted Averages*, *International Journal of Forecasting* 20 (1).
15. Kreiß Jens-Peter, Neuhaus G. (2006), *Einführung in die Zeitreihenanalyse*, Springer, Berlin-Heidelberg.
16. Lynwood A. Johnson Douglas C. Montgomery and John S. Gardiner (1990), *Forecasting and Time Series Analysis*, McGraw-Hill, Inc. New York.
17. Maddala G. S. (2006), *Ekonometria*, Wyd. naukowe PWN, Warszawa.
18. Połoz W., *Planowanie potrzeb materiałowych*, www.logistyka-produkcji.pl, (11.12.2013).
19. Prajakta S. Kalekar (Bombay), *Time series Forecasting using Holt-Winters Exponential Smoothing*, Kanwal Rekhi School of Information Technology, Bombay.
20. Proakis J. G., Manolakis D. G., (2006), *Digital Signal Processing*, Prentice Hall, New York.
21. Kreiß Jens-Peter, Neuhaus G. (2006), *Einführung in die Zeitreihenanalyse*, Springer, Berlin-Heidelberg.
22. Winters, P. R. (1960), *Forecasting Sales by Exponentially Weighted Moving Averages*, *Management Science* 6 (3).
23. Wolski Z. S. (1997), *Ilościowe metody zarządzania logistycznego w przedsiębiorstwie*, Toruńska Szkoła Zarządzania, Toruń.
24. Wolski Z. S. (1998), *Strategia zarządzania zaopatrzeniem*, Wyd. Placet, Warszawa.
25. Wolski Z. S. (2000), *Sterowanie zapasami w przedsiębiorstwie*, Warszawa.