

INNE ZASTOSOWANIA RYZYKA

Mariusz Doszyń
Krzysztof Dmytrów
Uniwersytet Szczeciński

PORÓWNYWANIE EFEKTYWNOŚCI PROGNOZ EX POST WIELKOŚCI SPRZEDAŻY W PEWNYM PRZEDSIĘBIORSTWIE WYZNACZONYCH ZA POMOCĄ ROZKŁADU GAMMA I MODELI Z WAHANIAMI SEZONOWYMI

Wstęp

Gospodarowanie zapasami i zakupami produktów jest istotnym z punktu widzenia kosztów elementem zarządzania przedsiębiorstwem. Ma ono istotne znaczenie zarówno w przypadku przedsiębiorstwa produkcyjnego, w którym zapasy materiałów, surowców czy półproduktów zapewniają ciągłość procesu produkcyjnego, jak i dla przedsiębiorstwa zajmującego się dystrybucją produktów końcowych. Tutaj zapasy zapewniają pokrycie zapotrzebowania zgłaszanego przez klientów. W pierwszym przypadku popyt na zapasy produkcyjne jest popytem zależnym (zależy on od popytu na produkty końcowe, na podstawie którego ustala się popyt na materiały, surowce czy półprodukty). W drugim przypadku mamy do czynienia z zapasami dystrybucyjnymi. Popyt na nie jest popytem niezależnym. Prognozuje się go za pomocą znanych metod, np. metod analizy szeregów czasowych czy prognozowania na podstawie rozkładów (empirycznych lub teoretycznych).

W klasycznym modelu zapasów należy odpowiedzieć na pytanie: jak często i ile należy zamawiać, żeby zaspokoić w danym stopniu zapotrzebowanie zgła-

szane na produkty [zob. Sarjusz-Wolski 2000]. Zakładamy, że znamy wartości jednostkowych kosztów magazynowania oraz niedoborów produktów, znamy także koszty złożenia i realizacji pojedynczego zamówienia. Znajomość tych kosztów ma bardzo istotne znaczenie, ponieważ uzupełniając zapasy, możemy albo zamawiać częściej mniejsze partie, albo zamawiać rzadziej większe partie. W pierwszym przypadku ponosimy niższe koszty magazynowania (ponieważ mamy mniejsze zapasy), za to ponosimy wyższe koszty zamawiania (bo zamawiamy częściej). W drugim zaś przypadku mamy sytuację odwrotną – ponosimy niższe koszty zamawiania (ponieważ realizujemy je rzadziej), za to godzimy się na wyższe koszty magazynowania. Znajomość kosztów pozwala nam wyznaczyć optymalną wielkość zamawiania, przy której łączne koszty będą minimalne.

W badanym przedsiębiorstwie jednak nie można zastosować klasycznego podejścia w celu wyznaczenia optymalnej wielkości zamówienia za pomocą któregoś ze znanych modeli gospodarowania zapasami. Jest to spowodowane specyfiką działania niniejszej firmy. Jest ona jednym z oddziałów dużego przedsiębiorstwa i zajmuje się dystrybucją produktów sprowadzanych z centrali. Centrala, chcąc ujednoczyć system uzupełniania zapasów, zdecydowała, że oddziały mają składać zamówienia uzupełniające co pięć tygodni i w każdym zamówieniu zamawiać wszystkie produkty, których zapasy wymagają uzupełnienia.

Z powyższych powodów kluczowym elementem efektywnego gospodarowania zapasami w badanym przedsiębiorstwie jest prawidłowe wyznaczenie przyszłego, pięcioletniego poziomu sprzedaży. Brane są tutaj pod uwagę różne kryteria. Przede wszystkim należy dążyć do w miarę pełnego zaspokojenia zapotrzebowania zgłaszanego na produkty przez odbiorców, przy jednoczesnym kontrolowaniu poziomu zapasów. W analizowanym przedsiębiorstwie, z ofertą składającą się z wielu produktów, pojawia się konieczność tworzenia systemu prognoz pozwalających na przewidywanie przyszłej sprzedaży. Większość ilościowych metod prognostycznych bazuje na, znanych z literatury, ekonometrycznych metodach analizy szeregów czasowych, jednak metody te nie zawsze dają zadowalające rezultaty, dlatego w analizowanym przypadku postanowiono porównać wyniki prognozowania za pomocą jednej z metod analizy szeregów czasowych z wynikami prognozowania na podstawie rozkładów.

1. Opis zastosowanych metod i procedur

Przeprowadzone badanie dotyczy efektywności prognoz *ex post* wyznaczonych dla okresów 5-tygodniowych. Przyjęcie takiego horyzontu prognozy jest

związane z długością cyklu składania zamówień. Wykorzystane informacje statystyczne dotyczą przedsiębiorstwa, w którego asortymencie znajduje się ponad 10 000 produktów. Obserwacje odnoszą się do tygodniowych wielkości sprzedaży poszczególnych produktów. Okres objęty analizą obejmuje 210 tygodni (ostatni tydzień, z którego pochodzą dane, to 3-10 II 2013 r.). Długość poszczególnych szeregów czasowych jest często różna. Jest to związane z ciągłymi zmianami asortymentu. Są wprowadzane nowe produkty, z kolei produkty, na które nie jest zgłaszany popyt, są wycofywane. Wyznaczane prognozy dotyczą produktów aktualnie dostępnych w asortymencie. Dane nie są zagregowane, ukazują sprzedaż każdego z produktów, w związku z czym często bardzo trudno doszukać się jednoznacznych prawidłowości w zakresie kształtowania się wielkości sprzedaży w czasie.

W pierwszym etapie badania zostały wyselekcjonowane te produkty, w przypadku których odpowiednie testy statystyczne wskazywały na występowanie istotnych statystycznie wahań sezonowych oraz na zgodność empirycznego rozkładu wielkości sprzedaży z rozkładem gamma*. Powodem wyboru liniowego modelu trendu ze stałą sezonowością była po pierwsze prostota obliczeń i interpretacji modelu, a po drugie dla danych tygodniowych branie pod uwagę dodatkowo zmiennej sezonowości spowodowałoby prawie dwukrotne zwiększenie liczby szacowanych parametrów, a co za tym idzie, zmniejszenie liczby stopni swobody, co nawet przy dużej liczbie obserwacji (210) znacznie pogorszyłoby własności analityczne i prognostyczne modeli. Z kolei powodem wyboru rozkładu gamma był fakt, iż jest to najczęściej występujący w praktyce rozkład zapotrzebowania [zob. Całczyński 2000]. Nawet gdyby rozkład zapotrzebowania nie był znany, to ze względu na swoją uniwersalność zastosowanie rozkładu gamma byłoby uzasadnione [zob. Tadikamalla 1984]. Jest to spowodowane kilkoma czynnikami. W bardzo wielu przypadkach występuje duża liczba okresów, w których nie występowało zapotrzebowanie na produkty oraz relatywnie rzadko zdarzały się okresy, w których zapotrzebowanie było bardzo wysokie (w odniesieniu np. do mediany). Rozkłady charakteryzowały się więc w większości przypadków skrajną asymetrią prawostronną, a co za tym idzie, bardzo dużą zmiennością (ze współczynnikami zmienności wynoszącymi nawet powyżej 1000%). Po przyjęciu poziomu istotności $\alpha = 0,1$ w przypadku 72 produktów wielkość sprzedaży wykazywała istotne wahania sezonowe, a rozkłady wielkości sprzedaży były zgodne z rozkładem gamma.

* Wszystkie obliczenia zostały wykonane z wykorzystaniem skryptów napisanych w języku *hansl*, który jest dostępny w pakiecie do obliczeń ekonometrycznych *Gretl*.

Wśród analizowanych produktów bardzo zróżnicowana była częstość zamówień, rozumiana jako udział tygodni z niezerowymi zamówieniami w liczbie tygodni, w których produkt był oferowany do sprzedaży. Znaczna część produktów była zamawiana bardzo rzadko, w wielu przypadkach dominowały pojedyncze zamówienia. Test na występowanie wahań sezonowych oraz na zgodność rozkładu zamówień z rozkładem gamma był stosowany tylko do tych produktów, w przypadku których częstość zamówień była większa od 0,5, czyli zamówienia były składane średnio częściej niż co dwa tygodnie. Jeżeli zamówienia były składane rzadziej, wówczas stosowano inne metody prognozowania sprzedaży, w której wykorzystywano zarówno poziom zamówień niezerowych, jak i średnie odstępy pomiędzy nimi.

Model ze zmiennymi sztucznymi, w którym uwzględnia się wahania tygodniowe, można zapisać następująco:

$$y_t = \alpha_0 + \alpha_1 t + \sum_{i=1}^{51} d_i Q_{it} + u_t \quad (1)$$

gdzie:

y_t – wielkość sprzedaży w tygodniu t ,

α_0, α_1, d_i ($i = 1, \dots, 51$) – parametry modelu,

t – zmienna czasowa,

Q_{it} – tygodniowe zmienne zero-jedynkowe,

u_t – składnik losowy.

Model (1) jest szacowany przy założeniu, że $\sum_{i=1}^{52} d_i = 0$. Zmienna $Q_{it}=1$ w i -tym tygodniu oraz zero w pozostałych tygodniach (poza 52). Zmienna Q_{it} dla ostatniego podokresu (52 tydzień) jest pomijana, a wartość pozostałych zmiennych sztucznych w tym podokresie jest równa -1 . Odchylenie dla ostatniego podokresu można wyznaczyć ze wzoru: $d_{52} = -\sum_{i=1}^{51} d_i$. W modelu (1) założono liniową funkcję trendu, aby uwzględnić ewentualne systematyczne zmiany poziomu zamówień, choć analiza wyselekcjonowanych szeregów czasowych wskazuje na to, iż wielkości zamówień oscylowały zazwyczaj wokół pewnego stałego poziomu.

Test na istotność wahań sezonowych bazuje na rozkładzie F -Fishera-Snedecora, w którym bada się łączną istotność wpływu sztucznych (tygodniowych) zmiennych zero-jedynkowych:

$$F = \frac{(SSR_r - SSR_u)/j}{SSR_u/df_u} \quad (2)$$

gdzie:

SSR_r – suma kwadratów reszt w modelu z restrykcjami (w modelu bez zmiennych zero-jedynkowych, w którym nie uwzględnia się wahań sezonowych),

SSR_u – suma kwadratów reszt w modelu bez restrykcji (w modelu ze zmiennymi zero-jedynkowymi, w którym uwzględnia się wahania sezonowe),

j – liczba restrykcji,

df_u – liczba stopni swobody w modelu bez restrykcji.

Prognozy były wyznaczane również na poziomie mediany obliczanej na podstawie funkcji gęstości rozkładu gamma:

$$f(y; \lambda, \eta) = \frac{\lambda^\eta}{\Gamma(\eta)} y^{\eta-1} e^{-\lambda y}, y \geq 0, \lambda > 0, \eta > 0 \quad (3)$$

gdzie $y \geq 0, \lambda > 0, \eta > 0$.

Parametry kształtu (λ) oraz skali (η) są równe odpowiednio:

$$\lambda = \frac{\bar{y}^2}{S^2(y)} \quad (4)$$

$$\eta = \frac{S^2(y)}{\bar{y}} \quad (5)$$


Hipoteza o zgodności rozkładu wielkości zamówień z rozkładem gamma była weryfikowana na podstawie nieparametrycznego testu Locke'a, w którym przyjmuje się, iż parametry rozkładu nie są znane [Locke 1976; Shapiro, Chen 2001]. Test ten odwołuje się do następującej zasady: jeżeli zmienne X i Y są niezależne, to zmienne X/Y i $X+Y$ są niezależne wtedy, gdy mają rozkład gamma [Locke 1976]. Test Locke'a może być stosowany wtedy, gdy parametry rozkładu nie są znane, ponieważ powyższa własność cechuje wszelkiego typu rozkłady gamma.

W teście tym próba jest dzielona losowo na dwie podpróby o takiej samej liczebności n . Jeśli liczba obserwacji jest nieparzysta, jedna z nich jest losowo pomijana, co może się przyczyniać do tego, że kolejne zastosowania tego testu mogą prowadzić do nieznacznie różniących się wyników. W kolejnym etapie są tworzone pary następujących zmiennych: $U_i = X_{2i-1} + X_{2i}$; $V_i = \max\left\{\frac{X_{2i-1}}{X_{2i}}, \frac{X_{2i}}{X_{2i-1}}\right\}$. Niezależność zmiennych U_i i V_i bada się na podstawie korelacji rang Kendalla. Szczegółowy opis całej procedury zawiera artykuł Locke'a [1976].

Test Locke'a był stosowany wtedy, gdy liczba obserwacji była większa od 30, a częstość tygodniowa sprzedaży (rozumiana jako udział tygodni z dodatnią wielkością sprzedaży) przekraczała 0,5. W przypadku wyników uzyskanych po


zastosowaniu testu Locke'a można stwierdzić, iż hipotezy o zgodności rozkładu wielkości zamówień z rozkładem gamma nie można było odrzucić w przypadku 343 produktów (poziom istotności 0,1)*.

Rozkłady wielkości zamówień przykładowych produktów przedstawiono na rys. 1-4.



Rys. 1. Rozkład wielkości zamówień produktu a


Źródło: Opracowanie własne.



Rys. 2. Rozkład wielkości zamówień produktu b


Źródło: Opracowanie własne.

* Szczegółowe wyniki nie zostały tu zamieszczone ze względu na ich dużą objętość.



Rys. 3. Rozkład wielkości zamówień produktu c

Źródło: Opracowanie własne.




Rys. 4. Rozkład wielkości zamówień produktu d

Źródło: Opracowanie własne.

2. Charakterystyka otrzymanych prognoz


Prognozy wielkości sprzedaży na kolejnych 5 tygodni zostały wyznaczone dla 72 produktów zarówno z wykorzystaniem modelu z wahaniami sezonowymi, jak i na podstawie rozkładu gamma. Tylko w przypadku 72 produktów test F wskazywał na istotność wahań sezonowych, a test Locke'a na zgodność rozkładu empirycznego z rozkładem gamma. Szeregi czasowe skrócono o 5 ostatnich tygodni. Na

podstawie wcześniejszych obserwacji dokonano prognoz na 5 tygodni, po czym porównano prognozy z rzeczywistymi wartościami sprzedaży w tych tygodniach. W przypadku rozkładu gamma za prognozę była przyjmowana mediana wyznaczona dla otrzymanej funkcji gęstości. Można zadać pytanie, dlaczego przyjęto właśnie ten poziom kwantyla. Powodów było kilka. Po pierwsze – w toku prowadzonych badań i dokonywanych symulacji stwierdzono, że właśnie ten poziom kwantyla daje średnio najmniejsze wielkości błędów prognoz. Po drugie – mimo że w wielu przypadkach poziom prognoz na poziomie mediany może być zaniżony, to jednak w wielu przypadkach zamówienia nie występują w każdym tygodniu (a prognozę na podstawie rozkładu gamma uzyskujemy na każdy tydzień). Przykładowe prognozy wraz z wielkościami zamówień w ostatnich 104 tygodniach wyznaczone za pomocą każdej z metod przedstawiają rys. 1-4.




Rys. 5. Dynamika wielkości zamówień produktu a wraz z prognozami wyznaczonymi na podstawie modelu z wahaniami sezonowymi oraz rozkładu gamma

Źródło: Opracowanie własne.



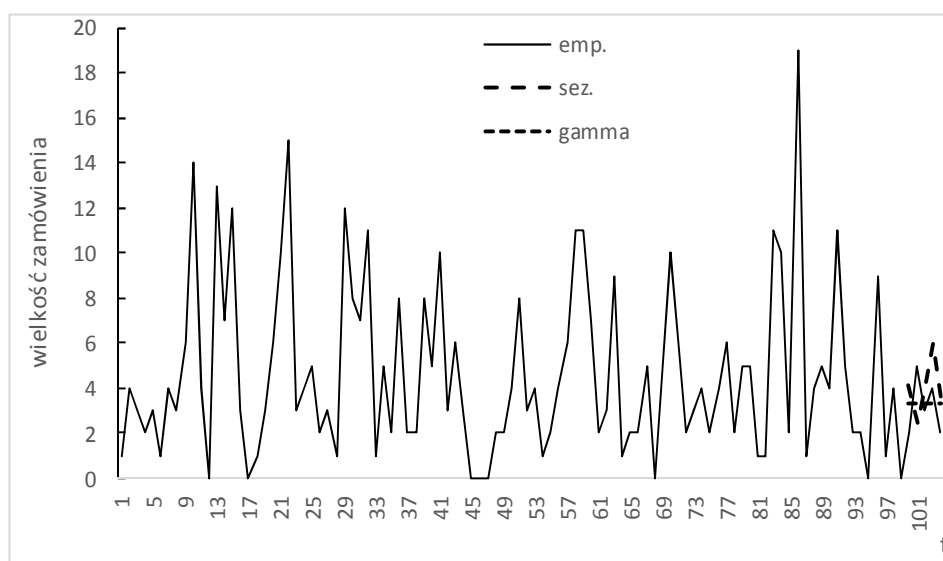
Rys. 6. Dynamika wielkości zamówień produktu *b* wraz z prognozami wyznaczonymi na podstawie modelu z wahaniami sezonowymi oraz rozkładu gamma

Źródło: Opracowanie własne.



Rys. 7. Dynamika wielkości zamówień produktu *c* wraz z prognozami wyznaczonymi na podstawie modelu z wahaniami sezonowymi oraz rozkładu gamma

Źródło: Opracowanie własne.



Rys. 8. Dynamika wielkości zamówień produktu d wraz z prognozami wyznaczonymi na podstawie modelu z wahaniami sezonowymi oraz rozkładu gamma

Źródło: Opracowanie własne.

Analizowane szeregi czasowe charakteryzowały się dość znaczną zmiennością. Współczynnik zmienności oscylował w przedziale 55%-281%. Wartości wybranych kryteriów charakteryzujących oszacowane modele z wahaniami sezonowymi przedstawiono w tabeli 1.

Tabela 1

Wybrane charakterystyki modeli z wahaniami sezonowymi

Kryterium	V_{s_e}	R^2	AIC	BIC	HQC
Min	0,21	0,3164	43,84	149,26	84,50
Max	2,28	0,9998	3166,70	3342,82	3237,94

Źródło: Opracowanie własne.

Dopasowanie modeli do wartości empirycznych było zróżnicowane, co potwierdzają wartości współczynnika determinacji zawierające się w przedziale 31,64%-99,98%. Dość zróżnicowane wartości przyjmował również współczynnik zmienności losowej (21%-228%). Kryteria informacyjne AIC , BIC i HQC przyjmowały wartości dodatnie w zróżnicowanym zakresie.

Dokładność prognoz zbadano za pomocą dwóch wielkości. Pierwszą z nich był względny błąd prognoz wyznaczony jako pierwiastek współczynnika zbieżności Theila:

$$I = \sqrt{\frac{\sum_{T=1}^r (y_T - y_{pT})^2}{\sum_{T=1}^r y_T^2}} \quad (6)$$

gdzie:

y_T – rzeczywista wielkość sprzedaży,

y_{pT} – prognoza wielkości sprzedaży,

T – okres prognozowany,

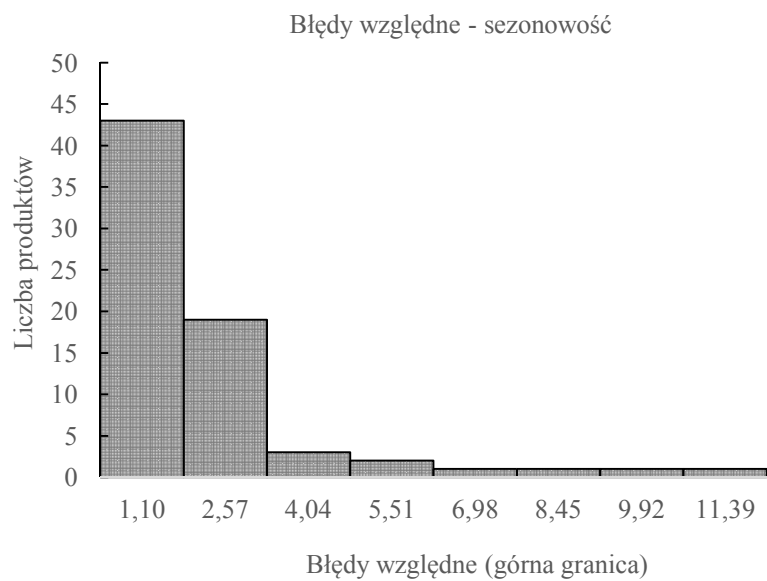
r – liczba okresów, na które jest dokonywana prognoza.

Drugą miarą była relacja sumy prognoz do sumy wielkości rzeczywistych. Współczynnik ten liczy się na podstawie wzoru:

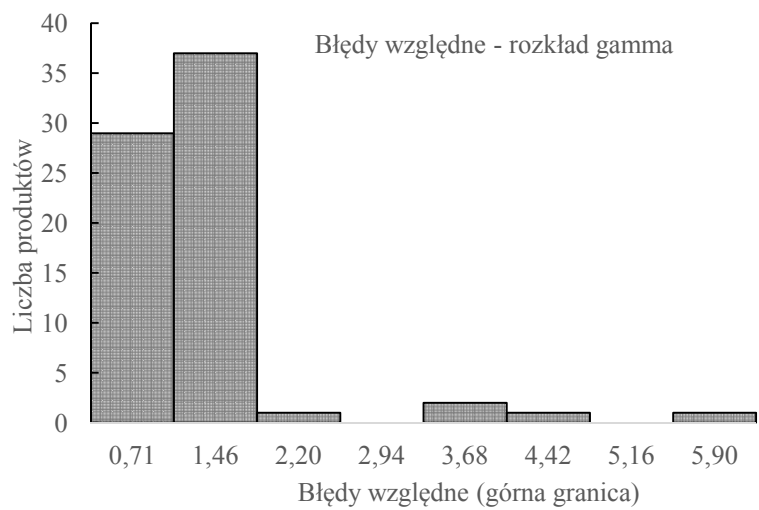
$$R = \frac{\sum_{T=1}^r y_{pT}}{\sum_{T=1}^r y_T} \quad (7)$$

gdzie oznaczenia są takie same, jak we wzorze (6).

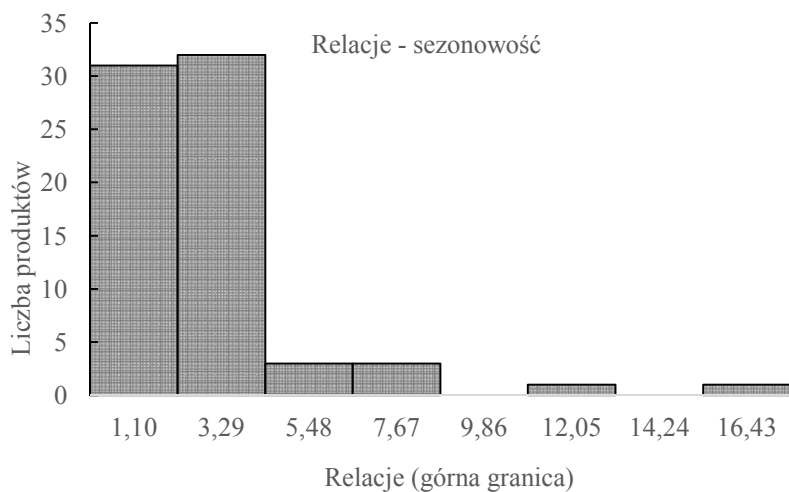
W przypadku badanej firmy była to ważniejsza miara dokładności prognoz. Przyczyną tego jest fakt, iż firmie nie zależało specjalnie, aby dokładnie przewidzieć wielkość sprzedaży w każdym tygodniu, tylko żeby przewidzieć zapotrzebowanie na 5 tygodni, gdyż na taki okres było składane zamówienie uzupełniające. Jeżeli chodzi o względny błąd prognoz, to oczywiście jest pożądana jak najmniejsza wartość tego błędu. Jeżeli z kolei chodzi o relacje sumy prognoz do sumy wielkości rzeczywistych, to najbardziej pożądaną wielkością tego błędu jest jedność. Oznaczałoby to, że idealnie przewidzieliśmy wielkość sprzedaży w prognozowanych pięciu tygodniach. Dla wszystkich 72 produktów obliczono oba rodzaje błędów zarówno dla prognoz uzyskanych za pomocą modeli z sezonowością, jak i dla prognoz uzyskanych za pomocą rozkładu gamma. Następnie zbadano rozkłady tych błędów. Przedstawiają je rys. 9-12.



Rys. 9. Rozkłady błędów względnych prognoz uzyskanych dla modeli z sezonowością
 Źródło: Opracowanie własne.

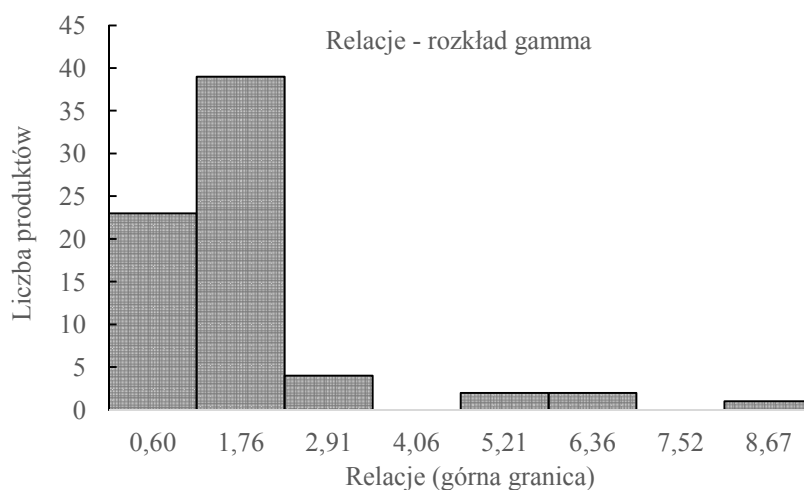


Rys. 10. Rozkłady błędów względnych prognoz uzyskanych dla rozkładu gamma
 Źródło: Opracowanie własne.



Rys. 11. Rozkłady błędów prognoz uzyskanych dla modeli z sezonowością

Źródło: Opracowanie własne.



Rys. 12. Rozkłady błędów prognoz uzyskanych dla rozkładu gamma

Źródło: Opracowanie własne.

Jeżeli zbadamy rozkłady błędów prognoz, to widać, że w każdym przypadku posiadały one silną asymetrię prawostronną (dla błędów względnych była to skrajna asymetria prawostronna). Świadczy to o tym, że dominowały mniejsze wielkości błędów. Podstawowe pozycyjne statystyki opisowe struktury błędów prognoz przedstawia tabela 2.

Tabela 2

Podstawowe (pozycyjne) statystyki opisowe struktury błędów prognoz

Miary	Błędy względne – sezonowość	Błędy względne – rozkład gamma	Relacje – sezonowość	Relacje – rozkład gamma
x_{min}	0,367	0,344	0,000	0,028
x_{max}	10,654	5,531	15,333	8,093
Mediana	1,000	0,777	1,352	0,827
Kwartyl pierwszy	0,746	0,585	0,732	0,313
Kwartyl trzeci	1,433	0,940	2,179	1,265
Odchylenie éwiartkowe	0,344	0,178	0,723	0,476
Współczynnik zmienności	34,35%	22,85%	53,51%	57,58%
Współczynnik asymetrii	0,261	-0,080	0,143	-0,079
Współczynnik spłaszczenia	0,121	0,253	0,178	0,227

Źródło: Opracowanie własne.

Jeżeli zbadamy strukturę względnych błędów prognoz, to widać, że nie jest ona zbyt korzystna. W przypadku modeli z sezonowością minimalny poziom tego błędu wyniósł ponad 36%, czyli prognozując, pomyliliśmy się średnio o ponad 36%. Jeżeli chodzi o maksymalny jego poziom, to wyniósł on aż ponad 1000%. W połowie przypadków prognozując na podstawie modeli z sezonowością pomyłono się o nie więcej niż 100%. Rozkład błędów w zawężonym obszarze zmienności posiadał znaczną zmienność oraz wyraźną asymetrię prawostronną, był też wysmukły. Nieco lepiej przedstawiały się błędy względne prognoz uzyskanych za pomocą rozkładu gamma. Minimalny ich poziom wyniósł ponad 34%, a maksymalny – ponad 500%. W połowie przypadków nie przekroczył on 78%. Zmienność rozkładu względnego błędu prognozy była znaczna, natomiast asymetria w zawężonym obszarze zmienności praktycznie nie występowała.

Analizując relacje sumy prognoz do sumy wartości rzeczywistych, można zauważyć, że prognozy były znacznie lepsze, niż wynikałoby to ze względnych błędów prognoz. W przypadku sezonowości w połowie przypadków suma prognoz w stosunku do sumy wielkości rzeczywistych nie była większa niż 35%. Analizując pozostałe kwartale, widać, że w przypadku pierwszych 25% produktów stosunek sumy prognoz do sumy wielkości rzeczywistych nie przekroczył 73%, a ostatnie 25% produktów posiadało tę relację na poziomie wyższym niż 218%. Rozkład relacji posiadał bardzo dużą zmienność (na poziomie przekraczającym 53%), niewielką asymetrię prawostronną oraz był wysmukły. Lepiej prezentowały się relacje sumy prognoz do sumy wielkości rzeczywistych dla prognoz uzyskanych na podstawie rozkładu gamma. Dla pierwszej połowy pro-

duktów relacja ta nie przekroczyła 83%, czyli prognozy były zaniżone. Pierwsze 25% produktów posiadało tę wartość nie większą niż 31%, a ostatnie 25% – powyżej 126,5%. Podobnie jak w przypadku sezonowości, zmienność rozkładu błędów była bardzo duża, asymetria w zawężonym obszarze zmienności praktycznie nie występowała oraz rozkład był wysmukły.

Jak widać z powyższych wyników, nie jest łatwo prognozować wielkość sprzedaży produktów przy takim kształtowaniu się jej w czasie – występowanie bardzo dużych wahań (czyli dużej zmienności), spora liczba okresów, w których nie występowały zamówienia. Widać także, że w takim przypadku prognozowanie na podstawie rozkładu gamma daje lepsze wyniki, niż stosowanie modeli trendu z wahaniami sezonowymi. Zarówno względne błędy prognoz, jak i relacje sumy prognoz do sumy wielkości rzeczywistych były bardziej korzystne dla rozkładu gamma.

Wnioski

W artykule porównano wyniki prognozowania wielkości sprzedaży na podstawie modeli z sezonowością oraz na podstawie rozkładu gamma. W badaniu wykorzystano rzeczywiste dane dotyczące ponad 10 tys. produktów, z których wyselekcjonowano 72. Ich sprzedaż można było prognozować za pomocą obu zaprezentowanych metod. Otrzymane wyniki wskazują, że lepsze prognozy uzyskano za pomocą rozkładu gamma. Oba rodzaje błędów potwierdziły mniejszą rozbieżność otrzymanych prognoz w porównaniu z rzeczywistymi wielkościami sprzedaży. Bardzo duża zmienność zamówień na poszczególne produkty oraz brak jednoznacznych prawidłowości powodują, że trudno jest zbudować modele tendencji rozwojowych z wahaniami sezonowymi o pożądanych własnościach prognostycznych.

Należy również zauważyć, że w badanym przedsiębiorstwie najwięcej produktów było zamawianych rzadziej niż co drugi tydzień, w związku z czym zastosowanie rozkładu gamma mogłoby nie dawać zbyt dobrych wyników (suma prognoz mogłaby być zawyżona, ponieważ otrzymano by je na każdy tydzień, a rzeczywista sprzedaż wystąpiłaby znacznie rzadziej). Dlatego dalszym etapem badań będzie badanie prognoz sprzedaży produktów, których sprzedaż występuje rzadko, maksymalnie co dwa tygodnie.

Bibliografia

- Całczyński A. (red.), 2000: Elementy badań operacyjnych w zarządzaniu. Tom 1. Radom.
- Czerwiński Z., Guzik B., 1980: Prognozowanie ekonometryczne. PWE, Warszawa.
- Dittman P., 2004: Prognozowanie w przedsiębiorstwie. Oficyna Ekonomiczna, Kraków.
- Locke C., 1976: A Test for the Composite Hypothesis that Population Has a Gamma Distribution. „Communications in Statistics”, 4, s. 351-364.
- Sarjusz-Wolski Z., 2000: Sterowanie zapasami w przedsiębiorstwie. PWE, Warszawa.
- Shapiro S.S., Chen L., 2001: Composite Test for the Gamma Distribution. „Journal of Quality Technology”, Vol. 33, No. 1, s. 47-59.
- Tadikamalla P.R., 1984: A Comparison of Several Approximations to the Lead Time Demand Distribution. „International Journal of Management Science”, Vol. 12, No. 6, s. 575-581.
- Zeliaś A., 1997: Teoria prognozy. PWE, Warszawa.

COMPARING THE EFFECTIVENESS OF EX POST FORECASTS OF SALES IN A COMPANY OBTAINED BY MEANS OF GAMMA DISTRIBUTION AND MODELS WITH SEASONAL ADJUSTMENTS

Summary

Main aim of the article was comparison of sales forecasts effectiveness in a company. In the first stage time series representing sales were selected with respect to presence of seasonality and consistency with gamma distribution. Two types of statistical tests were used: F test (seasonality) and nonparametric Locke tests (compatibility with gamma distribution). In the next step *ex post* forecast were computed by means of linear trend model with seasonality and gamma distribution (on the level of median of theoretical distribution). Effectiveness of forecasts was compared on the basis of chosen coefficients of forecasts errors. Forecasts obtained by means of gamma distribution turned out to be better in all considered aspects.