

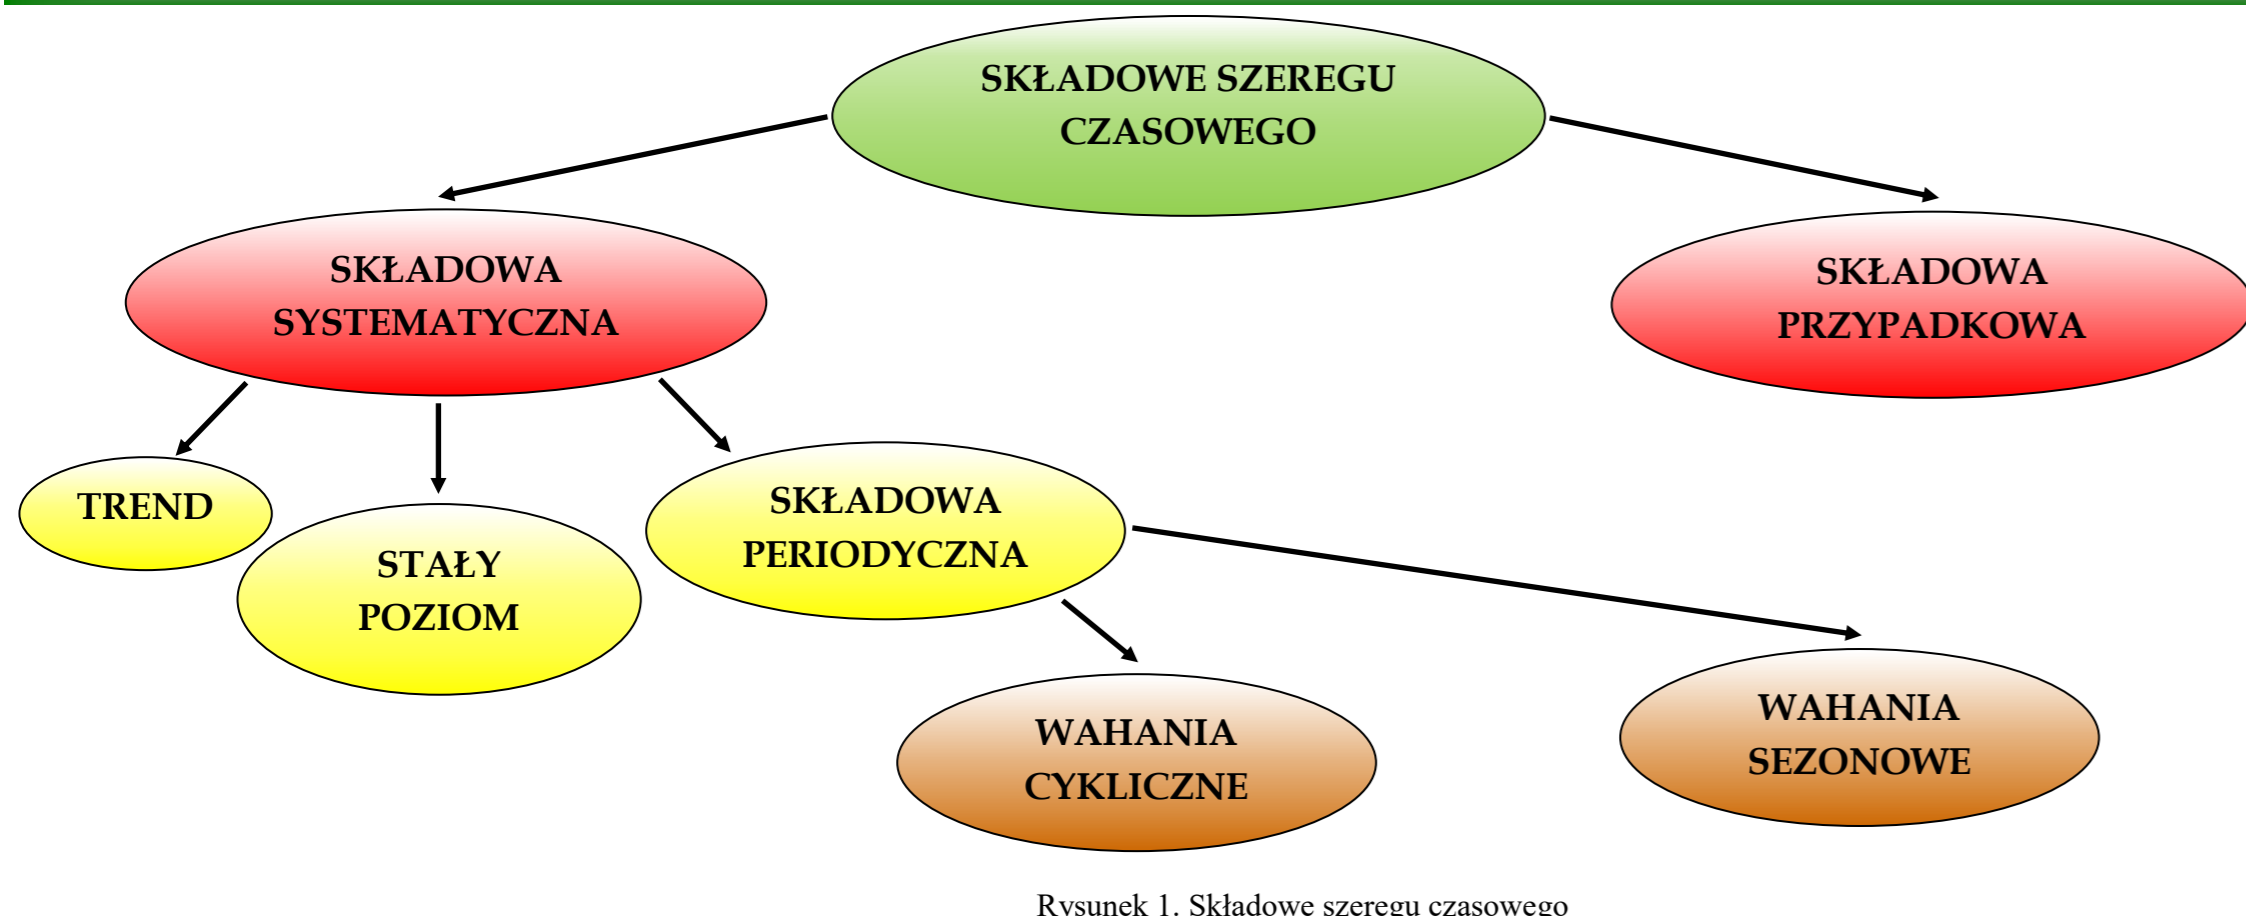


WYBRANE PROBLEMY DOTYCZĄCE METOD PROGNOZOWANIA POPYTU

WPROWADZENIE

Prognozowanie odgrywa bardzo istotną rolę w działalności przedsiębiorstw ze względu na nieregularność zmienności w przedziale czasu. Przeszacowanie popytu może być przyczyną wystąpienia zbyt dużych kosztów magazynowania, zaś jego niedoszacowanie może z kolei wygenerować koszty utraconych korzyści. W procesie prognostycznym, decydenci dążą do uzyskania jak największej ilości danych opisujących prognozowane zjawisko, celem zilustrowania przyszłych zdarzeń oraz optymalizacji podejmowanych decyzji. Biorąc pod uwagę liczbę czynników wpływających na kształtowanie się popytu np. jakość, cena, dostępność lub chociażby moda, sporządzenie prognozy nie jest łatwe. Odpowiednie zaplanowanie struktury oraz wielkości produkcji umożliwia sporządzenie planów produkcyjnych, które z kolei składają się na właściwe planowanie potrzeb materiałowych. Celem pracy było zwiększenie efektywności oraz zaprezentowanie korzyści wynikających z zastosowania oprogramowania matematycznego w odniesieniu do wybranych metod prognozowania popytu opartego na szeregach czasowych.

MODELOWANIE Z WYKORZYSTANIEM SZEREGÓW CZASOWYCH



Rysunek 1. Składowe szeregu czasowego

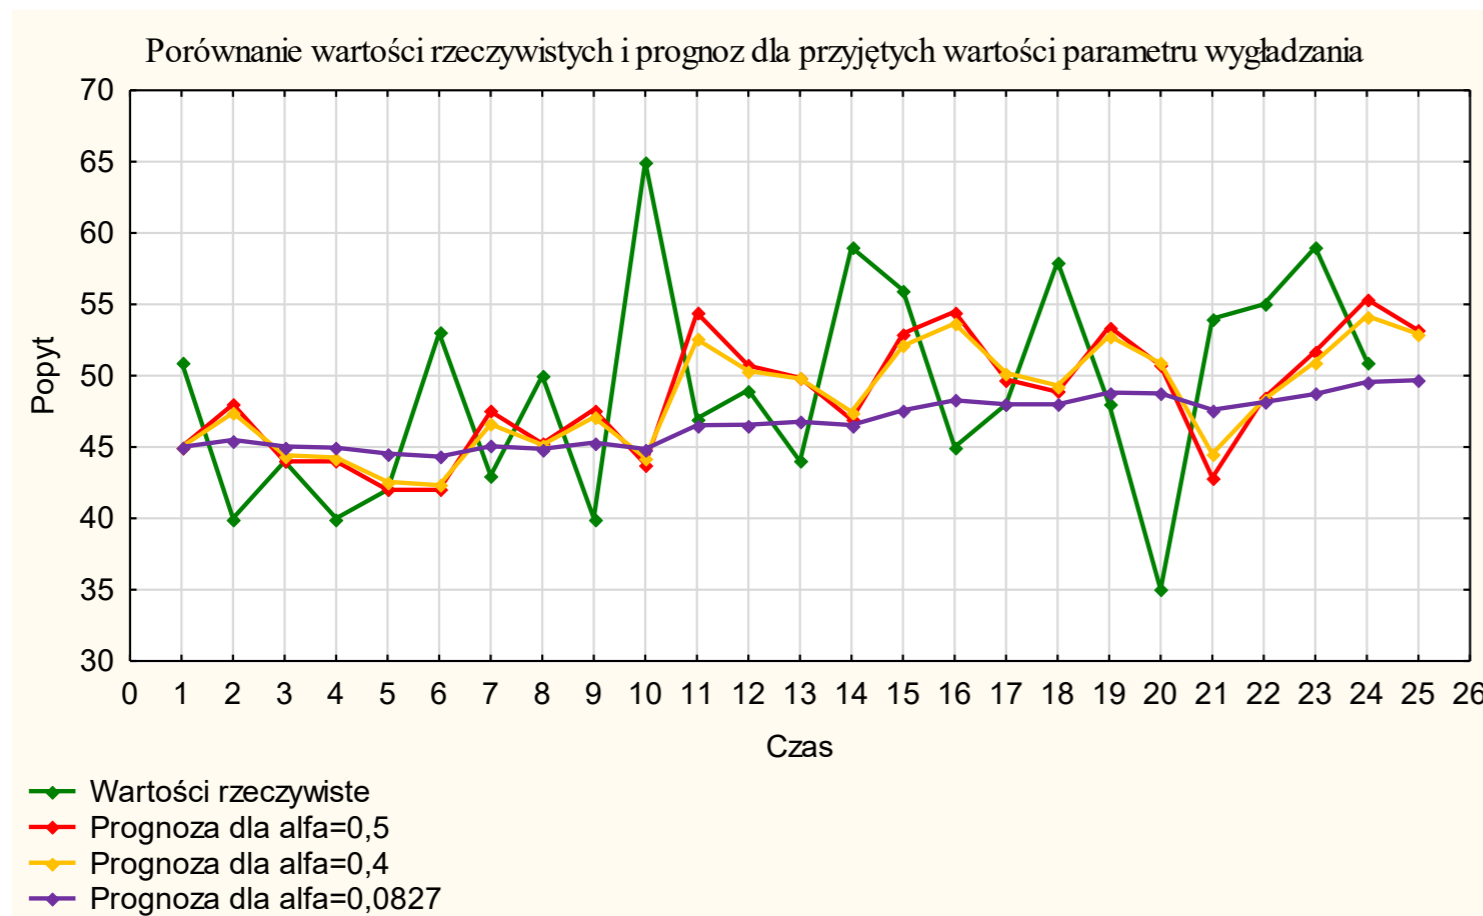
MODEL SZEREGÓW CZASOWYCH ZE STAŁYM POZIOMEM ZMIENNYCH

Model Browna służy do ustalania prognoz krótkookresowych dla szeregów czasowych, wykazujących brak tendencji rozwojowej oraz wahań sezonowych. Szereg czasowy charakteryzuje się prawie stałym poziomem prognozowanej zmiennej obciążonych wahaniami przypadkowymi. W modelu Browna prognozę należy wyznaczyć korzystając z następującego wzoru:

$$Pr_{i+1} = P_i \cdot \alpha + Pr_i \cdot (1 - \alpha)$$

gdzie:

P_i – popyt rzeczywisty w okresie i ,
 Pr_i – prognoza na okres i ,
 α – stała wygładzania o wartości z przedziału $[0;1]$.



Rysunek 2. Porównanie wartości rzeczywistych i prognoz dla ustalonych wartości parametru α

RODZAJ BŁĘDU	Model I	Model II	Model III
	$\alpha = 0,5$	$\alpha = 0,4$	$\alpha = 0,0827$
średni błąd prognozy	0,68	0,82	2,35
średni bezwzględny błąd prognozy	6,99	6,72	5,86
średni względny błąd prognozy	0,14	0,13	0,11
standardowy błąd prognozy	8,66	8,32	7,72
współczynnik Theila	0,17	0,16	0,15
prognoza	54	53	50

Tabela 1. Wartości błędów prognozy w zależności od parametrów modelu Browna

MODEL SZEREGÓW CZASOWYCH Z TENDENCJĄ ROZWOJOWĄ

Model Holta służy do analizy szeregów czasowych, w których występuje trend liniowy oraz wahaniami losowe. Jako pierwszą ocenę wartości średniej wygładzonego szeregu czasowego przyjmuje się pierwszą obserwację szeregu empirycznego, natomiast ocenę trendu wyznacza się jako różnicę pomiędzy drugą i pierwszą obserwacją empiryczną. Prognozę należy wyznaczyć korzystając z następujących zależności:

$$Pr_{i+j} = a_i + b_i \cdot j$$


$$a_i = \alpha \cdot P_i + (1 - \alpha) \cdot (a_{i-1} + b_{i-1})$$

$$b_i = \beta \cdot (a_i - a_{i-1}) + (1 - \beta) \cdot b_{i-1}$$

$$P_i^* = a_{i-1} + b_{i-1}$$

gdzie:

P_i – popyt rzeczywisty w okresie i ,
 P_i^* – prognoza wygasła na okres i ,
 Pr_i – prognoza na okres i ,
 α – stała wygładzania o wartości z przedziału $[0;1]$,
 β – stała wygładzania trendu o wartości z przedziału $[0;1]$.



Rysunek 3. Porównanie wartości rzeczywistych i prognoz dla ustalonych wartości parametrów α i β

RODZAJ BŁĘDU	Model I	Model II	Model III
	$\alpha = 0,5$ $\beta = 0,5$	$\alpha = 0,1$ $\beta = 0,3$	$\alpha = 0,0876$ $\beta = 0,1057$
średni błąd prognozy	0,26	0,51	1,47
średni bezwzględny błąd prognozy	7,64	5,72	5,5
średni względny błąd prognozy	0,13	0,1	0,09
standardowy błąd prognozy	9,95	7,85	7,71
współczynnik Theila	0,16	0,13	0,12
prognoza	83	90	85

Tabela 2. Wartości błędów prognozy w zależności od parametrów modelu Holta

MODEL SZEREGÓW CZASOWYCH Z WAHANIAM SEZONOWYMI

Model Wintersa uwzględniający sezonowość w szeregu czasowym, opiera się na idei wyrównywania wykładniczego. Prognozę należy wyznaczyć korzystając z następujących zależności:

$$Pr_i = a_n + b_n(i - n) + C_{i-r}$$

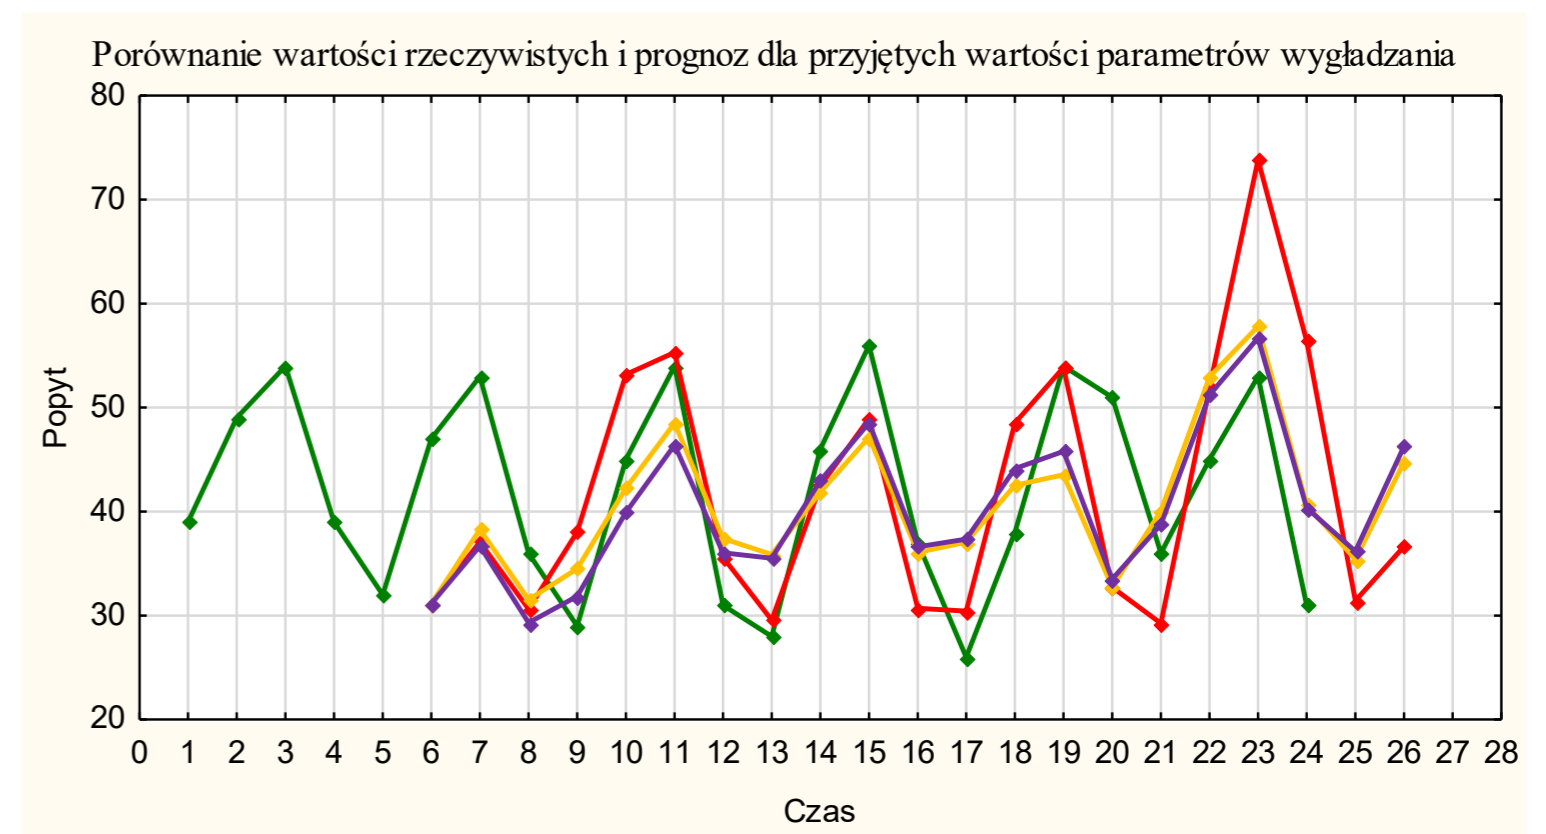
$$a_{i-1} = \alpha \cdot (P_{i-1} - C_{i-1-r}) + (1 - \alpha) \cdot (a_{i-2} - b_{i-2})$$

$$b_{i-1} = \beta \cdot (a_{i-1} - a_{i-2}) + (1 - \beta) \cdot b_{i-2}$$

$$C_{i-1} = \gamma \cdot (P_{i-1} - a_{i-1}) + (1 - \gamma) \cdot C_{i-1-r}$$

gdzie:

Pr_i – prognoza na okres i ,
 a_{i-1} – wygładzona wartość zmiennej prognozowanej dla okresu $i-1$ po eliminacji sezonowości,
 b_{i-1} – przyrost trendu na okres $i-1$,
 C_{i-1} – ocena sezonowości na okres $i-1$,
 r – liczba faz sezonowości,
 α, β, γ – parametry modelu przyjmujące wartości z przedziału $[0;1]$.



Rysunek 4. Porównanie wartości rzeczywistych i prognoz dla ustalonych wartości parametrów α, β oraz γ

RODZAJ BŁĘDU	Model I	Model II	Model III
	$\alpha = 0,2$ $\beta = 0,9$ $\gamma = 0,7$	$\alpha = 0,1$ $\beta = 0,5$ $\gamma = 0,05$	$\alpha = 0,2461$ $\beta = 0,4521$ $\gamma = 0,047$
średni błąd prognozy	0,71	1,26	1,74
średni bezwzględny błąd prognozy	9,05	7,77	7,53
średni względny błąd prognozy	0,22	0,19	0,18
standardowy błąd prognozy	11,65	9,23	9,09
współczynnik Theila	0,26	0,21	0,2
prognoza	37	45	47

Tabela 3. Wartości błędów prognozy w zależności od parametrów modelu Wintersa

WNIOSKI KOŃCOWE

1. Rezultat podejmowanej na podstawie prognozy popytu decyzji, powinien być oceniany za pomocą konkretnej miary i możliwy dzięki wykorzystaniu odpowiedniego algorytmu optymalizującego.
2. Udzielono odpowiedzi na postawione problemy badawcze oraz zaprezentowano teoretyczne podstawy konstrukcji modeli matematycznych ze stałym poziomem zmiennych, z tendencją rozwojową oraz wahaniami sezonowymi.
3. Błędne antycypowanie przyszłego poziomu rozpatrywanej zmiennej może mieć niekorzystne skutki dla przedsiębiorstwa.
4. Zastosowanie poszukiwania sieciowego przy wykorzystaniu STATISTICA 13.0 oraz narzędzia optymalizacyjnego Solver, w rezultacie doprowadziły do wyznaczenia optymalnej prognozy popytu pojazdów.
5. Pakiet STATISTICA 13.0 charakteryzuje się mniejszą złożonością obliczeniową niż arkusz MS Excel, co może mieć kluczowe znaczenie w sytuacji, gdy decydującym czynnikiem jest termin wyznaczenia prognozy.