

**POLITECHNIKA KRAKOWSKA IM. TADEUSZA KOŚCIUSZKI**

WYDZIAŁ INŻYNIERII LĄDOWEJ  
INSTYTUT ZARZĄDZANIA W BUDOWNICTWIE I TRANSPORCIE  
ZAKŁAD TRANSPORTU

ROZPRAWA DOKTORSKA

***„ZASTOSOWANIE NARZĘDZI SZTUCZNEJ INTELIGENCJI W  
STEROWANIU ZAPASAMI TOWARÓW W WARUNKACH  
NIEPEWNOŚCI”***

**AUTOR: MGR INŻ. PAWEŁ WIĘCEK**

**PROMOTOR: PROF. DR HAB. INŻ. ANDRZEJ ADAMSKI**

**KRAKÓW | 2017**



*Składam serdeczne podziękowania Panu promotorowi  
prof. dr hab. inż. Andrzejowi Adamskiemu za  
poświęcony czas i okazaną pomoc w przygotowaniu  
niniejszej pracy doktorskiej*



## SPIS TREŚCI

<b>STRESZCZENIE .....</b>	<b>6</b>
<b>SUMMARY.....</b>	<b>7</b>
<b>1. WSTĘP .....</b>	<b>8</b>
1.1. Geneza podjęcia tematu.....	8
1.2. Tezy pracy .....	9
1.3. Cele pracy.....	9
1.4. Zakres pracy .....	11
1.5. Wykaz najważniejszych skrótów i oznaczeń .....	12
<b>2. WYBRANE ELEMENTY MAGAZYNOWANIA I STEROWANIA ZAPASAMI ....</b>	<b>15</b>
2.1. Znaczenie i funkcje magazynów w logistycznych sieciach dostaw .....	15
2.2. Istota i funkcje zapasów w sieciach dostaw .....	19
2.3. Wybrane aspekty logistycznych kosztów obsługi zapasów .....	21
2.4. Klasyfikacja modeli w systemach sterowania zapasami .....	24
2.5. Klasyczne modele sterowania zapasami.....	25
2.5.1. Klasyczny model poziomego zamawiania.....	27
2.5.2. Model EOQ z dopuszczalnym niedoborem zapasów.....	29
2.5.3. Klasyczny model cyklu zamawiania.....	31
2.6. Inne wykorzystywane modele sterowania zapasami .....	32
2.7. Poziom obsługi klienta jako miara efektywności w sterowaniu zapasami.....	34
2.8. Inne wybrane miary efektywności sterowania zapasami .....	38
<b>3. ZNACZENIE ANALIZY I PREDYKCJI POPYTU W PROCESIE STEROWANIA ZAPASAMI TOWARÓW .....</b>	<b>40</b>
3.1. Wykorzystanie analizy ABC, XYZ w wyborze metody sterowania zapasami towarów .....	40
3.2. Identyfikacja, estymacja i predykcja popytu na towary jako kluczowy element w sterowaniu zapasami.....	41
3.2.1. Charakterystyka podstawowych modeli predykcji popytu na podstawie analizy szeregów czasowych .....	43
3.2.1.1. Metoda średnich ruchomych .....	44
3.2.1.2. Metoda wygładzania wykładniczego Browna.....	45

3.2.1.3. Liniowy model Holta .....	46
3.2.1.4. Model Wintersa .....	47
3.2.2. Wpływ błędów oszacowania prognoz popytu na proces sterowania zapasami .....	48
3.2.3. Źródła niepewności popytu na towary w sterowaniu zapasami .....	49
<b>4. METODA STEROWANIA ZAPASAMI W WARUNKACH NIEPEWNOŚCI Z WYKORZYSTANIEM DEDYKOWANYCH TECHNIK SZTUCZNEJ INTELIGENCJI .....</b>	<b>52</b>
4.1. Stan wiedzy dotyczącej sterowania zapasami towarów w kontekście oddziaływania czynników niepewnych .....	52
4.1.1. Rozwiązania wykorzystujące podejście typu robust .....	54
4.1.2. Rozwiązania wykorzystujące podejście stochastyczne .....	56
4.1.3. Rozwiązania wykorzystujące narzędzia sztucznej inteligencji .....	58
4.2. Założenia i charakterystyka proponowanej metody sterowania zapasami towarów w warunkach niepewności z wykorzystaniem narzędzi sztucznej inteligencji .....	60
4.2.1. Struktura i funkcjonalność modułu predykcji .....	63
4.2.1.1. Filtracja danych o zapotrzebowaniu na towary .....	63
4.2.1.2. Analiza spektralna danych o zapotrzebowaniu na towary .....	64
4.2.1.3. Hybrydowy model predykcji popytu na podstawie modeli autoregresyjnych ARIMA oraz sztucznych sieci neuronowych .....	66
4.2.2. Struktura i funkcjonalność modułu wnioskowania rozmytego .....	73
4.2.2.1. Istota rozumowania rozmytego i zbiorów rozmytych .....	74
4.2.2.2. Budowa i dobór parametrów modułu wnioskowania rozmytego .....	77
4.2.2.3. Wielokryterialna optymalizacja bazy reguł rozmytych modułu wnioskowania z wykorzystaniem algorytmu genetycznego .....	82
4.3. Matematyczne sformułowanie rozważanego problemu zapasów .....	87
4.4. Problem sterowania zapasami towarów w ujęciu systemowym .....	89

<b>5. WERYFIKACJA EFEKTYWNOŚCI PROPONOWANEJ METODY STEROWANIA ZAPASAMI TOWARÓW W WARUNKACH NIEPEWNOŚCI... 94</b>	
5.1. Analiza efektywności modułu predykcji .....	94
5.1.1. Charakterystyka danych empirycznych .....	94
5.1.2. Estymacja parametrów składowej spektralnej oraz modelu ARIMA w hybrydowym modelu predykcji.....	96
5.1.3. Ocena efektywności procesu uczenia sieci neuronowej w hybrydowym modelu predykcji .....	99
5.1.4. Weryfikacja trafności otrzymanych prognoz zapotrzebowania na towary .....	102
5.2. Analiza efektywności modułu sterowania .....	112
5.2.1. Wyniki wielokryterialnej optymalizacji bazy reguł rozmytych z zastosowaniem algorytmu genetycznego.....	112
5.2.2. Wyniki symulacji poziomu zapasów w proponowanej metodzie sterowania.....	127
5.2.3. Ocena wrażliwości uzyskanych wyników symulacji poziomu zapasów .....	135
<b>6. PODSUMOWANIE .....</b>	<b>138</b>
6.1. Weryfikacja założonych celów oraz postawionych tez.....	138
6.2. Praktyczne aspekty proponowanego rozwiązania .....	141
6.3. Dalsze kierunki badań .....	142
<b>BIBLIOGRAFIA .....</b>	<b>144</b>
<b>SPIS RYSUNKÓW .....</b>	<b>154</b>
<b>SPIS TABEL .....</b>	<b>157</b>
<b>ZAŁĄCZNIK A.....</b>	<b>158</b>
<b>ZAŁĄCZNIK B.....</b>	<b>162</b>

## STRESZCZENIE

Niniejsza rozprawa doktorska dotyczy problematyki sterowania poziomem zapasów towarów, w węzłowych punktach sieci dostaw w otoczeniu oddziaływania losowych czynników zewnętrznych. Specyfika przepływu strumieni towarowych w ramach sieci wiąże się z ich dynamiczną intensywnością w czasie oraz pewnym poziomem niepewności w stosunku do wielkości i czasu tego przepływu. Konsekwencją tego jest potrzeba tworzenia i utrzymania zapasów towarów na różnych poziomach sieci w celu zapewnienia ciągłości jej funkcjonowania. Właściwe uwzględnienie, w procesie decyzyjnym dotyczącym uzupełniania i utrzymywania zapasów, różnego rodzaju zakłóceń losowych rzutuje na efektywność i koszty działania sieci dostaw. W pracy zaproponowano odpowiednie wykorzystanie dedykowanych technik sztucznej inteligencji do rozwiązania wielokryterialnego problemu sterowania poziomem zapasów w warunkach oddziaływania wybranych czynników losowych w postaci niepewności zapotrzebowania na towar, czasu realizacji dostawy oraz zmiennej dostępności produktu u dostawcy. Zmienność tych parametrów została opisana poprzez zastosowanie teorii zbiorów rozmytych.

Głównym osiągniętym celem pracy jest opracowanie oryginalnej systemowej metody do rozwiązania wspomnianego problemu zapasów. Przedstawione w pracy podejście bazuje na połączeniu dwóch elementów metody jakimi są moduł predykcji oraz moduł rozumowania rozmytego. Pierwszy z nich wykorzystuje połączone wykorzystanie analizy spektralnej, modeli autoregresyjnych i sztucznych sieci neuronowych do identyfikacji i predykcji przyszłego zapotrzebowania na towar. Natomiast drugi odpowiedzialny jest za wyznaczenie optymalnych wartości parametrów sterowania w oparciu o zoptymalizowaną poprzez algorytm genetyczny bazę wiedzy w formie zbioru reguł rozmytych.

Potencjalne korzyści stosowania zaprezentowanej metodyki zostały otrzymane w wyniku przeprowadzenia wielu przykładów obliczeniowych i symulacji komputerowych na podstawie rzeczywistych danych o zapotrzebowaniu na dany produkt. Osiągnięte rezultaty zostały porównane z dwoma innymi powszechnie stosowanymi w praktyce metodami. Dodatkowo w pracy zbadano wrażliwość zaproponowanej metody sterowania i jej zdolność adaptacji do zmieniających się zakresów niepewności parametrów problemu.

## SUMMARY

The dissertation deals with the issue of inventory control problem of goods in the single nodal elements of the supply network, considering the influence of random external factors. The specificity of the good flows within the network is associated with its variable intensity in time and some level of uncertainty in relation to the volume and time of the flow. As a consequence of this fact, there is a need to create stocks of goods at different levels of the supply network in order to ensure the continuity of its operations. Therefore, in the decision-making process in field of inventory maintenance and renewal, a variety of random disturbances affecting the system should be properly taken into account. It is a crucial to provide required level efficiency and cost effective of supply network. In the work to solve the multicriteria problem of inventory control under uncertainties a dedicated artificial intelligence techniques have been applied. These uncertainties take the form of demand randomness, variability of delivery time and product availability by the supplier. The variability of these parameters have been described by applying fuzzy sets theory.

The main goal of dissertation which has been achieved was to develop an original system-wide method to solve this inventory problem. The approach presented in the work is based on a combination of two key elements, which are prediction module and fuzzy reasoning module. The first one uses the combined exploration of spectral analysis, autoregressive models and artificial neural networks to identify and predict future goods demand. The second is responsible for determining the optimal values of the control parameters based on optimized by genetic algorithm knowledge base in the form of a set of fuzzy rules.

The potential benefits of the presented methodology have been received as a result of the many calculation examples and computer simulations based on real data of a product demand. The results achieved were compared with two other commonly used methods in practice. In addition, the comprehensive sensitivity analysis of the proposed control method and its ability to adapt to changing ranges of uncertainty parameters have been conducted.

## 1. WSTĘP

### 1.1. GENEZA PODJĘCIA TEMATU

Obecnie postępująca globalizacja wraz z masową konsumpcją sprawiają, iż popyt na rynku towarów charakteryzuje się intensywną dynamiką i pewnym poziomem nieokreśloności szczególnie w dużych aglomeracjach i obszarach zurbanizowanych. Zachodzące tam procesy logistyczne w ramach sieci dostaw koncentrują się przede wszystkim na przepływie strumieni dóbr materialnych nie mniej uwzględniając również przepływy niezbędnych informacji oraz środków finansowych. Zmienna intensywność tych procesów i pewien poziom nieokreśloności powoduje powstawanie różnego rodzaju zapasów na różnych szczeblach sieci w celu zapewnienia ciągłości produkcji oraz nieprzerwanej dostępności wyrobów gotowych dla klientów. W praktyce pomimo stosowania nowoczesnych systemów JIT (Just In Time), ERP (Enterprise Resource Planning), MRP (Material resource Planning) nie jest możliwa całkowita eliminacja zapasów. W rzeczywistości bowiem procesy gospodarcze mają stochastyczną naturę (wynikającą zarówno ze środowiska operacyjnego tych procesów jak również oddziaływań ich otoczenia) a więc możliwe jest ich rozpoznanie jedynie w pewnym stopniu, z mniejszym lub większym błędem. Oddziaływanie losowych czynników na węzłowe elementy sieci dostaw (zakłady produkcyjne, centra dystrybucyjne, magazyny itp.) poprzez zmienność popytu na półprodukty lub wyroby gotowe, zmienność czasu dostawy, ograniczone możliwości dostawców itp. sprawiają, iż optymalna polityka w zakresie logistyki zaopatrzenia oraz sterowania zapasami ma kluczowy wpływ na efektywność funkcjonowania całej sieci logistycznej.

W obliczu wspomnianych czynników oraz rosnącej konkurencji pomiędzy podmiotami, przedsiębiorstwa logistyczne, próbując utrzymać pożądany poziom obsługi klientów zmuszone są niejednokrotnie utrzymywać wysoki poziom zapasów. Daje to możliwość dynamicznej reakcji na niespodziewane zmiany w popycie bądź działanie innych czynników zewnętrznych lecz zarazem generuje wzrost kosztów. Te w szczególności związane są z utrzymaniem zapasów, wynajmowaniem dodatkowych przestrzeni pod składowanie oraz zamrażaniem w zapasach ograniczonych środków finansowych. Z drugiej strony zbyt niski stan magazynowy w stosunku do pozycji asortymentowych, charakteryzujących się nietypowym wzorcem popytu, a które są istotne dla przedsiębiorstwa może prowadzić do pojawiania się kosztów zewnętrznych z tytułu ewentualnych braków w zasobach. Mogą one być wyrażone zarówno w jednostkach pieniężnych jak również w postaci utraty klientów, obniżenia reputacji czy też spadku konkurencyjności przedsiębiorstwa. Przedstawiona sytuacja sprzyja także powstawaniu dodatkowych kosztów transportu związanych z realizacją nieplanowanych dostaw. Podejmowana rozprawa doktorska ma na celu zaproponowanie symulacyjnej metody sterowania zapasami w oparciu o połączenie zaawansowanych metod obliczeniowych oraz różnych technik i narzędzi sztucznej inteligencji w celu zapewnienia kompromisu pomiędzy kosztami a stanem zapasów wybranych pozycji asortymentowych w warunkach silnego, jednoczesnego oddziaływania losowych czynników zewnętrznych. Zastosowanie połączonych ze sobą narzędzi sztucznej inteligencji w postaci sieci neuronowych, algorytmów genetycznych oraz rozumowania rozmytego może umożliwić



obniżenie poziomu nieokreśloności w odniesieniu do wielkości podlegających sterowaniu zapewniając większą jakość opisu i diagnostyki tych procesów i w konsekwencji jakość podejmowanych decyzji w tym zakresie.

W ciągu ostatnich dekad w literaturze można zaobserwować systematycznie rosnącą liczbę publikacji naukowych rozważających to zagadnienie przy zastosowaniu rozmaitych podejść oraz metod uwzględniających wpływ różnych czynników losowych oddziałujących na system zapasów. Jednakże pomimo wielu opracowań brak jest systemowych propozycji rozwiązań uwzględniających jednoczesny wpływ kilku tychże czynników. Dodatkowo brak jest podejść, które w sposób dynamiczny reagowałyby na aktualnie zachodzące zmiany w systemie zapasów zapewniając zdolność adaptacji i elastyczności rozwiązania dla różnych sytuacji oraz specyfiki popytu na dany towar. Dlatego też celem autora było zaproponowanie metody, która respektowałaby powyższe wymagania.

## 1.2. TEZY PRACY

W dysertacji postawione zostały następujące tezy badawcze:

***Główna teza pracy:*** Systemowe wykorzystanie dedykowanych technik sztucznej inteligencji istotnie wpływa na zwiększenie efektywności w zakresie logistyki zapasów w warunkach niepewności.

***Teza pomocnicza:*** Zastosowanie hybrydowych modeli prognostycznych umożliwia zmniejszenie poziomu niepewności w odniesieniu do predykcji popytu na dostawy towarów.

## 1.3 CELE PRACY

Na podstawie przeprowadzonego przeglądu literaturowego sformułowano problem badawczy polegający na identyfikacji specyfiki sterowania zapasami towarów w warunkach niepewności oraz zaproponowaniu metodyki opisu oraz rozwiązania problemu z wykorzystaniem odpowiednich narzędzi sztucznej inteligencji. Praca przedstawia badania teoretyczne o charakterze metodologicznym.

***Głównym celem rozprawy doktorskiej jest opracowanie inteligentnej metody sterowania zapasami w warunkach niepewności z wykorzystaniem dedykowanych metod i narzędzi sztucznej inteligencji.***

*Celami pośrednimi w pracy są:*

- 1. Ukazanie możliwych korzyści oraz zysków ze stosowania metod sztucznej inteligencji w obszarze sterowania zapasami.*
- 2. Opracowanie propozycji umiejscowienia podejmowanej problematyki kontrolowania poziomu zapasów w warunkach niepewności z wykorzystaniem narzędzi sztucznej*

*inteligencji w hierarchicznej koncepcji Inteligentnych Zintegrowanych Systemów Logistycznych.*

Aby spełnić realizację celu pracy oraz udowodnić postawione w niej tezy konieczna była realizacja następujących zadań :

- dokładne rozpoznanie i identyfikacja specyfikacji rozwiązywanego problemu, na podstawie analizy pozycji literaturowych, w których uwzględniono oddziaływanie różnego rodzaju czynników niepewnych mogących oddziaływać na system zapasów,
- określenie grupy oddziałujących czynników niepewnych na system zapasów, która została uwzględniona w proponowanej metodzie,
- sformułowanie modelu matematycznego problemu, określającego zmienne, warunki ograniczające oraz kryteria według których została zbadana efektywność metody,
- stworzenie architektury oraz struktury powiązań pomiędzy elementami systemu stanowiącego ideę proponowanego podejścia,
- dobór właściwych narzędzi oraz metod badawczych,
- budowa i analiza efektywności hybrydowego modelu predykcji popytu na towary,
- budowa zintegrowanego systemu sterowania zapasami w warunkach niepewności,
- pozyskanie niezbędnych danych historycznych z przedsiębiorstwa dotyczących struktury popytu, szacunkowych ponoszonych kosztów z tytułu utrzymania i uzupełniania zapasów,
- przeprowadzenie symulacji komputerowych poziomu zapasów wedle zaproponowanej metody celem weryfikacji efektywności podejścia, przy użyciu specjalistycznych narzędzi komputerowych w postaci pakietu Matlab wraz ze specjalnymi funkcjonalnymi bibliotekami Fuzzy Logic Toolbox, Genetic Algorithm Toolbox, Neural Network Toolbox, Econometric Toolbox,
- analiza wrażliwości proponowanego podejścia dla różnych zakresów zmienności istotnych parametrów oddziałujących na system zapasów,
- porównanie otrzymanych rezultatów z innymi podstawowymi metodami powszechnie dostępnymi w literaturze,

## 1.4 ZAKRES PRACY

Rozprawa przedstawia opracowaną oryginalną metodę rozwiązywania problemu sterowania poziomem zapasów towarów w otoczeniu oddziaływania czynników niepewnych. Oferowane rozwiązanie opiera się na wykorzystaniu systemowego podejścia do rozwiązania postawionego problemu badawczego z połączonym zastosowaniem dedykowanych technik obliczeniowych oraz narzędzi sztucznej inteligencji w postaci algorytmów genetycznych, rozumowania rozmytego oraz sztucznych sieci neuronowych. Praca zawiera sześć rozdziałów, spis bibliograficzny, rysunków, tabel oraz załączniki A i B.

W rozdziale pierwszym przedstawiono oraz scharakteryzowano poruszaną problematykę, sformułowano tezy badawcze oraz cele rozprawy.

Drugi rozdział przedstawia specyfikę rozważanego obszaru badawczego, podstawowe definicje, pojęcia związane ze sterowaniem zapasami i harmonogramowaniem dostaw. W rozdziale tym poruszono kwestie znaczenia magazynów oraz funkcji zapasów w sieciach dostaw. W wyczerpującym stopniu przedstawiono poszczególne rodzaje kosztów logistycznych ponoszonych z tytułu utrzymywania i odnawiania zapasów towarów, miar jakości i efektywności kontrolowania poziomu zapasów. Przedstawiono także podstawowe modele i metody sterowania zapasami dostępne w literaturze z uwypukleniem ich zalet oraz wad.

W rozdziale trzecim poruszono problem znaczenia predykcji zapotrzebowania na towary, identyfikacji wzorców popytowych w procesie sterowania zapasami. W tej części pracy dokonano zatem charakterystyki podstawowych metod prognozowania na podstawie szeregów czasowych, analizy wpływu niedokładności prognozowania na jakość sterowania zapasami oraz powstawanie w związku z tym niepożądanych zjawisk w sieci dostaw, w postaci efektu Forrestera. Dodatkowo w rozdziale tym podjęta została próba identyfikacji źródeł niepewności popytu na towary, generująca zmienną intensywność przepływu strumieni informacyjno - materiałowych w sieciach logistycznych.

Rozdział czwarty w początkowej części zawiera dokładny przegląd literatury związanej ze sterowaniem zapasami towarów w warunkach niepewności. Studia literaturowe zostały wykonane z rozróżnieniem na odmienne podejścia proponowane przez badaczy oraz grupę różnych czynników losowych oddziałujących na system zapasów. W odpowiedzi na przeprowadzoną analizę literaturową, w dalszej części rozdziału zaprezentowano koncepcję i założenia metody rozwiązania problemu zaproponowanej przez autora. Dodatkowo przedstawiono podstawowe informacje oraz wiedzę z zakresu zastosowanych w metodzie narzędzi prognostycznych, optymalizacyjnych oraz sztucznej inteligencji. W dalszej części rozdziału sformułowano model matematyczny rozwiązywanego zagadnienia oraz zaproponowano jego umiejscowienie w strukturze systemowej koncepcji Inteligentnych Zintegrowanych Systemów Logistycznych (ILS - Intelligent Integrated Logistics Systems).

W rozdziale piątym przeprowadzono proces weryfikacji efektywności zaproponowanej metody na podstawie rzeczywistych danych popytowych przedsiębiorstwa dla ustalonego okresu czasu. W pierwszej kolejności, analizie został poddany moduł predykcji stanowiący istotny element całego podejścia. Dokładność otrzymanych prognoz dla różnych horyzontów

prognozowania została porównana z innymi popularnymi metodami prognozowania. Następnie analizie efektywności poddano całość podejścia a otrzymane wyniki porównano z wybranymi podstawowymi metodami sterowania zapasami dostępnymi w literaturze. W ostatniej części rozdziału zawarto rezultaty przeprowadzonej analizy wrażliwości oferowanej metody na rosnącą zmienność wybranych parametrów losowych rozważanych w pracy.

W rozdziale szóstym zawarto podsumowanie oraz sformułowane wnioski płynące z przeprowadzonych badań oraz otrzymanych rezultatów.

## 1.5 WYKAZ NAJWAŻNIEJSZYCH SKRÓTÓW I OZNACZEŃ

<b>ROP</b>	Re – Order Point, model poziomu zamawiania
<b>ROC</b>	Re – Order Cycle, model cyklu zamawiania
<b>EOQ</b>	Economic Order Quantity, ekonomiczna wielkość dostawy minimalizująca łączne koszty funkcji zapasów
$Q_{opt}$	Wielkość dostawy minimalizująca funkcję kosztów tworzenia i utrzymania zapasów w modelu EOQ
$\overline{Q}_{T_p}$	przeciętna wielkość dostawy w okresie planistycznym $T_p$
<b>T</b>	Długość pojedynczego cyklu zamawiania w modelach ROP oraz ROC
$T_p$	Długość rozważanego okresu planistycznego
<b>R</b>	Poziom alarmowy zapasu towaru, tzn. wielkość przy której należy złożyć zamówienie na dostawę
<b>P</b>	Intensywność zużycia towaru w zapasie w trakcie trwania cyklu T
<b>SS</b>	Dodatkowa część zapasu nazywana zapasem bezpieczeństwa
<b>L</b>	Czas realizacji pojedynczej dostawy towaru dla modelu ROP, ROC
<b>k</b>	Współczynnik bezpieczeństwa czyli wielkość wynikająca z przyjętego poziomu obsługi klienta
$S_{max}$	Maksymalny poziom zapasu
$\overline{P}_L$	Przeciętne zapotrzebowanie na towar w trakcie cyklu uzupełniania zapasów
$k_z$	Jednostkowy koszt realizacji dostawy
$k_b$	Jednostkowy koszt ponoszony w przypadku braku zapasu
$k_u$	Jednostkowy koszt utrzymania zapasu

<b>FL</b>	Logika rozmyta, wykorzystana w przedstawionym w pracy podejściu do opisu niepewności czynników oddziałujących na system zapasów,
<b>GA</b>	Algorytm genetyczny, wykorzystany do optymalizacji bazy wiedzy w module rozumowania rozmytego
<b>ANN</b>	Sztuczne sieci neuronowe wykorzystane jako składowa hybrydowego modelu predykcji do rozpoznawania nieliniowych wzorców zapotrzebowania na towary
<b>ARIMA</b>	Auto - Regressive Integrated Moving Average, zintegrowany model autoregresji i średniej ruchomej, odpowiedzialny za rozpoznawanie liniowych zależności popytu w oparciu o zjawisko autoregresji
$p, d, q$	Odpowiednio parametry określające rząd opóźnienia członu AR, stopień zintegrowania szeregu oraz, rząd opóźnienia członu MA dla modelu ARIMA
<b>ACF</b>	Funkcja autokorelacji
<b>PACF</b>	Funkcja autokorelacji cząstkowej
$Y^{sr}$	Przeciętny poziom zmiennej prognozowanej jaką są przyszłe wartości zapotrzebowania na towar
$Y(t)^{(ARIMA)}$	Wartość zmiennej prognozowanej w chwili $t$ otrzymywanej ze składowej modelu ARIMA
$Y(t)^{(ANN)}$	Wartość zmiennej prognozowanej w chwili $t$ otrzymywanej z członu sztucznych sieci neuronowych
$Y^P(t)$	Całkowita prognozowana wartość zapotrzebowania na towar dla chwili $t$ wyznaczana przez moduł predykcji
$h$	Długość przyjętego horyzontu prognozowania
$z_t$	Wielkość zapasu w chwili $t$
$r_t$	parametr określający stopień wypełnienia dostawy oraz opisujący ograniczoną dostępność produktu u dostawcy w chwili $t$ .
$L_t$	Czas realizacji dostawy dla zamówienia złożonego w okresie $t$
$q_t^*$	Wielkość zamówienia w chwili $t$ , jedna ze zmiennych wyjściowych modułu rozumowania rozmytego, który stanowi jedną ze składowych w proponowanej w pracy metodzie
$rop_t^*$	Punkt ponownego zamawiania w chwili $t$ , druga ze zmiennych wyjściowych przedstawianej metody
$Nb_t$	zmienna pomocnicza określająca czy zaistniał brak towaru w chwili $t$
$ld_t$	zmienna pomocnicza określająca czy wystąpiła dostawa w chwili $t$
$lb_t$	Wielkość braków w zapasie towaru w chwili $t$
$z_0$	Początkowa ilość zapasu w chwili $t=1$

$Z_L$	Zbiór zmiennych lingwistycznych
$W_L$	Zbiór wartości lingwistycznych
$W^R$	Wektor $k_R$ elementowy zawierający wartości wag dla kolejnych reguł rozmytych
$w_i^R$	Waga dla $i$ -tej reguły rozmytej
$f_1, f_2, f_3$	Odpowiednio funkcje kryteriów cząstkowych określające przeciętny stan zapasów, liczbę braków zapasu oraz liczbę wykonanych dostaw.
$F(W^R)$	Funkcja kryterium zbiorczego podlegająca minimalizacji w procesie optymalizacji wag dla bazy reguł rozmytych



## 2. WYBRANE ELEMENTY MAGAZYNOWANIA I STEROWANIA ZAPASAMI

### 2.1 ZNACZENIE I FUNKCJE MAGAZYNÓW W LOGISTYCZNYCH SIECIACH DOSTAW

W ciągu ostatnich dekad w skutek nasilających się procesów globalizacji, wzrostu ekonomicznego, postępu technologicznego owocującego w rozwój systemów komputerowych, łączności i wymiany informacji nastąpiła intensyfikacja procesów transportowych i logistycznych związanych z przepływem strumieni towarowych. Fakt ten spowodował rozrastanie się sieci logistycznych, poprzez coraz większą liczbę podmiotów zaangażowanych w przepływ materiałów. Łańcuch dostaw (tj. najprostsza postać sieci logistycznej) jest zazwyczaj definiowany jako sieć producentów i usługodawców, którzy współpracują ze sobą w celu przetwarzania i przemieszczania dóbr – od fazy surowca do poziomu użytkownika końcowego. Wszystkie te podmioty są połączone przepływami dóbr fizycznych, przepływami informacji oraz przepływami pieniężnymi [20]. Kluczowym elementem zapewniającym sprawny przepływ towarów od punktu początkowego łańcucha do jego punktu końcowego jest magazyn bądź inaczej mówiąc centrum logistyczne. Jako główne ogniwo w logistycznym łańcuchu dostaw jest ono odpowiedzialne za przyjmowanie, okresowe przechowywanie a także w dalszej kolejności przekazywanie towaru do następnych ogniw łańcucha. W tym miejscu zasadne jest przytoczenie formalnej definicji magazynu. Według polskiej normy PN-84/N-01800 *magazyn to jednostka funkcjonalno organizacyjna przeznaczona do magazynowania dóbr materialnych w wyodrębnionej przestrzeni budowli magazynowej według ustalonej technologii, wyposażona w odpowiednie urządzenia i środki techniczne, zarządzana i obsługiwana przez zespół ludzi*. Z drugiej strony warto również przedstawić definicję centrum logistycznego ze względu na bliskość znaczenia tych pojęć. I. Fechner definiuje centrum logistyczne *jako obiekt przestrzennie funkcjonalny wraz z infrastrukturą i organizacją, w którym realizowane są usługi logistyczne związane z przyjmowaniem, magazynowaniem, rozdziałem i wydawaniem towarów oraz usługi towarzyszące świadczone przez niezależne w stosunku do nadawcy lub odbiorcy podmioty gospodarcze* [49]. Z przedstawionych dwóch definicji wynika, iż pojęcie centrum logistycznego ma szersze znaczenie aniżeli sam magazyn jednakże zarówno jedno jak i drugie stanowi ważny element łańcucha logistycznego oraz zachodzi w nim proces magazynowy. W towarzystwie tych terminów bardzo często używane jest pojęcie magazynowania. Otóż magazynowaniem nazywany jest zespół czynności związanych z czasowym przyjmowaniem, składowaniem, przechowywaniem, kompletowaniem, przemieszczaniem, konserwacją, ewidencjonowaniem, kontrolowaniem i wydawaniem dóbr materialnych (zapasów) [96]. Istota tego typu obiektów jakimi są magazyny i centra logistyczne w sieciach logistycznych nabiera coraz większego znaczenia. Wyróżnić można kilka przesłanek, które wpływają na proces tworzenia nowych magazynów oraz dążenia do optymalizacji i podnoszenia efektywności ich funkcjonowania. Jedną z nich jest wzrost znaczenia poziomu obsługi

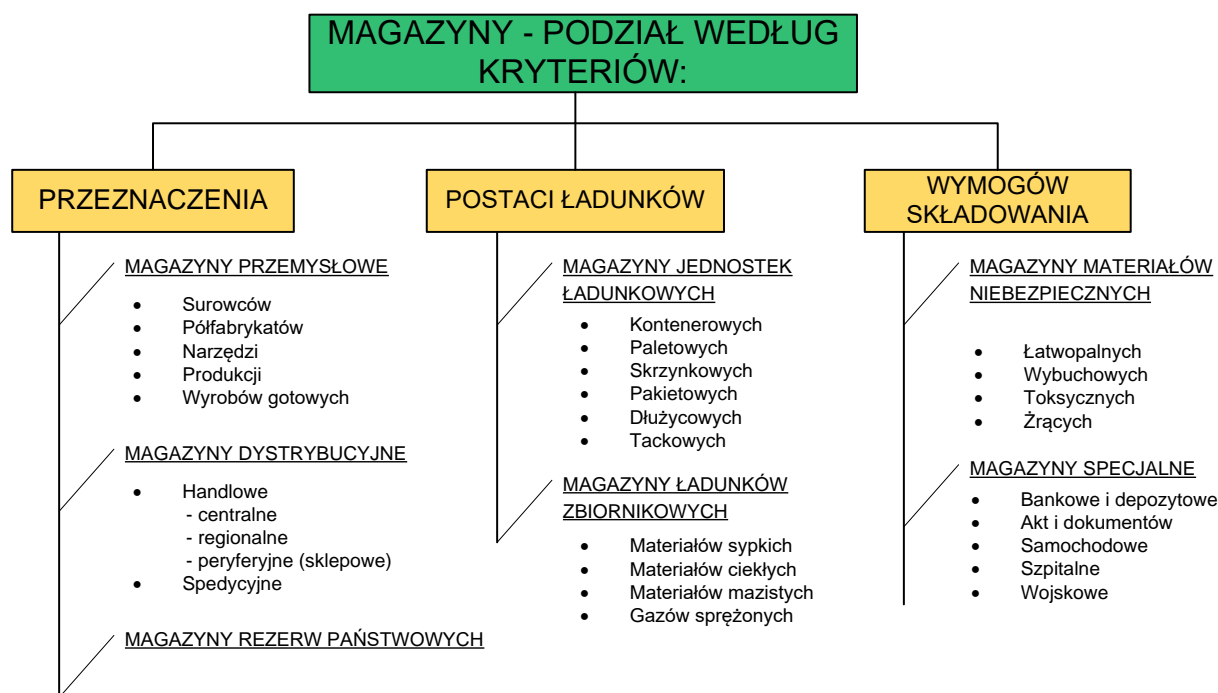
klientów, gdyż to na ich potrzebach skupia się działalność przedsiębiorstw, które tworzą łańcuch dostaw. Kolejną jest kompresja czasu czyli zaobserwowane skrócenie czasu dostaw niemal we wszystkich branżach, za sprawą wielu rozwiązań i usprawnień w ramach łańcucha dostaw. Popularyzacja handlu elektronicznego, elektronicznych platform informacyjno transakcyjnych oraz globalna dostępność produktów również odgrywa znaczenie. Jako ostatnią a zarazem najważniejszą przesłankę należy wskazać dążenie do ograniczania kosztów. Oferowanie odpowiedniego poziomu obsługi poprzez utrzymywanie wysokich stanów magazynowych jest wysoce nieekonomiczne generuje bowiem wysokie koszty. Dlatego odpowiednia konfiguracja i organizacja pracy magazynów znacząco obniża ponoszone nakłady.

Zmienna intensywność procesów przepływu strumieni produktów oraz informacji wewnątrz łańcucha logistycznego oraz ich nieciągłość powoduje powstawanie różnego rodzaju zapasów dóbr na różnych poziomach łańcucha. Jest to powodowane poprzez brak możliwości pełnej synchronizacji strumieni gromadzenia dóbr ze strumieniami ich zużycia. W związku z tym podstawowe funkcje magazynu można przedstawić jako pochodne strumieni przepływających przez nie zapasów wraz z ich cechami. W ten sposób można wyróżnić następujące funkcje:

- stanowią swoisty bufor oraz ochronę przed niepewnością dostaw która może odnosić się do czasu dostawy, wielkości jak i jakości zarówno w sferze produkcji jak i dystrybucji. W przeciwnej sytuacji ciągłość procesu produkcji bądź sprzedaży w przedsiębiorstwach mogłaby zostać poważnie zakłócona,
- dają możliwość zaspokojenia szczytowego zapotrzebowania na produkt gdy ma miejsce produkcja całoroczna i krótkoterminowe wysokie zużycie,
- umożliwiają prowadzenie gry rynkowej wykorzystując okresową koniunkturę lub dekoniunkturę cenową produktu,
- stanowią element pomocniczy w niwelowaniu skutków wysokiego rozproszenia w zakresie lokalizacji dostawców i odbiorców zarówno w skali kraju jak i świata,
- są kluczowym elementem różnych sieciowych kanałów dystrybucji umożliwiając kształtowanie wymaganego poziomu obsługi klienta,
- wyrównują fluktuacje podażyowo popytowe na rynku wyrobów gotowych jak i wahania wielkości zużycia surowców w przedsiębiorstwach produkcyjnych,

Wspomniane powyżej najważniejsze funkcje są dominujące w zależności od rodzaju, specyfiki oraz roli pełnionej przez magazyn w sieciach logistycznych. Podział magazynów według wybranych kryteriów przedstawia rys. 1.



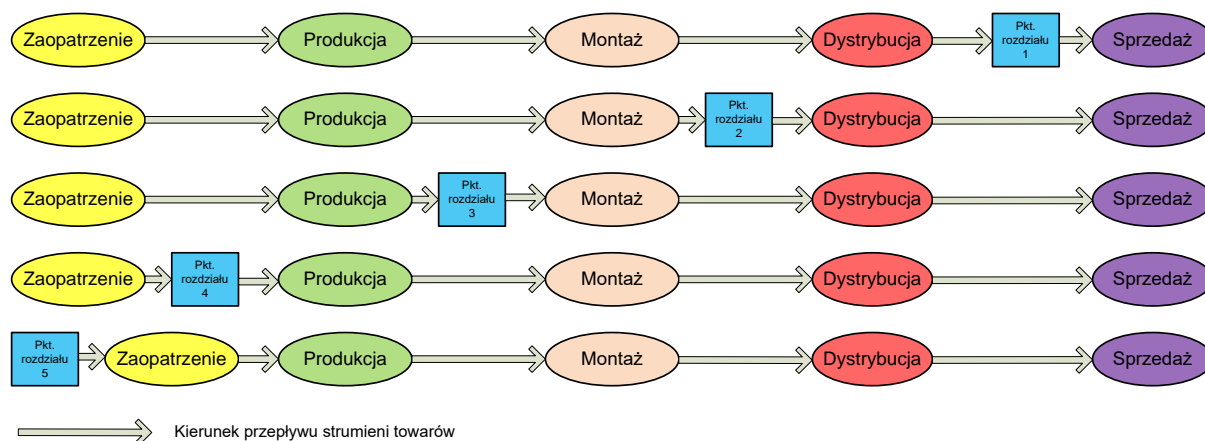


**Rys. 1.** Podział magazynów  
*Źródło: opracowanie własne na podstawie [56]*

Magazyn rozgranicza łańcuch dostaw na dwa obszary. Realizuje w ten sposób funkcję dzielącą zapotrzebowanie na niezależne (określa się go na podstawie prognoz zapotrzebowania w oparciu o dane historyczne zamówień od klientów, wynika z woli i decyzji klienta na rynku) i zapotrzebowanie zależne (stanowi zapotrzebowanie materiałowe, odnosi się do elementów składowych wchodzących w skład wyrobu gotowego) stając się tzw. punktem rozdziału. W praktyce można wyodrębnić pięć punktów rozdziału:

- punkt rozdziału 1 jest magazynem ulokowanym w niewielkim oddaleniu od rynku i klientów. Odnosi się przede wszystkim do towarów ogólnie dostępnych. Za przykład można podać magazyn dystrybucyjny,
- punkt rozdziału 2 odnosi się do magazynu wyrobów gotowych. Zazwyczaj jest usytuowany niedaleko miejsca wytwarzania,
- punkt rozdziału 3 stanowi magazyn umiejscowiony przed fazą montażu. Jest magazynem części i podzespołów potrzebnych do zmontowania wyrobu gotowego,
- punkt rozdziału 4 jest magazynem zaopatrzenia. W tego typu magazynie gromadzone są surowce oraz podzespoły pochodzące z zakupu,
- punkt rozdziału 5 stanowi magazyn dostawcy. W tym wypadku dostawa surowców odbywa się na zamówienie, koszty utrzymania zapasów przeniesione są na dostawców,

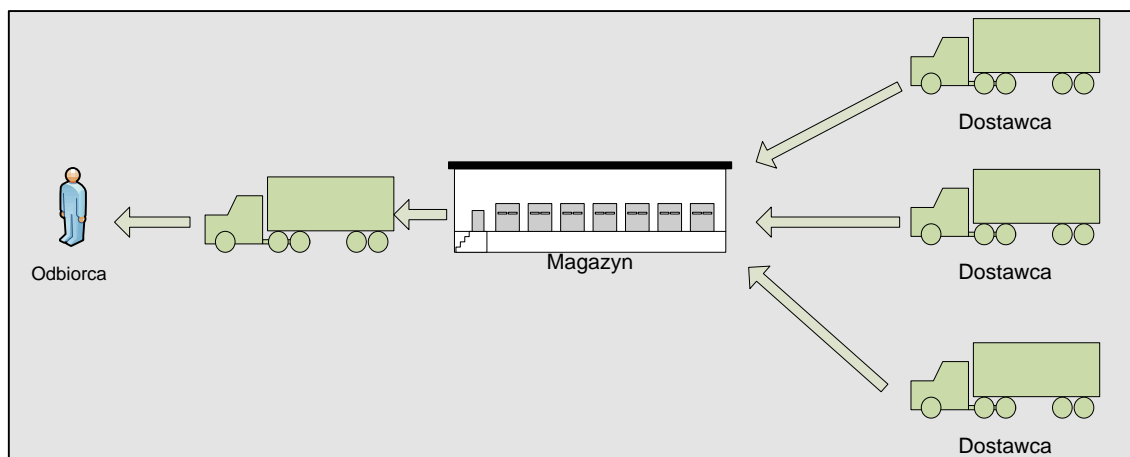
Rozmieszczenie przedstawionych powyżej punktów rozdziału w łańcuchu dostaw przedstawia rys. 2.



**Rys. 2.** Punkty rozdziálu w łańcuchu dostaw

*Źródło: opracowanie własne na podstawie [128]*


Poza wymienionymi powyżej magazyn może spełniać również pewne dodatkowe funkcje. Jednym z przykładów jest konsolidowanie w magazynie konsolidacyjnym wielu wpływających do niego strumieni towarów pochodzących od różnych dostawców w jedną większą przesyłkę wysłaną następnie do klienta. Opisaną sytuację przedstawia rys. 3.



**Rys. 3.** Konsolidacyjna funkcja magazynu

*Źródło: opracowanie własne*


Kolejna funkcja pełniona przez magazyn w ramach łańcucha dostaw polega na rozdzieleniu jednolitej przesyłki na mniejsze, które w dalszej kolejności trafiają do odbiorców. Przypadek ten przedstawia rys. 4.



**Rys. 4.** Dekonsolidacyjna funkcja magazynu

*Źródło: opracowanie własne*

Dodatkowo magazyny mogą odgrywać również rolę węzła przeładunku kompletacyjnego. Wpływające do niego strumienie materiałowe a następnie przemieszczane w jego obrębie są dzielone oraz kompletowane w nowe przesyłki, zróżnicowane pod względem asortymentu. Następnie towar podlega załadunkowi na środek transportu i jest wysyłany do klienta rys. 5. Czynności magazynowe związane z tego typu przeładunkiem kompletacyjnym powinny być ze sobą jak najlepiej zsynchronizowane aby minimalizować czas wykonania usługi.



**Rys. 5.** Funkcja przeładunku kompletacyjnego w magazynie

*Źródło: opracowanie własne*

## 2.2 ISTOTA I FUNKCJE ZAPASÓW W SIECIACH DOSTAW

Zachodzące przepływy strumieni materiałowych w przedsiębiorstwie jak i między nimi w ramach łańcucha logistycznego powodują nieustanne tworzenie zapasów w węzłowych jego punktach. Zapasem nazywana jest rzeczowa, niespiężona część środków obrotowych w skład której wchodzi: surowce, materiały, produkcja w toku, wyroby gotowe [96]. Podstawowym powodem tworzenia zapasów jest potrzeba bilansowania oraz wyrównywania zmiennych intensywności tychże przepływów. Kolejną przesłanką uzasadniającą gromadzenie zapasów jest oddziaływanie na procesy transportowe i logistyczne zakłóceń losowych. W takiej sytuacji nie jest możliwe tworzenie bezbłędnych planów i prognoz co zmusza do tworzenia wymaganych rezerw. Zatem utrzymywanie zapasów jest podyktowane

pewną asekuracją w przypadku wystąpienia większych niż się spodziewano potrzeb leżących po stronie popytu rynkowego a także niwelowaniem zachodzących opóźnień w dostawach. Zapasy są także często gromadzone dla uzyskania niższej atrakcyjnej ceny zakupu (rabaty otrzymywane przy większych partiach) bądź ze względu na sezonowy charakter danego dobra [128]. Ze względu na miejsce powstawania zapasów w łańcuchu dostaw można wyróżnić ich następujące rodzaje:

- zapasy produkcji w toku (tworzone na różnych etapach procesu produkcji),
- zapasy wyrobów gotowych (stanowią produkty przeznaczone do sprzedaży, ich podstawowa funkcja to zaspokajanie popytu przedsiębiorstw handlowych),
- zapasy towarów (powstają w przedsiębiorstwach handlowych celem bezpośredniego zaspokojenia popytu konsumpcyjnego),

Pod względem funkcjonalnym można wyróżnić kolejne typy zapasów:

- zapas bieżący ( ten rodzaj zapasu bardzo często nazywany jest cyklicznym, gdyż jest zużywany przez firmę w toku normalnego funkcjonowania i jest odnawiany w rutynowym procesie zamawiania),
- zapas w produkcji (nazywany także produkcją w toku, stanowi materiały i półprodukty na etapie wytwarzania oraz zapasy w drodze,
- zapas sezonowy (gromadzony jest aby zaspokoić popyt na produkt w całym roku lecz który jest wytwarzany jedynie sezonowo),
- zapas bezpieczeństwa (stanowi bufor dla opóźnień w dostawach oraz w sytuacji zwiększonego zapotrzebowania na produkt),
- zapas spekulacyjny (tworzony w sytuacji spodziewanej zwyżki cen, zmian kursów walutowych),
- zapas martwy (często określane również jako zbędny bądź nadmierny, którego utrzymanie przez firmę nie jest uzasadnione ekonomicznie),

Pomimo wdrażania coraz to bardziej efektywnych systemów *Just in time* oraz systemów planowania zapotrzebowania materiałowego ERP – Enterprise Resource Planning nie jest do końca możliwa całkowita eliminacja zapasów rzeczowych. Powodem takiego stanu jest niewątpliwie fakt, iż większość procesów zachodzących w gospodarce jest stochastyczna, co sprawia że dają się przewidzieć jedynie z większym lub mniejszym prawdopodobieństwem. Wobec powyższego decyzje podejmowane w obszarze kontrolowania i sterowania poziomem zapasów są podejmowane zazwyczaj w warunkach ryzyka i niepewności. Przez to jednym z głównych celów przedsiębiorstw jest dążenie do minimalizacji poziomu zapasów oraz kosztów związanych z ich tworzeniem, a także dotrzymanie założonego poziomu obsługi klienta.

## 2.3 WYBRANE ASPEKTY LOGISTYCZNYCH KOSZTÓW OBSŁUGI ZAPASÓW

Koszty związane z obsługą zapasów stanowią obok kosztów transportu istotną składową pozostałych kosztów logistycznych. *Ogólnie rzecz biorąc koszty logistyczne to wyrażone w pieniądzu zużycie pracy żywej, środków i przedmiotów pracy, wydatki finansowe oraz inne ujemne skutki zdarzeń nadzwyczajnych, które są powodowane przepływem dóbr materialnych (surowców, materiałów, wyrobów, towarów) w przedsiębiorstwie i między przedsiębiorstwami, a także utrzymaniem zapasów [128].*

Na wielkość kosztów obsługi zapasów ma wpływ szereg różnych czynników. Wśród najważniejszych zdecydowanie można wyróżnić:

- wielkość oraz rodzaj asortymentu który jest obsługiwany przez magazyn,
- rozmiar magazynu,
- typ obsługi magazynu (zmechanizowany albo automatyczny),
- poziom zaawansowania w zakresie technologii informatycznych wdrożonych w magazynie,
- podatność magazynową składowanych zapasów,

W praktyce ocena wielkości kosztów obsługi zapasów jest bardzo często trudna do osiągnięcia. Jednym z powodów takiego stanu jest fakt, iż tego typu koszty nie są z reguły wydzielone z ogólnego rachunku kosztów przedsiębiorstwa. Zazwyczaj są one ewidencjonowane na koncie kosztów ogólnych. Pojęcie kosztów obsługi zapasów ma znaczenie dosyć szerokie. Odnoszą się one bowiem do fizycznej obsługi zapasów (przyjęcie na magazyn, składowanie, wydanie) jak również do obsługi kredytów finansujących zapasy czy też braku zapasu.

Koszty obsługi zapasów można podzielić na trzy grupy: koszty tworzenia zapasów, koszty utrzymania zapasów oraz koszty wyczerpania zapasów.

Do pierwszej z wymienionych grup zalicza się koszty dostaw i przyjęć zapasów do magazynu. Należą do niej również koszty opracowywania zamówień oraz koszty przetwarzania informacji. Można zatem powiedzieć, że koszty tworzenia zapasów to przede wszystkim koszty procesów informacyjnych, utrzymania służb zaopatrzenia i zbytu. Natomiast drugą grupę tworzą koszty utrzymania zapasów w magazynie. Koszty utrzymania zapasów są często traktowane jako utrata możliwości bardziej opłacalnego wykorzystania „zamrożonego” w zapasach kapitału. W ramach niej można wskazać trzy składowe: koszty zaangażowanego kapitału w postaci kredytów na gromadzenie zapasów oraz ich ubezpieczenia, koszty magazynowania a także koszty spadku wartości zapasów na rynku. Na podstawie prac [128, 38] poniżej przedstawiono sposób wyznaczania wybranych kosztów obsługi zapasów.

Minimalizacja kosztów kapitału finansującego zapasy może mieć miejsce poprzez zastosowanie kompleksowych działań zmierzających do zapewnienia racjonalnego kształtowania poziomu oraz struktury zapasów.

Koszt ten można przedstawić następująco:

$$K_f = \overline{M}_z \cdot \overline{S}_o \quad (1)$$

gdzie:

$K_f$  - koszt zaangażowania kapitału,

$\overline{M}_z$  - przeciętny stan zapasów w rozpatrywanym okresie,

$\overline{S}_o$  - przeciętna stopa oprocentowania,

Istotnym elementem kosztów utrzymania zapasów są koszty magazynowania. Są one związane z kosztami składowania (koszty zapewnienia odpowiedniej przestrzeni i pojemności magazynu, urządzeń składowania, paliwa, energii itp.) oraz kosztami manipulacyjnymi przepływu towarów (czynności związane z przyjęciem dostawy jak odbiór ilościowy i jakościowy, transport do miejsc składowania itp.) Koszty magazynowania można wyznaczyć następująco:

$$K_m = \overline{M}_z \cdot S_m \quad (2)$$

gdzie:

$K_m$  – łączne koszty magazynowania,

$\overline{M}_z$  - przeciętny stan zapasów w rozpatrywanym okresie,

$S_m$  – empirycznie ustalony wskaźnik kosztów magazynowania wyrażony jako % wartości zapasów,

Trzecią składową kosztów utrzymania zapasów są koszty spadku ich wartości na rynku bądź inaczej mówiąc koszty „starzenia się” zapasów. Pewne zachodzące zmiany w cechach fizyczno – chemicznych towarów na skutek długotrwałego przechowywania bardzo często powodują spadek wartości użytkowej produktu częściowy bądź całkowity. Może również pojawić się sytuacja w której posiadane zapasy nie są w stanie pełnić funkcji do których zostały przystosowane. Jest tutaj mowa przede wszystkim o dokonującym się nieustannie postępie technologicznym, przez który produkty zastępowane są coraz nowszymi, zmienności popytu wywołanej wieloma czynnikami, przykładowo modą lub sezonowością. Zatem zmniejszenie bądź całkowita utrata wartości użytkowej produktu na skutek wspomnianych sytuacji generuje niekorzystne skutki ekonomiczne. Źródła tychże kosztów odnoszą się w dużej mierze do warunków kształtowanych przez rynek. Dlatego ważnym elementem który może wpłynąć na ich obniżenie jest sporządzanie możliwie dokładnej analizy struktury popytu oraz prognoz.

Ostatnią grupą kosztów zapasów są koszty wyczerpania zapasów. Opisują one utratę korzyści jakie przedsiębiorstwo mogłoby osiągnąć w sytuacji gdyby posiadało wymagany zapas towaru we właściwej ilości miejscu i czasie. W zależności od rodzaju przedsiębiorstwa oraz jego funkcji w łańcuchu dostaw brak zapasu może generować zakłócenia w procesie produkcji, dystrybucji, kary finansowe z tytułu nie dostarczenia towaru do klienta, dodatkowe koszty transportu związane z nieplanowanymi, „awaryjnymi” dostawami celem uzupełnienia zapasu itp. A więc wśród tych kosztów można wyróżnić koszty ponoszone niezależnie od



wielkości braku jak również zależne od jej wielkości. Koszty stałe można obliczyć następująco:

$$KS_{bz} = KB \cdot p(B) \cdot l_d \quad (3)$$

gdzie:

$KS_{bz}$  – koszty stałe braku zapasu,

$KB$  - koszt ponoszony w sytuacji zaistnienia braku w zapasie (np. wysokość kary umownej, wielkość dodatkowych kosztów transportu),

$p(B)$  – prawdopodobieństwo wystąpienia braku w danym cyklu uzupełnienia zapasu,

$l_d$  – liczba wykonanych dostaw w rozpatrywanym okresie,

Koszty zmienne można wyznaczyć w następujący sposób:

$$KZ_{bz} = k_b \cdot NB \quad (4)$$

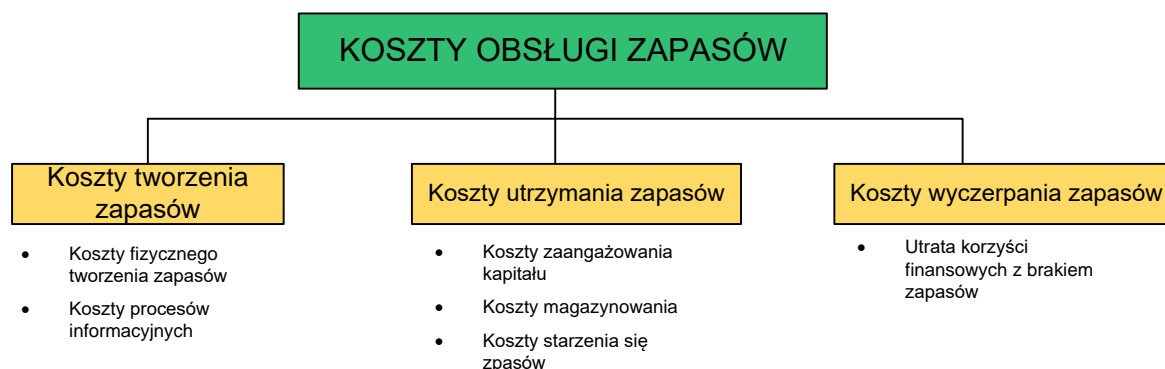
gdzie:

$KZ_{bz}$  – koszty zmienne braku zapasu,

$k_b$  - koszt ponoszony w przypadku zaistnienia braku jednej jednostki zapasu (np. wysokość kary umownej za niedostarczenie jednej sztuki towaru lub wielkość utraconej marży od niesprzedanej pojedynczej jednostki towaru),

$NB$  - przeciętna ilość brakującego towaru w zapasie dla rozpatrywanego okresu czasu,

Można stwierdzić, że koszty wyczerpania zapasu są z reguły skutkiem mało efektywnego procesu planowania, prognozowania popytu, zarządzania strumieniami przepływu materiałów. Oczywiście należy zdawać sobie sprawę, że nie zawsze jest możliwe całkowite wyeliminowanie tego typu kosztów. Należy jednak dążyć do usprawnienia zarządzania procesami logistycznymi celem minimalizacji tych kosztów. Przedstawioną strukturę kosztów obsługi zapasów przedstawia rys. 6.



**Rys. 6.** Struktura kosztów obsługi zapasów

*Źródło: opracowanie własne na podstawie [128]*

## 2.4 KLASYFIKACJA MODELI W SYSTEMACH STEROWANIA ZAPASAMI

W praktyce nie jest możliwa całkowita likwidacja zapasów w ogniwach łańcucha dostaw. Dlatego też kluczową sprawą powinny być działania przedsiębiorstw skoncentrowane na dążeniach do optymalnego i racjonalnego nimi sterowania, poprzez wykorzystanie właściwych metod i narzędzi komputerowych. Pojęcie sterowania wiąże się z takim oddziaływaniem na dany obiekt aby osiągnąć określony cel. Efekt sterowania jest najczęściej związany ze zmianą właściwości a mówiąc szerzej ze zmianą stanu obiektu. Obiekt, na który się oddziałuje podczas sterowania przyjęło się nazywać obiektem sterowania. *Sterowanie to celowe oddziaływanie na obiekt sterowany w celu otrzymania zamierzonych zmian przebiegu procesów zachodzących w obiekcie sterowania lub zamierzonego stanu sterowanego systemu w danej chwili, które uważa się za pożądane.* Zatem w odniesieniu do teorii zapasów pojęcie sterowania można rozumieć jako proces decyzyjny, który ma na celu określenie dla danego modelu stanu zapasów ile należy zakupić towarów oraz w jakich momentach czasu aby przy minimalnych kosztach zapasów zapewnić wymagany poziom obsługi klienta [149].

Wśród istniejącej literatury dotyczącej problematyki sterowania zapasami odnaleźć można wiele różnych podejść oraz systemów kontrolowania poziomu zapasów. System zapasów może być rozumiany jako zbiór powiązanych za sobą obiektów w postaci pojedynczego podsystemu składowania lub grupy powiązanych za sobą podsystemów składowania (przykładowo magazyn centralny i grupa magazynów regionalnych), wraz z określonymi specyfikacjami funkcjonalnymi zewnętrznymi i wewnętrznymi tych podsystemów np. struktura powiązań systemowych, liczba dostawców, odbiorców, rodzaj towaru, którego poziom zapasów podlega sterowaniu w oparciu o określoną metodę (model) odnawiania zapasu. Dla rozwiązywania różnych praktycznych problemów np. sterowania zapasami tworzone są adekwatne modele systemów zapasów. Modele te mają na celu uwzględnić różne istotne praktycznie aspekty, dążąc do możliwie dokładnego odwzorowania warunków odpowiadających rzeczywistości. Dlatego na samym początku rozważań warto dokonać wstępnej klasyfikacji modeli sterowania zapasami według pewnych kryteriów. Na podstawie rekomendacji zawartych w pracach [108], [126], które szczegółowo dokonują typologii metod odnawiania zapasów, zasadnym jest podział ze względu na:

- **Strukturę systemu zapasów**

W przypadku tego kryterium można rozróżnić systemy sterowania jednoszczeblowe odnoszące się do pojedynczego magazynu oraz wieloszczeblowe rozpatrujące jednocześnie większą liczbę punktów składowania. Dodatkowo struktura systemu zapasów może uwzględniać również liczbę dostawców oraz odbiorców punktu składowania.

- **Specyfikę parametrów systemu zapasów**

Na każdy system zapasów oddziałuje proces popytu na dany towar jak również proces uzupełniania zapasu. Natura tych procesów może w kluczowy sposób wpływać na efektywność i zachowanie się systemu zapasów. Stąd można wskazać modele zapasów o popycie deterministycznym bądź stochastycznym. W tym drugim przypadku rozkład prawdopodobieństwa może być całkowicie znany wraz z parametrami lub znany tylko pod względem typu rozkładu bądź też nieznan w zupełności. Podobnie dotyczy to również

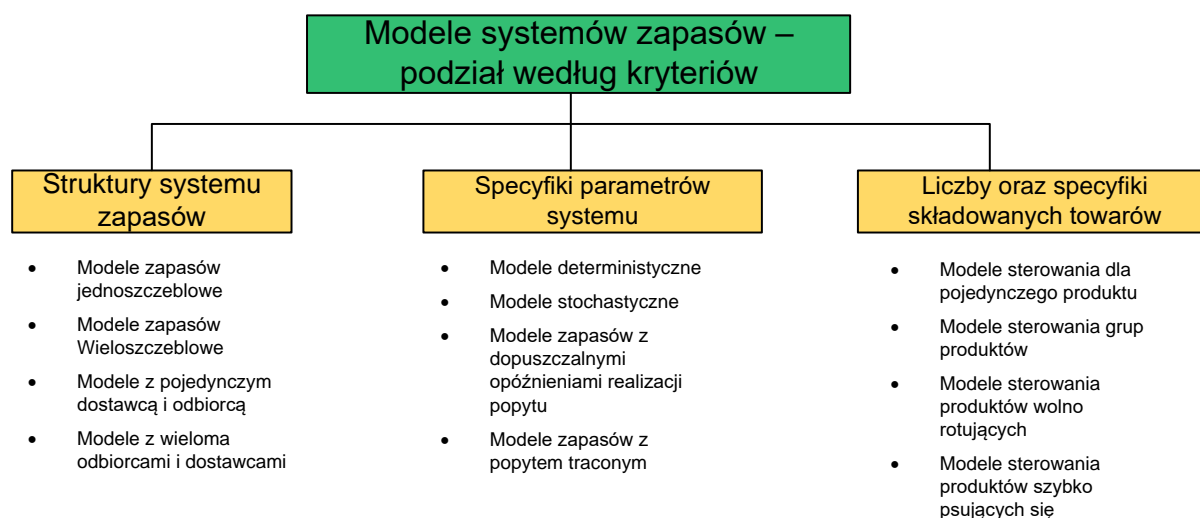


charakterystyki procesu odnawiania zapasu i czasu realizacji dostawy. W ramach tego kryterium można również wskazać modele w których dopuszczalna jest realizacja popytu dla klienta z pewnym opóźnieniem jak również modele z całkowicie traconym popytem na skutek braku zapasu.

- **Liczby oraz specyfikę składowanych towarów**

Ze względu na to kryterium podziału można wskazać modele odnawiania zapasów pojedynczych produktów jak również modele sterowania zapasami wielu produktów jednocześnie. Dostępne metody uwzględniają także ich specyfikę a mianowicie modele sterowania dla produktów podatnych na składowanie bądź też szybko psujących, szybko rotujących lub o popycie nieciągłym.

W formie graficznej klasyfikacja modeli zapasów według przedstawionych powyżej kryteriów przedstawiona jest na schemacie rys. 7.



**Rys. 7.** Klasyfikacja modeli zapasów

*Źródło: opracowanie własne na podstawie [128, 108, 94]*

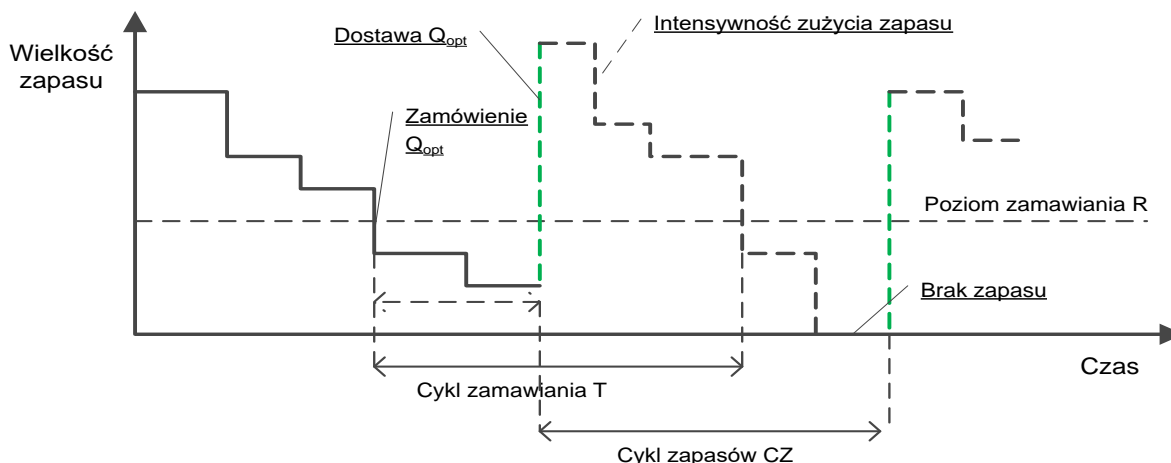
## 2.5 KLASYCZNE MODELE STEROWANIA ZAPASAMI

Przedstawione w niniejszej pracy metody tworzenia i kontrolowania zapasów będą dotyczyły popytu niezależnego czyli takiego, który jest utożsamiany z zapotrzebowaniem na wyroby gotowe. W teorii zapasów zazwyczaj wyróżnia się dwa klasyczne modele sterowania zapasami:

- model poziomu zamawiania (Re-order Point – ROP),
- model cyklu zamawiania (Re-order Cycle – ROC),

W przypadku pierwszego przegląd aktualnego stanu zapasów jest dokonywany na bieżąco, stąd podejście to należy do grupy metod ciągłego przeglądu zapasów. W modelu tym parametrami sterowania jest optymalna wielkość zamawianej partii towaru  $Q_{opt}$  oraz pewien poziom alarmowy  $R$  zapasu. W sytuacji gdy stan zapasu danego produktu będzie

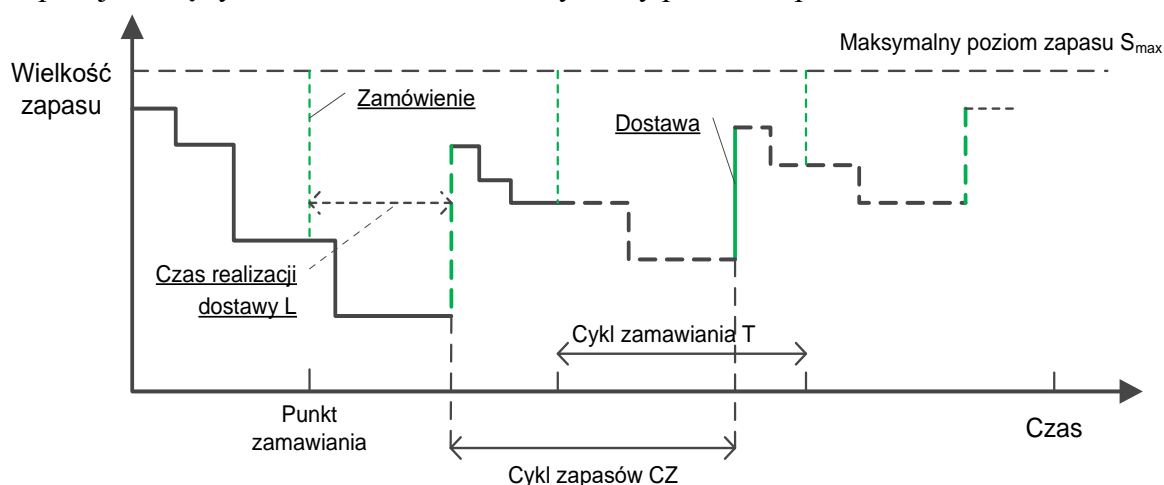
równy bądź spadnie poniżej tej wartości należy wystawić zamówienie uzupełniające o wielkości  $Q_{opt}$  celem niedopuszczenia do całkowitego wyczerpania zapasu rys. 8. Kolorem zielonym oznaczono chwile czasowe, w których nadchodzą kolejne dostawy uzupełniające zapas.



**Rys. 8.** Schemat modelu poziomu zamawiania

Źródło: opracowanie własne na podstawie [149]

Analizując schemat graficzny modelu (rys.8) można wywnioskować, iż stałym parametrem w tym modelu jest wielkość dostawy, natomiast zmienne są momenty zgłaszania zamówienia. Nieco inna sytuacja zachodzi w modelu cyklu zamawiania. Tam kolejne zamówienia uzupełniające wystawiane w stałych cyklach, podczas gdy wielkości dostawy są zmienne. W ten sposób należy on do grupy metod o okresowym przeglądzie zapasów. W modelu tym w pewnych ustalonych punktach czasowych tzw. punktach zamawiania ma miejsce wystawienie zamówienia w wielkości która jest różnicą pomiędzy maksymalnym założonym poziomem zapasu ( $S_{max}$ ) a bieżącym stanem zapasu danego towaru w magazynie. W tym podejściu wielkość zamawianego towaru jest zmienna oraz zależy od wielkości zapasu w punkcie zamawiania. Przedstawioną sytuację ilustruje rys. 9. Zatem normami sterowania w tym podejściu są cykl zamawiania oraz maksymalny poziom zapasu.




**Rys. 9.** Schemat modelu cyklu zamawiania

Źródło: opracowanie własne na podstawie [149]

### 2.5.1 Klasyczny model poziomu zamawiania

Przedstawiona w poprzednim rozdziale idea modelu poziomu zamawiania zakłada iż jedną z norm sterowania jest optymalna wielkość dostawy  $Q_{opt}$  zwana inaczej Ekonomiczną Wielkością Zamówienia – EOQ (*Economic Quantity Order*) oraz poziom zamawiania  $R$ . Wartość  $Q_{opt}$  ma na celu minimalizację łącznych kosztów systemu zapasów w zadanym okresie (najczęściej w okresie roku). Wobec tego łączne koszty zapasów są sumą kosztów tworzenia i utrzymania zapasów oraz są wyrażone jako funkcja zmiennej  $Q$ . Wykorzystując wyjściową postać modelu EOQ do wyznaczenia optymalnej partii dostawy wymagane jest przyjęcie następujących założeń: intensywność zużycia zapasów  $P$  na dany okres jest znana i stała, czas realizacji dostawy  $L$  (czas upływający od momentu złożenia zamówienia do chwili przyjscia dostawy) przyjmuje również stałe i znane wartości jak również stałe są jednostkowe koszty utrzymania zapasów. W związku z tym że każde zamówienie opiewa na tę samą wielkość realizowane dostawy są jednakowe i w stałych odstępach czasu. Dodatkowo przyjmowane jest założenie że zapotrzebowanie w każdym momencie musi być zaspokojone [94]. Sytuację tę przedstawia rys. 10.



**Rys. 10.** Poziom zapasów w czasie dla modelu EOQ

*Źródło: opracowanie własne*

Na podstawie schematu (rys.10.) równanie opisujące stan zapasu w dowolnej chwili czasu można przedstawić jako:

$$Z(t) = Q_{opt} - P \cdot t \quad (5)$$

gdzie:

$Z(t)$  - stan zapasu w danej chwili czasu,

$P$  – zużycie zapasu w jednym cyklu  $T$ ,

$Q_{opt}$  - wielkość dostawy,

Pierwszym krokiem do wyznaczenia wartości  $Q_{opt}$  jest wyznaczenie wyrażenia opisującego koszty zapasów w jednym cyklu zamawiania  $T$ :

$$K_{ZAPASÓW} = KU + k_z \quad (6)$$

gdzie:

$k_z$  – koszt realizacji jednej dostawy,

$KU$  – koszty utrzymania (magazynowania) zapasów,

Wobec powyższego koszt zapasów w pojedynczym cyklu można zapisać:

$$\begin{aligned} K_{ZAPASÓW}(Q) &= k_u \int_0^T Z(t) dt + k_z = k_u \int_0^T (Q - Pt) dt + k_z = k_u \left( Q \cdot T - \frac{P \cdot T^2}{2} \right) + k_z \\ &= k_u \frac{Q^2}{2P} + k_z \quad (7) \end{aligned}$$

gdzie:

$T = \frac{Q}{P}$  - długość pojedynczego cyklu,

$k_u$  - jednostkowy koszt utrzymania zapasów,

Jeśli przyjąć, że dla rozpatrywanego horyzontu czasu złożonego z  $n$  cykli o długości  $T$  całkowite zapotrzebowanie na produkt jest równe  $D=nP$ , to łączne koszty zapasów w tym okresie można zapisać następująco:

$$\text{ŁK}_{ZAPASÓW}(Q) = \frac{nP}{Q} \left\{ k_u \frac{Q^2}{2P} + k_z \right\} - \min \quad (8)$$

Korzystając z zasad rachunku różniczkowego i rozwiązując poniższe równanie można wyznaczyć optymalną wartość dostawy  $Q_{opt}$ .

$$\frac{d\text{ŁK}_{ZAPASÓW}}{dQ} = 0 \quad (9)$$

$$\frac{nk_u}{2} - \frac{nPk_z}{Q^2} = 0 \quad (10)$$

$$Q_{opt} = \sqrt{\frac{2Pk_z}{k_u}} \quad (11)$$

Narzucone na przedstawiony model EOQ optymalnej wielkości dostawy założenia i warunki sprawiają, że jej stosowalność w praktyce jest dosyć mocno ograniczona. W rzeczywistości rzadko kiedy parametry modelu jak popyt, czas dostawy itp. mają charakter deterministyczny. Dlatego w celu zwiększenia możliwości jej stosowania wykonywane są jej dodatkowe modyfikacje.

Drugą normą sterowania w modelu poziomym zamawiania jest parametr  $R$ . Opisuje on poziom zapasu przy którym należy niezwłocznie złożyć zamówienie uzupełniające zapas. Poziom zapasu równy  $R$  ma na celu zapewnić obsługę popytu w czasie realizacji dostawy. W klasycznym dosyć wyidealizowanym przypadku kiedy popyt oraz czas dostawy są wartościami stałymi poziom zamawiania jest równy:

$$R = P \cdot L \quad (12)$$

gdzie:

$P$  - popyt w założonym okresie,

$L$  - czas dostawy jednego zamówienia,

W sytuacji kiedy wielkość popytu oraz czas realizacji dostawy są wartościami znacząco zmiennymi w czasie poziom zamawiania  $R$  jest powiększany o dodatkową wartość zapasu, często nazywaną zapasem bezpieczeństwa  $SS$  (Safety Stock). Wówczas poziom zamawiania może przybrać następującą postać:

$$R = \bar{P} \cdot \bar{L} + k \sqrt{\bar{L}\sigma_P^2 + \bar{P}^2\sigma_L^2} \quad (13)$$

gdzie:

$\bar{P}$  - średni popyt w danym okresie,

$\bar{L}$  - średni czas realizacji dostawy,


$\sigma_P^2$  - wariancja popytu w danym okresie,

$\sigma_L^2$  - wariancja czasu realizacji zamówienia,

$k$  – współczynnik bezpieczeństwa czyli wielkość wynikająca z przyjętego poziomu obsługi klienta,

### 2.5.2 Model EOQ z dopuszczalnym niedoborem zapasów

W wielu przypadkach założenie pełnego zaspokojenia popytu klientów jest niezwykle kosztowne, a potencjalne straty wynikłe z niewielkiego niedoboru towaru mogą okazać się niewiele znaczące. Wobec tego można wprowadzić pewną relaksację założenia o pełnym zaspokojeniu popytu dla klienta znanego z klasycznej wersji modelu EOQ. Zgodnie z tym zakłada się pewien dopuszczalny poziom niedoboru towaru  $B$  przez pewien okres czasu. Sytuacja ta może odpowiadać przypadkowi kiedy popyt klienta zostanie zrealizowany z zaakceptowanym przez niego opóźnieniem. Opisaną sytuację przedstawia schemat rys. 11.



Rys. 11. Zużycie zapasu w czasie w sytuacji założenia planowego niedoboru

Źródło: opracowanie własne

Dla tak postawionych warunków należy podjąć decyzje nie tylko jaka powinna być wielkość dostawy lecz również jaki powinien być maksymalny dopuszczalny poziom niedoboru zapasu w określonym czasie. Rozważany przypadek zakłada iż, z chwilą nadejścia

dostawy zaległy popyt jest zaspokajany pozostawiając tym samym  $Q_{opt} - B$  jednostek zapasu do dyspozycji.

W analizowanej sytuacji cykl zamawiania  $T$  jest sumą dwóch podcykli  $T_1$  oraz  $T_2$ . Pierwszy z nich obejmuje czas w którym zapas pokrywa zapotrzebowanie o stałej intensywności  $P$  natomiast drugi, czas kiedy poziom braku zapasu rośnie od zera do założonej wartości  $B$ . Wobec tego można sformułować warunki odnoszące się do tych sytuacji:

$$Q - B = T_1 P \quad \Rightarrow \quad T_1 = \frac{Q - B}{P} \quad (14)$$

$$B = T_2 P \quad \Rightarrow \quad T_2 = \frac{B}{P} \quad (15)$$

$$Q = P \cdot (T_1 + T_2) = P \cdot T \quad (16)$$

Zatem równanie, które opisuje poziom zapasu w danej chwili czasu  $t$  przyjmuje postać:

$$z(t) = -P \cdot t + Q - B \quad (17)$$

W rozważanym przypadku oprócz ponoszonych kosztów utrzymania zapasów oraz kosztów realizacji zamówień pojawia się dodatkowa składowa opisująca koszt niedoboru zapasu który ma miejsce w okresie  $T_2$ . Postępując analogicznie jak w przypadku klasycznej wersji EOQ łączny koszt zapasów, który teraz jest funkcją dwóch zmiennych w jednym cyklu zamówień  $T$  można zapisać jako:

$$\begin{aligned} K_{ZAPASÓW}(Q, B) &= k_u \int_0^{T_1} z(t) dt + k_b \left| \int_{T_1}^T z(t) dt \right| + k_z \\ &= k_u \int_0^{T_1} -P \cdot t + Q - B dt + k_b \left| \int_{T_1}^T -P \cdot t + Q - B dt \right| + k_z \\ &= \frac{k_u(Q - B)^2}{2P} + k_b \frac{B^2}{2P} + k_z \quad (18) \end{aligned}$$

gdzie:

$B$  – dopuszczalny poziom niedoboru zapasu,

$k_b$  - jednostkowy koszt braku zapasu,

Dla przyjętego okresu planistycznego złożonego z  $n$  cykli o długości  $T$  łączne koszty zapasów będą miały postać:

$$\text{ŁK}_{ZAPASÓW}(Q, B) = \frac{nP}{Q} \left( \frac{k_u(Q - B)^2}{2P} + k_b \frac{B^2}{2P} + k_z \right) = \frac{nk_u(Q - B)^2}{2Q} + \frac{nk_b B^2}{2Q} + \frac{nk_z P}{Q}$$

Optymalne wartości  $Q$  oraz  $B$  otrzymuje się wskutek rozwiązania poniższego układu równań:

$$\begin{cases} \frac{d\mathbb{L}K_{ZAPASÓW}}{dQ} = 0 \\ \frac{d\mathbb{L}K_{ZAPASÓW}}{dB} = 0 \end{cases}$$

W rezultacie ostateczne rozwiązanie przybiera postać:

$$\begin{cases} Q = \sqrt{\frac{2Pk_z}{k_u}} \sqrt{\frac{k_b + k_u}{k_b}} \\ B = \sqrt{\frac{2Pk_z}{k_b}} \sqrt{\frac{k_u}{k_b + k_u}} \end{cases} \quad (21)$$

Analizując łączną funkcję kosztów (19) można wykazać pewne zależności a mianowicie jeżeli jednostkowe koszty realizacji zamówień będą wzrastały to automatycznie wielkość dostawy  $Q$  będzie wzrastać zmniejszając tym samym liczbę wykonywanych dostaw. Z drugiej strony jeżeli koszty utrzymania zapasu  $k_u$  będą wzrastały wpłynie to na zmniejszenie wielkości dostaw. W przypadku kosztów niedoboru  $k_b$  ich wzrost będzie wpływał na zmniejszenie dopuszczalnej wartości  $B$ .

### 2.5.3 Klasyczny model cyklu zamawiania

W celu zastosowania drugiego z przedstawionych klasycznych modeli sterowania zapasami jakim jest model stałego cyklu zamawiania należy wyznaczyć dwie normy sterowania a mianowicie optymalny cykl zamawiania  $T_{opt}$  oraz maksymalny poziom zapasu  $S_{max}$ . W tym celu korzysta się z następujących sformułowań:

$$T_{opt} = \frac{T_p}{n_{opt}} \quad (22)$$

$$n_{opt} = \frac{\bar{D}}{Q_{opt}} \quad (23)$$

gdzie:

$T_p$  - długość rozpatrywanego okresu planistycznego np. dni, tygodnie, miesiące, lata,

$n_{opt}$  - liczba dostaw w ciągu rozpatrywanego okresu  $T_p$ ,

$\bar{D}$  - przeciętny popyt w okresie planistycznym  $T_p$ ,

Na podstawie wyznaczonej optymalnej długości cyklu zamawiania wyliczany jest maksymalny poziom zapasu danego produktu.



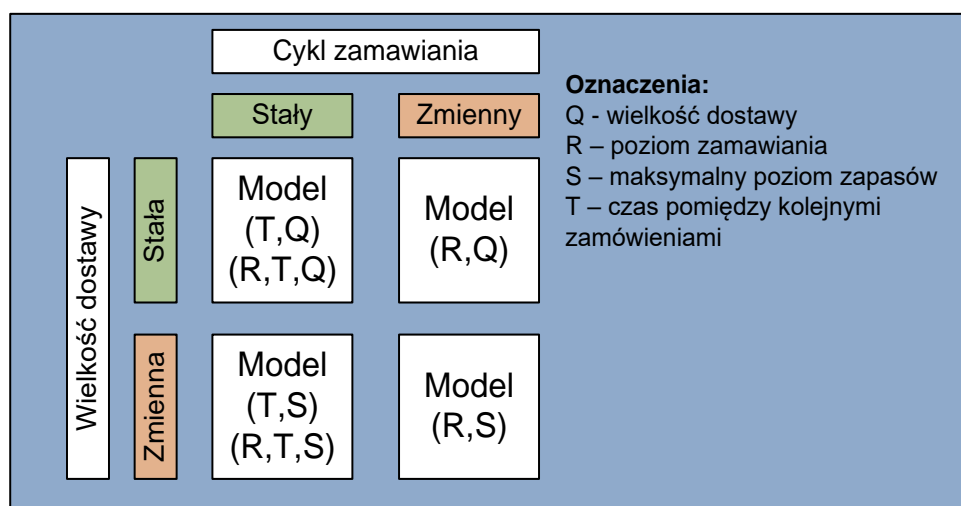
$$S_{max} = \bar{P}(\bar{L} + T_{opt}) + k\sqrt{\bar{L} + T_{opt}} \quad (24)$$

Wyznaczony w ten sposób zapas maksymalny ma na celu zaspokojenie zapotrzebowania w całym okresie cyklu zamawiania oraz przeciętnym czasie realizacji dostawy. Dodatkowo poziom zapasu jest powiększany o pewien zapas bezpieczeństwa także w okresie  $\bar{L} + T_{opt}$ . Wielkość dostawy w tym przypadku jest zmienna w czasie i jest wyznaczana na podstawie różnicy maksymalnego założonego zapasu  $S_{max}$  i jego poziomu aktualnego w okresie zamawiania  $T$ .

$$Q_T = S_{max} - z(T) \quad (25)$$

## 2.6 INNE WYKORZYSTYWANE MODELE STEROWANIA ZAPASAMI

Poza dwoma klasycznymi modelami sterowania przedstawionymi w poprzednim podrozdziale można zaprezentować również nieco inne modele. Ich cechą wspólną jest wykorzystanie pewnych podstawowych założeń z klasycznych modeli poziomu i cyklu zamawiania. W ten sposób stanowią one grupę tzw. modeli hybrydowych, w których zbiór norm sterowania jest kombinacją zbioru zmiennych decyzyjnych z przedstawionych dwóch podejść klasycznych. Rys. 12. przedstawia charakter (stałość w czasie, zmienność) parametrów sterowania w zależności od przyjętego modelu zapasów.



**Rys. 12.** Cechy parametrów sterowania w zależności od przyjętego modelu zapasów

*Źródło: opracowanie własne*

Na podstawie schematu (rys.12.) można dostrzec iż dla niektórych modeli pewna grupa parametrów sterowania przyjmuje wartości stałe natomiast część z nich jest zmienna w czasie. Reguły sterowania poziomem zapasów w tych modelach przedstawiają się następująco:



- **model (R, S)** Zamówienia na dostawy wystawiane są w momentach gdy poziom zapasu spadnie poniżej wartości  $R$ . Wielkość zamówienia na dostawę jest wyznaczana na podstawie wzoru:

$$Q_t = S_{max} - z(t) \quad (26)$$

gdzie:

$Q_t$  - wielkość zamówienia na dostawę w chwili  $t$  gdy poziom zapasów  $z(t) \leq R$ ,

Podejście to należy do grupy modeli ciągłego monitorowania zapasów, gdzie w dowolnym momencie istnieje możliwość zamówienia  $Q_t$  jednostek towaru.

- **model (R, Q)** Zamówienia na dostawy również wykonywane są w momentach kiedy poziom zapasu spadnie poniżej wyznaczonego poziomu  $R$  jednakże wielkość dostawy  $Q$  jest stała wyznaczana zazwyczaj z wykorzystaniem wzoru (11).
- **model (T, S)** Dla tego modelu w każdym stałym okresie czasu  $T$  dokonywane jest monitorowanie poziomu zapasów i wystawiane jest zamówienie na dostawę o zmiennej wielkości  $Q_T$  zgodnie ze wzorem (25).
- **model (T, Q)** W tym przypadku podobnie jak to miało miejsce dla modelu (T,S) monitorowanie zapasów odbywa się w stałych okresach  $T$  jednakże wielkość dostawy jest stała zazwyczaj wyznaczana ze wzoru (11).
- **model (R, T, Q)** Metoda ta bardzo często nazywana jest również modelem poziomu zamawiania w stałych cyklach zamawiania. W tym modelu monitorowanie zapasu odbywa się w ustalonych odstępach czasu  $T$  równych optymalnemu cyklowi zamawiania. W sytuacji kiedy w punkcie kontroli zapasu jego poziom spadnie poniżej wielkości  $R$  zamówienia na dostawy o stałych wielkościach są wystawiane.
- **model (R, T, S)** Model ten inaczej jest nazywany połączonym modelem poziomu zamawiania i stałego cyklu zamawiania. Ideą tej metody jest w pewien sposób podwójne zabezpieczenie na wypadek wystąpienia braku w zapasie. Zamówienia wystawiane są w sytuacjach kiedy zapas magazynowy spadnie poniżej wyznaczonego poziomu zamawiania  $R$  jak również w stałych punktach zamawiania odległych o  $T$  jednostek czasu. Koncepcja ta sprawia, iż metoda ma szczególną rekomendację do stosowania w odniesieniu do szczególnie wartościowych produktów [149].

Reasumując można stwierdzić iż modele typu (R, Q), (R, S), należą do grupy metod ciągłego monitorowania stanu zapasów podczas gdy modele typu (R, T, Q), (T, S) i (T, Q) należą do grupy metod okresowego przeglądu zapasów. Dodatkowo można wyodrębnić zarówno ich mocne jak i słabe strony. Najważniejsze z nich są przedstawione w Tabeli 1.

**Tabela 1.** Najważniejsze zalety i wady modeli okresowego i ciągłego monitorowania zapasów


Typ modelu	Wady	Zalety
<b>Modele ciągłego monitorowania poziomu zapasów</b>	<ul style="list-style-type: none"> <li>• trudność łączenia zamówień dla wielu produktów jednocześnie,</li> <li>• trudność w organizacji łącznych przewozów, zwłaszcza gdy transport musi odbywać się cyklicznie,</li> <li>• konieczność informatyzacji,</li> </ul>	<ul style="list-style-type: none"> <li>• aktualna informacja o poziomie zapasów,</li> <li>• możliwość stosowania dla zróżnicowanego asortymentu,</li> <li>• potrzebuje niższego poziomu zabezpieczającego,</li> </ul>
<b>Modele okresowego monitorowania poziomu zapasów</b>	<ul style="list-style-type: none"> <li>• brak aktualnej informacji o poziomie zapasów,</li> <li>• zwiększone ryzyko wyczerpania zapasu w sytuacji zwiększonej intensywności popytu na krótko przed dokonaniem przeglądu poziomu zapasu,</li> <li>• konieczność utrzymywania zwiększonego zapasu zabezpieczającego</li> </ul>	<ul style="list-style-type: none"> <li>• proste w zastosowaniu,</li> <li>• umożliwia grupowe łączenie zamówień na różne produkty,</li> <li>• łatwość organizacji łącznego przewozu</li> </ul>

## 2.7 POZIOM OBSŁUGI KLIENTA JAKO MIARA EFEKTYWNOŚCI W STEROWANIU ZAPASAMI

Obecnie jednym z najważniejszych celów przedsiębiorstw oprócz zapewnienia odpowiedniej jakości produktów oraz atrakcyjnej ceny jest dążenie do osiągnięcia właściwego poziomu obsługi klienta w postaci określonego czasu dostaw, powtarzalności, elastyczności, dostępności towarów. Aspekt ten w dużym stopniu rzutuje na pozycję firmy na rynku. Klientem w tym przypadku może być każdy odbiorca w relacji odbiorca – dostawca na różnych poziomach łańcucha dostaw. Jednakże w końcowym rozrachunku wysiłki wszystkich podmiotów powinny być skoncentrowane na klienta (odbiorcę) znajdującego się na końcu łańcucha logistycznego. *Poziom obsługi klienta jest definiowany jako wyrażona odpowiednią miarą jakość obsługi logistycznej* [38]. Przykładowymi wskaźnikami mierzącymi jakość obsługi są między innymi czas realizacji zamówienia, wskaźnik zgodności jakościowej, ilościowej i terminowej dostaw, wskaźnik elastyczności dostaw oraz dostępność towaru w zapasie.

Na potrzeby niniejszej pracy poziom obsługi klienta będzie odnosił się wyłącznie do miar opisujących dostępność towaru w zapasie. W tym przypadku poziom obsługi można rozumieć jako prawdopodobieństwo zaspokojenia popytu w cyklu uzupełniania zapasu. Takie pojmowanie poziomu obsługi będzie oznaczane jako  $pok_1$ . Przykładowo jeśli założony poziom obsługi będzie wynosił 95% oznacza to iż, z prawdopodobieństwem 0,95 popyt w okresie od chwili złożenia zamówienia do momentu nadejścia dostawy będzie obsłużony.

Przyjmując, że popyt w trakcie cyklu uzupełnienia zapasów ma rozkład normalny o średniej  $\bar{P}_L$  oraz odchyleniu standardowym  $\sigma_{\bar{P}_L}$  graficznie poziom obsługi można przedstawić jak na poniższym schemacie rys. 13.

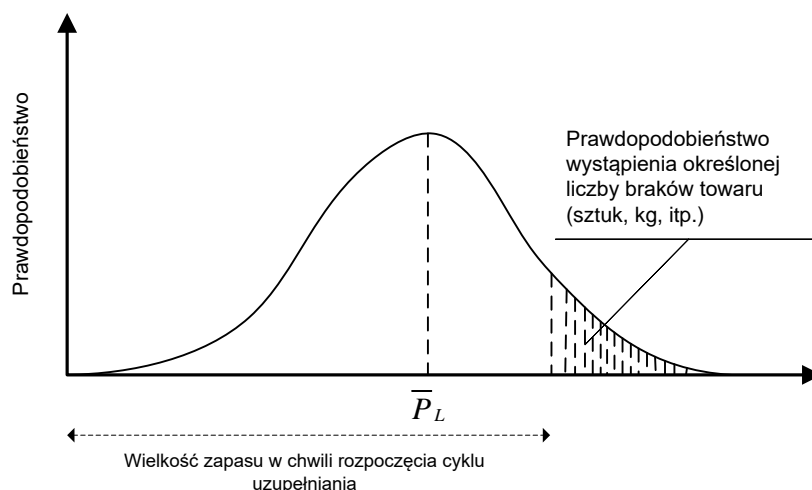


**Rys. 13.** Graficzna interpretacja poziomu obsługi klienta  $pok_1$   
*Źródło: opracowanie własne na podstawie [94]*

W ten sposób rozumiany poziom obsługi klienta jest wyznaczany z funkcji skumulowanego prawdopodobieństwa rozkładu popytu. Zdefiniowany w poprzednich paragrafach poziom ponownego zamawiania  $R$  jest ściśle powiązany z rozważanym poziomem obsługi. Według powyższego rysunku ilość zapasu równa  $\bar{P}_L$  pokrywa przeciętne zapotrzebowanie w trakcie cyklu uzupełnienia zapasu. Wobec tego istnieje 50% procent szans iż posiadany w tym okresie zapas nie pokryje zaistniałego popytu. W celu zwiększenia poziomu obsługi należy zatem przesunąć się na prawą stronę od wartości  $\bar{P}_L$ . Przesunięcie to stanowi wartość zapasu zabezpieczającego (SS – Safety Stock). Wielkość tego przesunięcia mierzona jest jako krotność odchylenia standardowego od przeciętnej wielkości  $\bar{P}_L$  stanowiąc tzw. współczynnik bezpieczeństwa  $k$ . Formalnie prawdopodobieństwo że popyt w trakcie czasu realizacji dostawy przyjmie wartość mniejszą lub równą  $R$  można zapisać wykorzystując dystrybuantę standardowego rozkładu normalnego w następujący sposób:

$$pok_1 = P(\bar{P}_L \leq R) = \Phi\left(\frac{R - \bar{P}_L}{\sigma_{\bar{P}_L}}\right) = \Phi\left(\frac{SS}{\sigma_{\bar{P}_L}}\right) \quad (27)$$

Powyższa interpretacja poziomu obsługi klienta sygnalizuje ryzyko wystąpienia braku nie określa natomiast w jakiej wielkości może okazać się zaistniały niedobór. W sytuacji w której istotny jest nie sam fakt wystąpienia niedoboru lecz jego wartość wyrażona przez liczbę brakujących jednostek towaru w zapasie, definiowany jest poziom obsługi klienta w ujęciu ilościowym poprzez wyznaczenie współczynnika ilościowej realizacji popytu  $W_{IR}$ . Opisuje on wartość popytu obsłużonego w stosunku do łącznego zapotrzebowania w przyjętym okresie planistycznym. W ten sposób postrzegany poziom obsługi będzie oznaczany jako  $pok_2$ . Rozważany przypadek można przedstawić w sposób przedstawiony na rys. 14.



**Rys. 14.** Idea interpretacji poziomu obsługi klienta w sensie ilościowym

*Źródło: opracowanie własne na podstawie [94]*

Dla przykładu  $pok_2 = 0.95$  oznacza, że w określonym cyklu uzupełnienia zostanie zrealizowane 95% zapotrzebowania na produkt. Ten sposób opisu poziomu obsługi klienta jest szczególnie ważny w sytuacji gdy z każdą brakującą pojedynczą sztuką towaru jest związana pewna kara finansowa bądź utracony zysk ze sprzedaży.

Na podstawie [38] współczynnik ilościowej realizacji popytu  $W_{IR}$  można opisać w następujący sposób:

$$pok_2 = W_{IR} = \frac{D_{T_p} - NB_{T_p}}{D_{T_p}} = \frac{\overline{Q_{T_p}} \cdot ld_{T_p} - E(nb) \cdot ld_{T_p}}{\overline{Q_{T_p}} \cdot ld_{T_p}} = \frac{\overline{Q_{T_p}} - E(nb)}{\overline{Q_{T_p}}} \quad (28)$$

gdzie:

$D_{T_p}$  – wielkość popytu w okresie planistycznym  $T_p$  np. Rok,

$NB_{T_p}$  – wielkość braków towaru zaobserwowana w okresie  $T_p$ ,

$\overline{Q_{T_p}}$  – przeciętna wielkość dostawy w okresie  $T_p$ ,

$ld_{T_p}$  – liczba wykonanych dostaw w okresie  $T_p$ ,

$E(nb)$  – oczekiwana wielkość braków towaru w pojedynczym cyklu uzupełniania zapasów,

Aby określić oczekiwaną wielkość braków towaru w jednym cyklu uzupełniania zapasu można w tym celu wykorzystać następujące sformułowanie:

$$E(nb) = \sum_{i=1}^{T_p} lb_i \cdot p(lb_i) \quad (29)$$

gdzie:

$E(nb)$  – oczekiwana wielkość braku towaru w pojedynczym cyklu uzupełniania zapasu,

$lb_i$  – zaobserwowana wielkość braków w kolejnych cyklach uzupełniania zapasu w trakcie okresu planistycznego  $T_p$ ,

$p(lb_i)$  – prawdopodobieństwo wystąpienia określonej wielkości braków w kolejnych  $i$ -tych cyklach uzupełniania zapasu w trakcie okresu planistycznego  $T_p$ ,

Jak wiadomo dla każdego z kolejnych cykli uzupełniania zapasu można określić zaistniałą w nim wielkość popytu. Zakładając, iż cykl ten rozpoczyna się z chwilą zaistnienia potrzeby złożenia zamówienia gdy poziom zapasu spadnie poniżej wartości  $R$  i trwa do momentu nadejścia dostawy w czasie  $L$  można wyznaczyć ewentualną liczbę brakujących sztuk towaru. Na podstawie obserwacji historycznych dokonując opisu za pomocą rozkładu prawdopodobieństwa zaistniałych wielkości braków można obliczyć parametr  $p(lb_i)$  niezbędny do wyznaczenia oczekiwanej liczby braków w pojedynczym cyklu.

W sytuacji kiedy system kontroli zapasów dopuszcza realizację popytu klienta z pewnym opóźnieniem na skutek chwilowego braku zapasu warto przytoczyć jeszcze jeden wskaźnik poziomu obsługi a mianowicie współczynnik czasu oczekiwania klienta na realizację zamówienia  $W^o$ . Zakładając że wybrany system zapasów obsługuje pewną losową liczbę zamówień od klientów  $O^\tau$  w pewnym interwale  $\tau$  wówczas można również wyodrębnić liczbę zamówień od klientów  $O_w^\tau$  która będzie zrealizowana z opóźnieniem po dokładnie  $w$  cyklach. Zatem współczynnik  $W^o$  definiowany jest w następujący sposób [147]:

$$W^o: P\{W^o = w\} = p_w^o = \frac{E(O_w^\tau)}{E(O^\tau)} \quad \bigwedge_{w \in W^o} \quad (30)$$

$$p_w^{o*} = \frac{O_w^{\tau*}}{\sum_{w=0}^{\infty} O_w^{\tau*}} \quad (31)$$

Wartość  $p_w^{o*}$  jest nieobciążonym estymatorem prawdopodobieństwa, iż pewna liczba zamówień od klientów zostanie zrealizowana z opóźnieniem  $w$ .

Podsumowując, spojrzenie na poziom obsługi jako prawdopodobieństwo wystąpienia braku jest dosyć łatwe do wyznaczenia i często wykorzystywane w praktyce. Jednakże posiada on pewną wadę, gdyż nie uwzględnia wielkości dostawy  $Q$ . Jeśli jej wielkość jest odpowiednio duża to pokrywa ona popyt przez większą ilość czasu pomimo iż wyznaczony w ten sposób poziom obsługi  $pok_1$  może okazywać się niski. Z drugiej strony w przypadku kiedy wielkość dostawy jest odpowiednio mała to faktyczny poziom obsługi może okazać się niski pomimo iż wyznaczona wartość  $pok_1$  może przyjąć pozornie wysoką wartość. Dlatego w wielu przypadkach poziom obsługi  $pok_2$  lub współczynnik czasu oczekiwania klienta w bardziej reprezentatywny sposób opisują faktyczny poziom obsługi klienta, gdyż oprócz faktu zaistnienia braku opisują stopień obsłużenia popytu oraz czas realizacji popytu zaległego. Dobór właściwego sposobu mierzenia poziomu obsługi jest zależny od wielu czynników. Należą do nich między innymi specyfika klientów, ich oczekiwania, koszty braku zapasów jak również i wielkość kosztów utrzymywania wysokiego wskaźnika obsługi. Z praktycznego punktu widzenia nie jest możliwe wyznaczenie jednakowego poziomu obsługi dla wszystkich rodzajów towarów głównie ze względu na duże koszty. Dlatego bardzo często wyznacza się miary poziomu obsługi wewnątrz grup produktów jednolitych ze względu na ich określone atrybuty.

## 2.8 INNE WYBRANE MIARY EFEKTYWNOŚCI STEROWANIA ZAPASAMI

Poza przedstawionymi w poprzednim paragrafie miarami jakości obsługi klienta można wskazać kilka dodatkowych wskaźników oceniających efektywność przyjętego sposobu kontrolowania zapasów w przedsiębiorstwie. Jednym z nich jest wskaźnik prawidłowości kształtowania się zapasów. Ma on na celu porównanie rzeczywistego poziomu zapasów danego produktu w stosunku do przyjętej normy zapasu (np. zapas maksymalny, minimalny, sezonowy bądź średni) [42]. Wskaźnik ten jest wyznaczany ze wzoru:

$$Z_m = \frac{Z_{rz}}{Z_n} \quad (32)$$

gdzie:

$Z_m$  – wskaźnik prawidłowości kształtowania się zapasów,

$Z_{rz}$  – rzeczywista wielkość zapasów,

$Z_n$  – wielkość zapasu według przyjętej normy,

Pewną uzupełniającą miarą do wskaźnika  $Z_m$  jest wskaźnik wielkości zapasu w określonej jednostce czasu (np. dniu, tygodniu, miesiącu lub roku)  $M_z$ . Pozwala on wyznaczyć różnicę między wydaniem zapasu a jego przyjęciem.

$$M_z = Z + (Z_p - Z_w) \quad (33)$$

gdzie:

$Z$  – początkowa wielkość zapasów na początku danego okresu,

$Z_p$  – wielkość zapasów przyjęta do magazynu,

$Z_w$  – wielkość zapasów wydana z magazynu,

Innym parametrem oceny przyjętego sposobu kontrolowania zapasów jest miernik wartości zapasów. Opisuje on jednostkowy koszt danego asortymentu w zapasie [56]. Wartość tego kosztu wyznaczana jest ze wzoru:

$$M_{wz} = \frac{Z_w}{Z_s} \quad (34)$$

gdzie:

$M_{wz}$  – miernik wartości zapasów,

$Z_w$  – średnia wartość zapasów w rozpatrywanym okresie wyrażona w jednostkach pieniężnych

$Z_s$  – średnia wielkość zapasów wyrażona w jednostkach naturalnych dla danego artykułu (szt.  $m^2$ ,  $m^3$ , itp.),

Kolejnym istotnym wskaźnikiem o którym należy wspomnieć jest wskaźnik rotacji zapasów. Może on być wyznaczany dla każdego rodzaju asortymentu osobno lub też dla pewnych grup produktów. Szybkość obiegu zapasów jest nazywana rotacją. Zazwyczaj wskaźnik rotacji jest obliczany w postaci liczby rotacji bądź dni. Liczbę rotacji wyznacza się



jako stosunek wielkości obrotu magazynowego do przeciętnej wielkości zapasów w danym okresie.

$$M_{LR} = \frac{O_w}{Z_{\dot{s}}} \quad (35)$$

gdzie:

$M_{LR}$  – wskaźnik liczby rotacji,

$O_w$  – obrót magazynowy według wielkości wydań z magazynu w rozpatrywanym okresie,

$Z_{\dot{s}}$  – średnia wielkość zapasu w rozpatrywanym okresie,

Natomiast współczynnik rotacji mierzony w dniach dostarcza wiedzy ile dni dany zapas pozostawał w magazynie. Można go wyznaczyć korzystając z poniższego wzoru:

$$M_{RD} = \frac{Z_{\dot{s}}}{O_w} = \frac{Z_{\dot{s}}D}{O_w} \quad (36)$$

gdzie:

$M_{RD}$  – wskaźnik rotacji zapasów wyrażony w dniach,

$O_w$  – wielkość dziennych wydań zapasów z magazynu,

$Z_{\dot{s}}$  – średnia wielkość zapasów w danym okresie,

$D$  – liczba dni w danym okresie,

Dodatkową miarą która może określać w pewnym sensie jakość sterowania zapasami jest miernik stosunku wielkości zapasów do wielkości sprzedaży. Wskaźnik ten ma na celu dokonanie oceny zmian wartości zapasu w miarę wzrostu sprzedaży [143]. Wartość tego wskaźnika można obliczyć następująco:

$$M_{zs} = \frac{Z_{\dot{s}}}{S_n} \quad (37)$$

gdzie:

$M_{zs}$  – wskaźnik stosunku wielkości zapasów do wielkości sprzedaży,

$Z_{\dot{s}}$  – średnia wielkość zapasów w danym okresie wyrażona w jednostkach pieniężnych,

$S_n$  – sprzedaż netto w jednostkach pieniężnych,

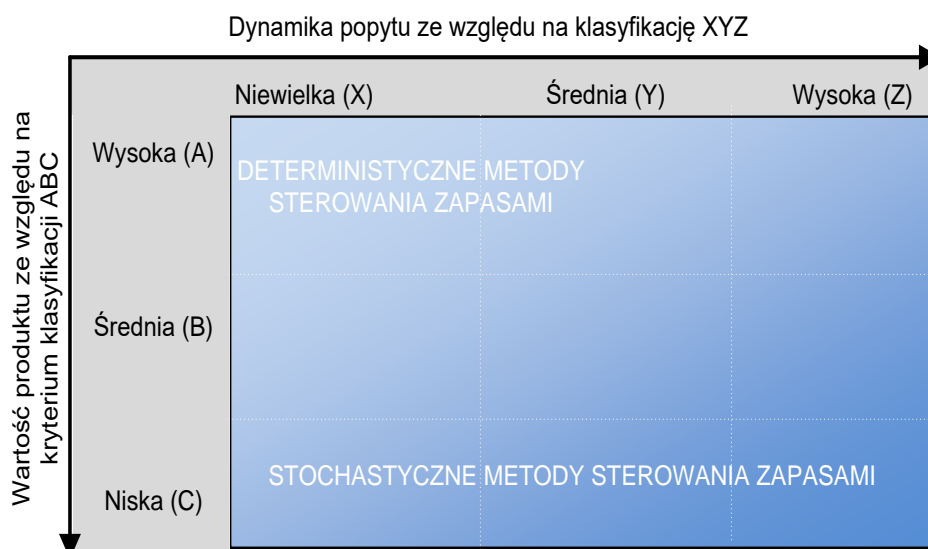
Można wywnioskować iż, z chwilą kiedy wartość tego wskaźnika będzie wzrastać to będzie to świadczyło o potrzebie zmiany metody sterowania. Przedstawione w niniejszym paragrafie dodatkowe miary mają na celu wesprzeć proces oceny przyjętej przez dane przedsiębiorstwo metody sterowania.

### **3. ZNACZENIE ANALIZY I PREDYKCJI POPYTU W PROCESIE STEROWANIA ZAPASAMI TOWARÓW**

#### **3.1 WYKORZYSTANIE ANALIZY ABC, XYZ W WYBORZE METODY STEROWANIA ZAPASAMI TOWARÓW**

Posiadanie wiedzy na temat mechanizmów, które mają wpływ na kształtowanie się wielkości popytu w określonym czasie na dany rodzaj produktu jest niezwykle istotne z punktu widzenia efektywnego sterowania zapasami towarów. Dlatego podstawą wyboru właściwego podejścia do sterowania zapasami powinno być przeprowadzenie podstawowej analizy co do natury popytu w funkcji czasu dla danego artykułu jak i stopnia jego ważności w odniesieniu do przyjętego kryterium (wartość, częstość pobrań, liczba wydań z magazynu dla danego okresu). Tych podstawowych informacji, dostarczają analizy ABC, XYZ oraz różnego rodzaju techniki prognozowania popytu przedstawione w dalszych częściach rozdziału. Szerokie spektrum strumieni dóbr przepływających przez większość magazynów oraz centrów dystrybucyjnych sprawia, że pozycje asortymentowe generujące duże koszty utrzymania zapasów bądź te które są wartościowe dla przedsiębiorstwa wymagają znacznie bardziej wyrafinowanego podejścia do sterowania poziomem zapasów. W tym celu wykonywana jest analiza ABC mająca na celu podział towarów w magazynie na trzy grupy A, B i C na podstawie jednego z przyjętych kryteriów podziału (np. wartość produktu, częstość pobrań, szybkość rotowania itp.) [54]. Przeprowadzenie analizy i klasyfikacji ABC pomaga zatem w dostarczeniu wiedzy na temat stopnia ważności poszczególnych produktów dla przedsiębiorstwa pod kątem różnych kryteriów, a co za tym idzie w wyborze adekwatnego podejścia oraz metod uzupełniania i kontroli zapasów dla danego typu towaru. Analiza ta nie uwzględnia natomiast specyfiki towarów pod kątem dynamiki popytu oraz dokładności prognozowania jego przyszłych wartości. Dlatego w celu uzyskania tych informacji dodatkowo wykonuje się klasyfikację XYZ, która stanowi w pewien sposób rozszerzenie analizy ABC. Ideą tej analizy jest podział zbioru różnorodnych pozycji asortymentu na trzy grupy X, Y oraz Z pod kątem stabilności popytu oraz możliwości jego predykcji w przyjętym okresie czasu [73]. Biorąc pod uwagę zarówno wyniki przeprowadzonych obu analiz poszczególne produkty można przypisać do jednej z dziewięciu kategorii ze względu na wykazywane cechy popytu i wartość przyjętego kryterium w klasyfikacji ABC. Z jednej strony występuje klasa produktów AX o stabilnym popycie i dużej wartości, z drugiej produkty o cechach zupełnie przeciwnych w klasie CZ gdzie zapotrzebowanie charakteryzuje się dużą zmiennością a wartość produktu jest niewielka. Wykonanie połączonej analizy ABC – XYZ oraz wykorzystanie wniosków sformułowanych na podstawie otrzymanych z niej wyników pozwala określić dedykowane podejście i metody sterowania (deterministyczne bądź stochastyczne) dla konkretnych produktów. Rekomendacje w odniesieniu do wyboru odpowiedniego podejścia w sterowaniu zapasami przedstawia rys. 15. Obecne na rysunku gradientowe tło wskazuje na możliwą niewyraźną granicę na stykach określonych klas. Tam wybór podejścia w sterowaniu powinien być podyktowany dodatkową analizą przedsiębiorstwa.





**Rys. 15.** Rekomendacje dotyczące wyboru podejść do sterowania zapasami w zależności od klas produktów

*Źródło: opracowanie własne na podstawie [73]*

Ze schematu (rys.15) wynika, iż im bardziej stabilny popyt na dany artykuł oraz wyższa jego pozycja w klasyfikacji ABC tym bardziej uzasadnione jest stosowanie metod deterministycznych ze względu na prostotę obliczeń oraz zadowalające rezultaty. Przeciwny przypadek stanowią produkty o wysokiej zmienności zapotrzebowania i niskiej wartości w klasyfikacji ABC, gdzie bardziej rekomendowane są podejścia stochastyczne. Oczywiście należy mieć na uwadze, że ostateczny dobór metody sterowania poziomem zapasów jest podyktowany swoistą specyfiką przedsiębiorstwa, produktu oraz charakterystyką łańcucha dostaw w którym ma miejsce jego przepływ. Uwzględnienie charakterystyk oraz specyfiki klas produktów w stosowanych metodach sterowania może wpłynąć pozytywnie na poprawę jakości usług dostawczych oraz przede wszystkim na redukcję zapasów materiałowych czego konsekwencją jest obniżenie kosztów magazynowania. Dodatkowo należy zwrócić uwagę na fakt, iż analizę ABC/XYZ powinno się okresowo aktualizować gdyż jej wyniki mogą zmieniać się w czasie.

### 3.2 IDENTYFIKACJA, ESTYMACJA I PREDYKCJA POPYTU NA TOWARY JAKO KLUCZOWY ELEMENT W STEROWANIU ZAPASAMI

Podejmowanie decyzji jest nieodłącznym elementem życia i działalności człowieka. W konsekwencji mają one bardzo zróżnicowany charakter. Pewne decyzje mogą być podejmowane natychmiastowo, inne z kolei wymagają głębszych analiz. Niezależnie jednak od obszaru rozważań podejmowane decyzje silnie wpływają na przyszłe zdarzenia. Dlatego też podejmowanie właściwych decyzji w zakresie sterowania zapasami towarów bardzo często wymaga precyzyjnych informacji o kształtowaniu się zapotrzebowania na dany produkt w przyszłości. To sprawia iż istnieje potrzeba budowania prognoz, które będą w stanie z mniejszą lub większą niepewnością wyrażoną zazwyczaj poprzez błąd prognozy opisać przyszłe zachowanie się popytu. Przez prognozowanie należy rozumieć racjonalne,

naukowe przewidywanie przyszłych zdarzeń. Określenie „naukowe” zaznacza, iż w toku całego procesu badawczego który obejmuje między innymi gromadzenie danych o przeszłości, diagnozę, formułowanie założeń i konkluzji korzysta się z dorobku nauki wyrażonego w jej ogólnej metodologii w postaci teorii oraz reguł rozwiązywania problemów napotkanych w trakcie badania [37]. W literaturze można odnaleźć wiele kryteriów, umożliwiających dokonanie podziału i klasyfikacji dostępnych metod i narzędzi prognozowania. Z punktu widzenia niniejszej pracy warto rozróżnić podział metod ze względu na okres na który została ona zbudowana czyli tzw. horyzont prognozy. Tutaj wyróżnia się prognozy krótkoterminowe (obejmujące zazwyczaj okres do 3 miesięcy), średnioterminowe (nie przekraczające 2 lat) oraz długoterminowe (powyżej 2 lat). Podział ten należy jednak traktować umownie gdyż zależy on od charakteru prognozowanego zjawiska. Z perspektywy sterowania zapasami kluczową rolę odgrywają krótkoterminowe prognozy, które stanowią podstawę planowania operacyjnego w postaci harmonogramowania produkcji, wyznaczania poziomów zapasów cyklicznych i bezpieczeństwa, kontroli kosztów logistycznych oraz poziomu obsługi klienta. Innym ważnym kryterium podziału jest wyróżnienie prognoz ilościowych i jakościowych. Prognoza ilościowa to taka, w której wielkość zmiennej prognozowanej jest wyrażona za pomocą liczby. Jeśli prognoza jest wyznaczona jako konkretna liczba mamy wówczas do czynienia z prognozą punktową lub przedziałową jeśli podawany jest przedział w którym ma znaleźć się wartość prognozowanej zmiennej. Z kolei prognozy jakościowe to takie, które dotyczą cech jakościowych. Ze względu na rodzaj i cel sporządzanej prognozy można wyodrębnić metody prognozowania matematyczno – statystyczne oraz metody nie matematyczne, do których należą metody ankietowe, intuicyjne, metody kolejnych przybliżeń, metody analogowe, metoda delficka itp. [153]. Techniki te mają bardzo często charakter subiektywny, gdyż istotny jest w tym wypadku wpływ czynnika ludzkiego. Prognozy te bowiem opracowywane są na podstawie opinii ekspertów bądź pracowników. Jednakże są one dosyć często wykorzystywane ze względu na łatwość ich stosowania.

Podstawowym celem sporządzanych prognoz w obszarze kontroli poziomu zapasów jest zmniejszenie ryzyka w procesie planowania i podejmowania decyzji. Złe rozpoznanie przyszłych sytuacji rozwojowych i trendów w popycie może działać niekorzystnie w stosunku do przedsiębiorstwa w zakresie efektywności ekonomicznej oraz poziomu obsługi klienta. Decyzje w zakresie kontroli i kosztów utrzymania zapasów mogą przynosić oczekiwane rezultaty jedynie wtedy gdy są podejmowane w oparciu o wiarygodne modele prognostyczne. Dlatego więc metody mające zastosowanie w prognozowaniu popytu należą głównie do grupy metod matematyczno – statystycznych opartych na analizie szeregów czasowych. Wśród nich do najpopularniejszych należą klasyczne modele trendu, adaptacyjne modele trendu, modele przyczynowo – opisowe, modele autoregresyjne, rekurencyjne i wiele innych.

### 3.2.1 Charakterystyka podstawowych modeli predykcji popytu na podstawie analizy szeregów czasowych

Bardzo często wykorzystywanymi metodami predykcji są ekonometryczne modele przyczynowo skutkowe. Zakładają one, że zmienna prognozowania (zmienna objaśniana) występuje w związku przyczynowo – skutkowym ze zmiennymi objaśniającymi, które mają wpływ na kształtowanie się zmiennej objaśnianej. Tego typu podejścia są zazwyczaj stosowane do planowania i prognozowania procesów logistycznych w dłuższym horyzoncie czasu, w sferze strategicznej przedsiębiorstwa. Za pomocą nich buduje się prognozy popytu na kilka bądź kilkanaście lat. Modele przyczynowo – skutkowe mogą być również wykorzystane do predykcji zapotrzebowania na szczególnie ważne produkty bądź materiały w przedsiębiorstwie [128].

Większość z matematyczno - statystycznych metod prognozowania bazuje na wykorzystaniu szeregów czasowych. Szereg czasowy stanowi realizację procesu stochastycznego. Jest on ciągiem wartości liczbowych opisujących kształtowanie się wielkości zapotrzebowania na dany produkt w czasie. Analiza szeregu czasowego ma na celu poznanie a także wyjaśnienie mechanizmu, który kształtuje zmiany, rozwój prognozowanego zjawiska. Na podstawie wykonanej diagnozy o zachowaniu prognozowanej zmiennej w przeszłości można wyznaczyć prognozę na okres czasu znajdujący się bezpośrednio za chwilą dla której znamy ostatnią obserwację bądź też na dowolne kolejne okresy czasu. Analizując szereg w dziedzinie czasu wyodrębnia się zazwyczaj jego pewne składowe, jednakże nie wszystkie z nich mają obowiązek występować w tym samym szeregu. W przypadku addytywnego modelu szeregu jego składowe można przedstawić w następujący sposób:

$$Y = M + Tr + C + S + K + I + \xi \quad (39)$$

gdzie:

Y – to szereg czasowy reprezentujący prognozowaną zmienną,

M – stały przeciętny poziom prognozowanej zmiennej,

Tr – występująca tendencja rozwojowa w postaci trendu,

C – wahania regularne w postaci cykli długo okresowych dłuższych niż rok,

S – wahania sezonowe, regularne wahania o okresie rocznym,

K – wahania krótkookresowe, regularne wahania o krótszym okresie niż rok,

I – gwałtowne pojedyncze zmiany będące konsekwencją wpływu czynnika zewnętrznego,

$\xi$  – składnik losowy reprezentowany jako zmienna losowa o wartości średniej równej zero i stałej wariancji,

Trendem nazywany jest ogólny kierunek rozwoju prognozowanej zmiennej. Stanowi on tendencje rozwojową, obserwowaną w całym szeregu. Trend może przybierać różną postać między innymi może być liniowy, wykładniczy, asymptotyczny, S-kształtny itp. Wahania sezonowe natomiast zakładają występowanie zwiększonego popytu na określone produkty w ustalonym czasie. Sezonowość jest wywoływana różnymi czynnikami zazwyczaj są nimi pora roku, zachowania ludzkie. Z kolei wahania cykliczne nie charakteryzują się tak regularnym

występowaniem jak zmiany sezonowe. Z tego względu znacznie trudniej ustalić odstępy czasowe w jakich się pojawiają oraz amplitudy fluktuacji popytu. Wielkość popytu jest także determinowana przez działanie czynników losowych (Interwencje), których wystąpienie i siłę oddziaływania jest ciężko przewidzieć a które w istotny sposób mogą niekorzystnie wpłynąć na dokładność prognozy. Czynniki te powodują jednorazowe lub długotrwałe zakłócenia w poszczególnych składowych szeregu [117].

Jeśli składniki szeregu czasowego połączone są za pomocą iloczynu wówczas szereg taki nazywany jest multiplikatywnym. Identyfikacja mechanizmów, które kształtują poszczególne składniki systematyczne szeregu ma kluczowe znaczenie dla rozpoznania kształtu przyszłego popytu na podstawie którego wyznaczane są normy sterowania w modelach kontroli zapasów. Dlatego też bardzo często krótkoterminowa predykcja popytu, jako element operacyjnych działań logistycznych, jest oparta o wykorzystanie adaptacyjnych modeli prognozowania. Najczęściej stosowane w praktyce z nich zostaną pokrótce przedstawione w poniższych podrozdziałach, gdyż w dalszej kolejności zostaną wykorzystane do wyznaczenia poziomu odniesienia dla oceny zaproponowanego w pracy rozwiązania.

### 3.2.1.1 Metoda średnich ruchomych

Jedną z najprostszych metod wykorzystywanych do szacowania przyszłych wartości popytu jest metoda wyznaczania tzw. średnich ruchomych. Średnie ruchome wyznaczane są jako średnie arytmetyczne z określonej liczby  $m$  obserwacji szeregu. Kolejne wartości są otrzymywane poprzez przesuwanie zasięgu obserwacji objętych średnią wzdłuż szeregu za każdym razem opuszczając najstarszą obserwację i uwzględniając pierwszą z kolei „nową” która nie była brana pod uwagę wcześniej. Sytuację przedstawia poniższy wzór:

$$Y_t = \frac{1}{m} \sum_{i=t-m}^{i-1} y_i \quad (40)$$

gdzie:

$Y_t$  – prognozowana wartość zmiennej w chwili  $t$ ,

$y_i$  – wartość zmiennej prognozowanej w momencie  $i$ ,

$m$  – stała wygładzania,

Liczba  $m$  wyrazów średniej ruchomej nazywana również stałą wygładzania jest określana zazwyczaj przez prognozę. Im więcej wyrazów szeregu branych jest do średniej tym silniejsze jest wygładzenie szeregu oraz wolniejsza reakcja na zmiany zachodzące w wartościach zmiennej prognozowanej. Użycie mniejszej liczby wyrazów powoduje szybsze wyrażenie zmian zachodzących w szeregu lecz wówczas wpływ wywieranych na zmienną wahań losowych będzie silniejszy. Wybór stałej wygładzania powinien stanowić pewien kompromis w zależności od potrzeb. Liczbę wyrazów wziętych do średniej można również ustalić na podstawie błędów prognoz *ex post*, wybierając ten wariant dla którego błąd jest najmniejszy [37]. Klasyczna średnia ruchoma w powyższej postaci nie uwzględnia jednak istotnego aspektu związanego z postarzeniem informacji przypisując jednakowe wagi

wszystkim  $m$  – elementom. W rzeczywistości zazwyczaj nowsze obserwacje zawierają bardziej aktualne informacje o prognozowanej zmiennej, stąd idea nadawania większych wag najnowszym wartościom szeregu. Ważoną średnią ruchomą przedstawia poniższy wzór:

$$Y_t = \frac{1}{m} \sum_{i=t-m}^{i=t-1} y_i w_{i-t+m+1} \quad (40)$$

$$0 < w_1 < w_2 < \dots < w_m \quad (41)$$

$$\sum_{i=1}^m w_m = 1 \quad (42)$$

gdzie:

$Y_t$  – prognozowana wartość zmiennej w chwili  $t$ ,

$y_i$  – wartość zmiennej prognozowanej w momencie  $i$ ,

$w_{i-t+m+1}$  - waga nadana  $i$  – tej obserwacji,

$m$  – stała wygładzania,

Tego rodzaju metody mogą posłużyć do wyznaczania prognoz popytu w sytuacji gdy w rozważanym okresie czasu poziom prognozowanej zmiennej jest względnie stały z drobnymi wahaniami losowymi, natomiast bez obecności tendencji rozwojowej oraz wahań cyklicznych i sezonowych.

### 3.2.1.2 Metoda wygładzania wykładniczego Browna

Modele wygładzania wykładniczego stanowią pewne uogólnienie metod naiwnych czyli takich, które opierają się na założeniu braku zmian w sposobie oddziaływania czynników określających wartości prognozowanej zmiennej przez co kolejne wartości kształtują się na dotychczasowym poziomie. Najprostszy przykład metody naiwnej przedstawia poniższy wzór:

$$Y_t = y_{t-1} \quad (43)$$

Metoda wygładzania wykładniczego Browna jest również używana do prognozowania krótkoterminowego szeregów czasowych o takich samych cechach jak w przypadku modelu średniej. W podejściu tym pojawia się tzw. parametr wygładzania  $\alpha \in (0;1)$ . Prognozy otrzymuje się obliczając kolejne wygładzone wartości szeregu za pomocą wzoru:

$$Y_t = \alpha y_{t-1} + (1 - \alpha) Y_{t-1} \quad (44)$$

gdzie:

$Y_t$  - wartość prognozowanej zmiennej w chwili  $t$ ,

$y_{t-1}$  - wartość obserwacji szeregu w chwili  $t-1$ ,

$Y_{t-1}$  - wartość prognozy wygasłej w chwili  $t-1$ ,



Jeżeli wartość parametru  $\alpha$  zbliża się do jedności, to prognoza w bardzo dużym stopniu uwzględnia błędy poprzednich prognoz. W odwrotnym wypadku im bliższa zero wartość  $\alpha$  tym prognoza w bardzo niewielkim stopniu uwzględnia błędy poprzednich prognoz. Początkowa wartość prognozy  $Y_1$  która jest konieczna do utworzenia modelu przyjmuje się pierwszą obserwację szeregu bądź średnią z jego kilku początkowych wartości. Parametr  $\alpha$  jest dobierany zazwyczaj eksperymentalnie jako wartość dla której średni błąd prognoz wygasłych jest najmniejszy.

### 3.2.1.3 Liniowy model Holta

Poza prostym wygładzaniem przedstawionym w poprzednim podrozdziale występują także bardziej złożone modele, które są adekwatne dla szeregów czasowych w których pojawiają się istotne składniki w postaci trendu bądź sezonowości. Jeżeli w zapotrzebowaniu na dany produkt występuje trend oraz wahania przypadkowe wówczas do konstrukcji prognoz krótkoterminowych często stosowany jest liniowy model Holta. W porównaniu do poprzedniej metody Browna ten model jest uważany za bardziej elastyczny ze względu na występowanie dwóch równań wygładzających trend oraz stałą wartość prognozowanej zmiennej. Równania modelu przedstawia się w sposób jak poniżej:

$$F_{t-1} = \alpha y_{t-1} + (1 - \alpha)(F_{t-2} + S_{t-2}) \quad (45)$$

$$S_{t-1} = \beta(F_{t-1} - F_{t-2}) + (1 - \beta)S_{t-2} \quad (46)$$

gdzie:

$F_{t-1}$  - jest wygładzoną wartością prognozowanej zmiennej na okres  $t-1$ ,

$S_{t-1}$  - jest wygładzoną wartością przyrostu trendu na okres  $t-1$ ,

$\alpha, \beta$  - parametry modelu przyjmujące wartości z przedziału  $[0,1]$ ,

Równanie (45) opisuje wyrównany wykładniczo średni popyt, podczas gdy składowa modelu (46) wyraża uśrednioną ocenę przyrostu trendu. Równanie za pomocą którego wyznaczana jest prognoza na okres  $t > n$  przybiera postać:

$$Y_t = F_n + (t - n)S_n, \quad t > n \quad (47)$$

gdzie:

$Y_t$  - wartość wyznaczonej prognozy na okres  $t$ ,

$F_n$  - wygładzona wartość zmiennej prognozowanej dla chwili  $n$ ,

$S_n$  - wygładzona wartość przyrostu trendu dla chwili  $n$ ,

$n$  - liczba wyrazów szeregu czasowego reprezentującego popyt,

Początkowe wartości  $F_1$  oraz  $S_1$  niezbędne do zbudowania modelu można wyznaczyć przyjmując za  $F_1$  wartość pierwszej obserwacji szeregu  $y_1$ , natomiast za  $S_1$  różnicę obserwacji  $y_2 - y_1$ . Inne sposoby ich wyznaczania przedstawione są między innymi w pracy [84]. Wartości parametrów modelu  $\alpha, \beta$  podobnie jak to ma miejsce w poprzednich modelach wyznaczane są w oparciu o symulacje komputerowe dla których przeciętny błąd dla prognoz wygasłych jest najmniejszy.

### 3.2.1.4 Model Wintersa

Model Wintersa jest najbardziej odpowiedni do stosowania dla szeregów czasowych, które zawierają w sobie zarówno, wahania sezonowe jak i wahania przypadkowe nakładające się na trend. Składowe te opisane są odrębnymi równaniami. Model występuje w dwóch wersjach: addytywnej i multiplikatywnej. Wersja addytywna jest sformułowana w następujący sposób:

$$F_{t-1} = \alpha(y_{t-1} - C_{t-1-r}) + (1 - \alpha)(F_{t-2} - S_{t-2}) \quad (48)$$

$$S_{t-1} = \beta(F_{t-1} - F_{t-2}) + (1 - \beta)S_{t-2} \quad (49)$$

$$C_{t-1} = \gamma(y_{t-1} - F_{t-1}) + (1 - \gamma)C_{t-1-r} \quad (50)$$

Odpowiednio składowe dla wersji multiplikatywnej modelu można przedstawić za pomocą poniższych formuł:

$$F_{t-1} = \alpha \frac{y_{t-1}}{C_{t-1-r}} + (1 - \alpha)(F_{t-2} - S_{t-2}) \quad (51)$$

$$S_{t-1} = \beta(F_{t-1} - F_{t-2}) + (1 - \beta)S_{t-2} \quad (52)$$

$$C_{t-1} = \gamma \frac{y_{t-1}}{F_{t-1}} + (1 - \gamma)C_{t-1-r} \quad (53)$$

gdzie:

$F_{t-1}$  - wygładzona wartość zmiennej prognozowanej w okresie  $t-1$  po wyeliminowaniu wahań sezonowych,

$S_{t-1}$  - wygładzona wartość przyrostu trendu w okresie  $t-1$ ,

$C_{t-1}$  - ocena wskaźnika sezonowości dla okresu  $t-1$ ,

$r$  - długość cyklu sezonowego,

$\alpha, \beta, \gamma$  - parametry wygładzania przyjmujące wartości z przedziału  $[0,1]$ ,

Równania wyznaczające prognozę na okres  $t > n$  odpowiednio dla wersji addytywnej i multiplikatywnej modelu przedstawione są jak poniżej:

$$Y_t = F_n + S_n(t - n) + C_{t-r} \quad (54)$$

$$Y_t = [F_n + S_n(t - n)]C_{t-r} \quad (55)$$

Według literatury jednym ze sposobów wyboru wartości parametrów modelu jest analiza szybkości zmian jego składowych. Jeżeli zmieniają się one szybko to zasadne jest wybranie parametrów modelu bliskich jedności, w przeciwnym przypadku na poziomie bliskim zera.



### 3.2.2 Wpływ błędów oszacowania prognoz popytu na proces sterowania zapasami

Każdy proces prognozowania jest obciążony pewną niedokładnością oraz błędem. Błąd ten wyrażony jest w oparciu o różnice pomiędzy popytem prognozowanym a rzeczywistym. Dokładność sporządzanych prognoz popytu niezależnie od stopnia dopasowania wybranej metody do posiadanych danych zawsze jest ograniczona i możliwa do zmierzenia przy użyciu dostępnych mierników błędów *ex post*. Niewystarczająca jakość budowanych prognoz wpływa na efektywność planowania dostaw często wymagając aktualizacji stworzonych już harmonogramów a to przekłada się na wzrastające koszty. Zawyżenie prognozy w stosunku do wartości rzeczywistych może przyczynić się do utrzymywania nadmiernych zapasów, z kolei niedoszacowanie popytu może narazić na koszty utraconych możliwości w skutek wyczerpania zapasów [145]. Dokładność prognozy popytu jest także uzależniona od przyjętego horyzontu czasowego prognozy (im prognoza bardziej sięga w przyszłość tym ryzyko błędu wzrasta, gdyż prawidłowości lub czynniki kształtujące popyt mogą ulec zmianie a parametry modelu będą wymagały aktualizacji ) jak i rodzaju rozważanych produktów. Błędy prognozy często określane mianem reszt modelu mogą mieć charakter systematyczny jak i losowy. Błędy systematyczne powstają w sytuacji kiedy zastosowana metoda prognozowania nie uwzględnia wszystkich zmiennych objaśniających, w niewystarczającym stopniu rozpoznaje zależności między danymi, pomija element sezonowości itp. Z kolei błędy losowe to takie których nie da się przewidzieć przy użyciu żadnej z zastosowanych metod. Proces krótkoterminowego prognozowania popytu wymaga ciągłego monitorowania jakości konstruowanych prognoz. Dzięki temu w porę można uchwycić zachodzące zmiany w prognozowanym zjawisku, które są powodem rosnących błędów. Wtedy musi nastąpić konieczność weryfikacji i aktualizacji parametrów wybranego modelu. Monitorowanie procesu prognozowania bardzo często odbywa się z wykorzystaniem sygnału śledzącego, którego ideą jest obserwacja dokładności prognoz w kolejnych ustalonych odstępach czasowych. Sygnał śledzący wyraża się wzorem:

$$SL_t = \frac{\sum e_t}{s_t} \quad (56)$$

gdzie:

$e_t$  - różnica pomiędzy popytem rzeczywistym a prognozowanym w okresie  $t$ ,

$s_t$  - średni absolutny błąd prognozy,

Jeśli wartości tego sygnału obliczane dla kolejnych chwil czasowych mieszczą się w określonym przedziale to nie jest konieczna weryfikacja parametrów modelu gdyż powstałe niedokładności są efektem głównie czynnika losowego. Najczęściej podawany przez literaturę przedział to (-4;4) [21]. Wykorzystując proces prognozowania oraz mierniki oceny jakości sporządzanych prognoz formułę (13) używaną do ustalania poziomu ponownego zamawiania można zastąpić wzorem:

$$R = Y_t \cdot \bar{L} + k \sqrt{\hat{s}^2 \bar{L} + Y_t^2 \sigma_L^2} \quad (57)$$

gdzie:

$Y_t$  – prognozowana wartość popytu na ustalony okres czasu  $t$

$\hat{s}$  - prognozowany średni błąd prognozy na okres czasu  $t$

### 3.2.3 Źródła niepewności popytu na towary w sterowaniu zapasami

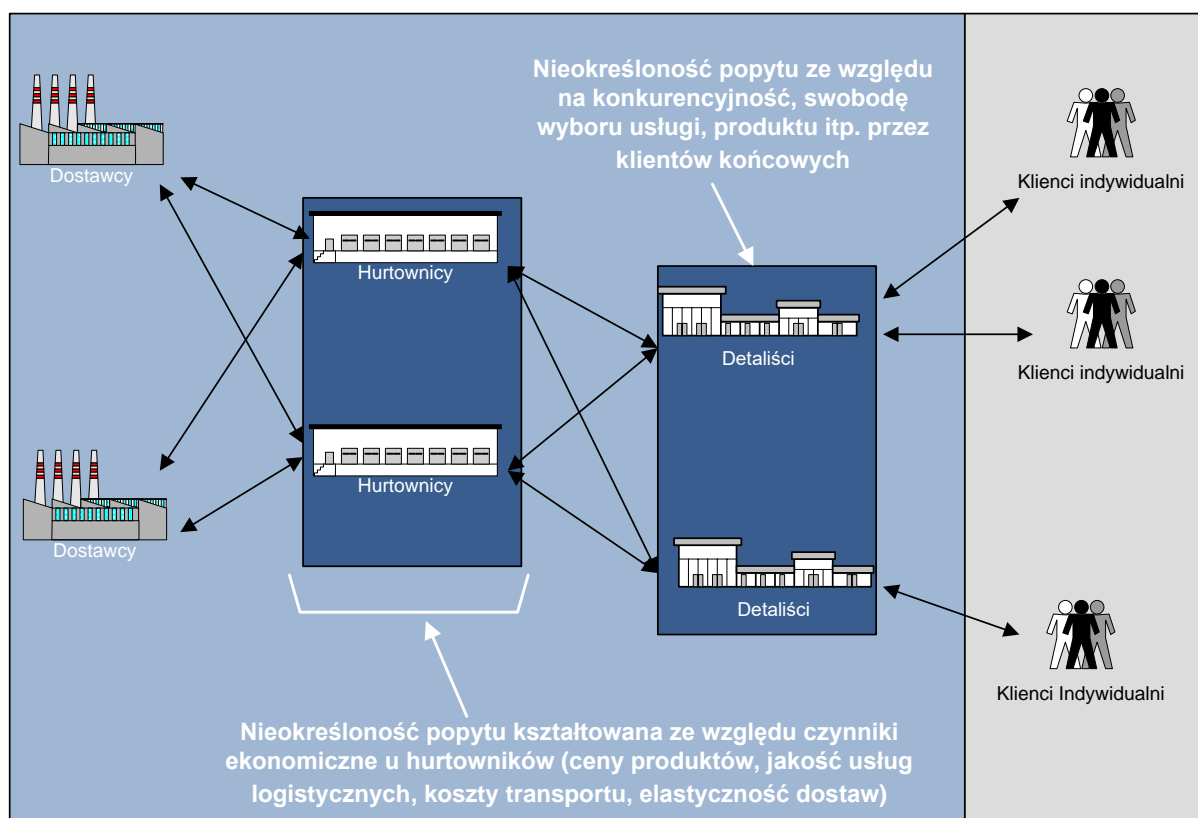
Wybór odpowiedniej metody predykcji popytu nie jest zadaniem prostym zwłaszcza gdy znaczenie jakości prognoz jest kluczowe dla spełnienia wymaganego poziomu obsługi klienta. Decyzja o wyborze metody predykcji jest uzależniona od bardzo wielu aspektów jak rodzaj popytu (zależny, niezależny), specyfika produktu, przeznaczenie i szczegółowość prognozy, horyzont czasowy prognozy, jakość dostępnych danych historycznych a także innych istotnych czynników kształtujących to zapotrzebowanie. Przedsiębiorstwa działają przeważnie w warunkach niepewności, w której podejmowane są decyzje i realizowane są procesy logistyczno transportowe. Wobec tego starają się pozyskać jak najwięcej informacji o prognozowanych zjawiskach, dzięki czemu opracowywane prognozy obarczone jak najmniejszym błędem mają wspomagać podejmowanie optymalnych decyzji zarówno w obszarze kontroli zapasów jak i pozostałych działalności operacyjnych firmy. Zachodzące w łańcuchach dostaw procesy transportowe i logistyczne są z natury stochastyczne, podobnie jak i zjawiska rządzące popytem w tychże łańcuchach. Niepewność popytu na towary w sieci logistycznej jest najczęściej powodowana i kształtowana oddziaływaniem wielu determinan-  
tów. Poza ceną na profil popytu ma wpływ grupa czynników rynkowych takich jak [88] :

- dochody przedsiębiorstw korzystających z usług logistycznych,
- ceny dóbr lub usług komplementarnych,
- przewidywana przez konsumentów wysokość dochodów (zachowanie racjonalne konsumenta w stosunku do swojej przyszłej siły nabywczej).

Drugą grupą elementów oddziałujących na wielkość popytu są czynniki pozarynkowe do których należą:

- liczba przedsiębiorstw konkurujących ze sobą w ramach sieci dostaw,
- nawyki, moda, gust konsumentów,
- sezonowość zapotrzebowania,
- czynniki kulturowe,
- szerokość geograficzna, klimat, pora roku,

Czynniki losowe wpływające na nieokreśloność popytu w pojedynczych ogniwach sieci dostaw przedstawia rys. 16. Niezależnie od zajmowanego miejsca w sieci dostaw na każde pojedyncze ogniwo sieci może oddziaływać specyficzna grupa czynników wzmagająca poziom nieokreśloności zapotrzebowania na towary. Zatem bez względu na pełnią rolę podmiotu w sieci dostaw efektywna identyfikacja przyszłego zapotrzebowania jest bardzo ważna nie tylko z punktu widzenia minimalizowania zapasów i kosztów z nimi związanych w pojedynczym ogniwie lecz także z perspektywy całej sieci.

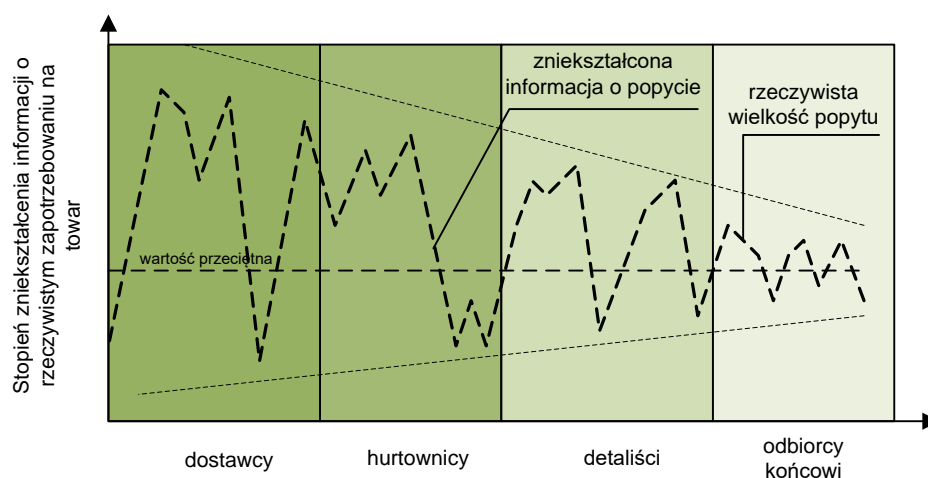


**Rys. 16.** Losowe czynniki oddziałujące na nieokreśloność popytu w pojedynczych ogniwach sieci dostaw

*Źródło: opracowanie własne*

Wpływ wspomnianych determinant na zmienność oraz niepewność zapotrzebowania a także niewystarczająca współpraca podmiotów w łańcuchach dostaw w zakresie wymiany informacji powoduje powstawanie efektu Forrestera, inaczej nazywanego efektem byczego bicza (ang. bullwhip effect). Termin ten jest rozumiany jako zniekształcenia popytu, które narastają wraz przesuwaniami się w górę łańcucha dostaw [36]. Główną przyczyną występowania tego zjawiska jest przeszacowanie przyszłego zapotrzebowania na towar dla klientów końcowych, które bardzo często jest powiększane o dodatkowy zapas zabezpieczający. Bowiem nawet nieznaczny błąd w oszacowaniu zapotrzebowania w danym węźle łańcucha powoduje błędne wnioski o popycie w ogniwach na pozostałych jego szczeblach. Rezultatem kumulacji tych błędów jest spadek efektywności działań logistycznych w całym łańcuchu dostaw [86]. Wpływ na takie zachowanie podmiotów wywołujące efekt Forrestera ma między innymi fluktuacja cen, niedokładność prognozowania, czas realizacji dostaw, metoda sterowania zapasami, wielkość łańcucha dostaw itp. [18]. Aspekty te oraz wspomniana niepewność informacji o przyszłym popycie powodują tworzenie się nadmiernych zapasów w poszczególnych poziomach łańcuchów dostaw. Już w 1991 J. Burbidge wykazał w swojej pracy, że klasyczne metody sterowania zapasami w oparciu o ekonomiczną wielkość zamówienia wywołują przyspieszoną propagację zmian popytu w łańcuchu dostaw [22]. W związku z tym podejmowane obecnie działania w ramach łagodzenia efektu Forrestera koncentrują się na minimalizowaniu wpływu niepewności popytu, dzieleniu się informacją przez podmioty łańcucha, usprawnianiem metod

kontroli zapasów i predykcji. Rys. 17. przedstawia zniekształconą informację o popycie propagowaną w górę łańcucha dostaw.



**Rys. 17.** Zniekształcenie informacji o rzeczywistej wielkości popytu propagujące wzdłuż łańcucha dostaw

*Źródło: opracowanie własne*

Zgodnie z rys. 17. niska efektywność identyfikacji, analizy i predykcji przyszłego zapotrzebowania na towar oraz niewystarczająca współpraca w zakresie wymiany informacji pomiędzy pojedynczymi podmiotami na różnych poziomach sieci dostaw powoduje powstanie błędu w oszacowaniu wielkości zapotrzebowania. Obarczona błędem informacja jest przekazywana do kolejnych ogniw sieci, w których błąd ten jest zwielokrotniony. W związku z tym zapewnienie możliwie wysokiej dokładności predykcji jest bardzo istotne z punktu widzenia minimalizacji poziomu zapasów oraz kosztów w pojedynczym przedsiębiorstwie jak również w kontekście całej sieci dostaw.

## **4. METODA STEROWANIA ZAPASAMI W WARUNKACH NIEPEWNOŚCI Z WYKORZYSTANIEM DEDYKOWANYCH TECHNIK SZTUCZNEJ INTELIGENCJI**

### **4.1 STAN WIEDZY DOTYCZĄCEJ STEROWANIA ZAPASAMI TOWARÓW W KONTEKŚCIE ODDZIAŁYWANIA CZYNNIKÓW NIEPEWNYCH**

Przedstawione w poprzednim rozdziale znaczenie analizy zmienności popytu oraz jej niepożądane oddziaływanie na problem sterowania zapasami towarów stanowi zaledwie jeden, choć niezwykle istotny, spośród wielu innych determinant wpływających na rozważane zagadnienie. W rzeczywistości bowiem na proces optymalizacji poziomu zapasów mogą rzutować oprócz zmienności popytu również dodatkowe czynniki w postaci zmiennego czasu dostawy, zmiennego poziomu niezawodności dostaw, zmienności kosztów utrzymania zapasów, kosztów z tytułu wyczerpania zapasu, zmiennego czasu oczekiwania klienta itp. [155]. Oczywiście należy przy tym zaznaczyć, że siła oddziaływania tych poszczególnych parametrów jest uzależniona od specyfiki branży, produktu, jego podatności na składowanie, złożoności łańcucha dostaw itp. Dlatego też w wielu publikacjach powstałych na przestrzeni ostatnich lat badacze próbują odwzorować jak najdokładniej różne warunki w jakich podejmowane są decyzje dotyczące odnawiania zapasów, uwzględniając choćby w proponowanych modelach kwestie starzenia i psucia przechowywanych produktów. Taka sytuacja zachodzi w przypadku utraty przez nich wartości wskutek zmian technologicznych na rynku, wprowadzenia nowych produktów, zmian preferencji nabywców [26]. Wskutek tego problem optymalnej polityki zapasów ulega znacznej komplikacji. Zagraniczni autorzy dokonują klasyfikacji modeli uwzględniających to założenie. Wyróżniają modele o stałym czasie przydatności produktów, modele probabilistyczne oraz modele zakładające arbitralnie maksymalny czas przechowywania danych pozycji asortymentowych w magazynie. [24,35,26,29,43,44]. Istotnym elementem na który zwracają uwagę zagraniczni badacze jest uwzględnienie w modelach sterowania kilku produktów jednocześnie, gdyż jest to znacznie bliższe rzeczywistości [51,76,82,83]. Innym aspektem jest próba zamodelowania reakcji konsumentów na braki w zapasach. W tym przypadku w metodach uwzględnia się stały poziom opóźnienia w realizacji zamówień na każdy cykl uzupełniania zapasu, lub też wprowadza się funkcję czasu oczekiwania by określić jak długo klient jest w stanie oczekiwać na realizację zamówienia [26,30,43,46,45,47]. Wiele pozycji zagranicznych rozszerza problem sterowania zapasami z jednego wyizolowanego ogniwa w sieci logistycznej na zadanie wieloszczeblowe. Tutaj celem jest koordynacja zapasów pomiędzy grupą magazynów regionalnych a magazynem centralnym [67,69,75,78,97,115,152]. Wiele prac, oprócz klasycznych zmiennych czynników wpływających na efektywność polityki zaopatrzenia porusza problem zmiennej dostępności towarów na rynku co powoduje zakłócenia i przerwy w dostawach. Autorzy w rozwiązaniach proponują analityczne modele zmiennego poziomu niezawodności oddziałujący na zapas bezpieczeństwa. Przedstawiane są również systemy

wczesnego ostrzeżenia przed zakłóceniami w dostawach oraz strategii zaopatrzenia u wielu dostawców [39,130,109,122,35,142,131]. Snyder and Tomlin rozważają system sterowania, który uwzględnia wzorzec prawdopodobieństwa wystąpienia zakłóceń w dostawach wraz ze strategią ostrzeżenia. Dzięki temu autorzy wskazują na możliwość dużych oszczędności kosztów ponoszonych przez przedsiębiorstwo w szczególności, gdy prawdopodobieństwo zakłócenia zmienia się istotnie w czasie. Możliwe jest wtedy zapewnienie odpowiedniego poziomu obsługi klientów [90]. Innym elementem, który może podlegać wahaniom w czasie oddziałując na efektywność sterowania zapasami są koszty z nimi związane. W większości pozycji literaturowych koszty te są z założenia przyjmowane jako stałe, tymczasem istnieją przypadki w których zasadne jest zamodelowanie kosztów zmiennych w czasie oraz traktowanie zmienności popytu jako funkcji kosztów sprzedaży. W pracy [50] autorzy w swoim modelu zakładają, że koszt utrzymania zapasów może być zmienny w czasie jako nieliniowa funkcja czasu składowania towarów. W opracowaniu [53] rozważana jest sytuacja w której koszty utrzymania zapasów są do pewnego momentu stałe a następnie po jego przekroczeniu stają się rosnącą funkcją zależną od długości cyklu zamawiania. Można spotkać również rozwiązania w którym koszt składowania jest złożony z dwóch komponentów: kosztu stałego oraz kosztu wzrastającego wraz z czasem przechowywania [120]. W literaturze prezentowane są także modele, w których zarówno popyt jak i koszty składowania zależą od poziomu zapasów [103,104]. Autorzy pracy [40] starają się iść o krok dalej i prezentują model, w którym jednocześnie uwzględniają zmienność popytu zależną od ceny sprzedaży, koszty składowania zależne od czasu składowania oraz wielkość zamówienia od ceny zakupu i rabatów. Innym ciekawym aspektem poruszonym w badaniach nad optymalizacją zapasów jest próba potraktowania czasu realizacji zamówienia i dostawy nie jako parametru lecz zmiennej decyzyjnej podlegającej kontroli – oczywiście tylko w określonych przypadkach i z konsekwencją ponoszenia dodatkowych kosztów [132,102].

Często dokładne wartości tychże parametrów nie są możliwe do poznania z odpowiednim wyprzedzeniem lub mogą być jedynie oszacowane z pewnym mniejszym lub większym błędem (prognozy). Dla przykładu parametry rozmaitych procesów transportowych i logistycznych nie są możliwe do dokładnego zmierzenia, zatem w momencie rozwiązywania zadanego problemu dane wejściowe jak chociażby popyt, czas trwania transportu towaru nie istnieją a jedynie odbywa się wnioskowanie co do ich możliwych wartości [79]. Zmienne w czasie wartości cen, kosztów magazynowania mogą sprawić iż otrzymane rozwiązanie może okazać się niedopuszczalne ze względu na ograniczenia dostępnej powierzchni składowania, dostępnych środków finansowych przeznaczonych na zapasy itp. Wobec tego podstawowe klasyczne podejścia przywołane w rozdziale 2 bardzo często nie spełniają cechy reprezentatywności warunków, które w wielu przypadkach zachodzą w rzeczywistości. Sytuacja ta prowadzi zatem do spojrzenia na zagadnienie optymalizacji i kontroli zapasów w kontekście niepewności co do możliwych wartości parametrów modelu.



#### 4.1.1 Rozwiązania wykorzystujące podejście typu *robust*

Jednym z podejść, które ujmuje niepewność danych jest koncepcja znana z literatury zagranicznej jako sterowanie i optymalizacja typu *robust* czyli odporna na wahania parametrów modelu. Podstawowa idea tego podejścia zostanie przedstawiona na przykładzie klasycznej struktury sformułowanego liniowego problemu optymalizacji. W najprostszy sposób można przedstawić go następująco:

$$PO: \min_x \{C^T x: Ax \leq b\} \quad (58)$$

Gdzie  $x \in R^n$  jest wektorem zmiennych decyzyjnych,  $C \in R^n$  współczynnikami funkcji kryterium,  $A$  macierzą współczynników przy ograniczeniach o wymiarze  $m \times n$  oraz  $b$  wektorem wyrazów wolnych przy ograniczeniach. Odpowiednikiem powyższego liniowego problemu który uwzględnia niepewność parametrów modelu (58) jest zbiór problemów liniowych o takiej samej wspólnej strukturze przedstawiony w poniższy sposób:

$$\{\min_x \{C^T x: Ax \leq b\}: (C, A, b) \in U\} \quad (59)$$

Powyższe sformułowanie oznacza rozpatrzenie wielu programów liniowych gdzie parametry modelu zarówno przy funkcji celu jak i przy ograniczeniach mogą przybierać dowolne wartości ze specjalnie określonego zbioru niepewności  $U$ . Wobec powyższego rozwiązaniem odpornym typu *robust* jest na przykład wektor zmiennych decyzyjnych  $x$  rozwiązujący poniżej bardzo ogólnie sformułowany problem:

$$PO: \min_x \{ \sup_{(C,A,b) \in U} C^T x: Ax \leq b \forall (C, A, b) \in U \} \quad (60)$$

Optymalne, rozwiązanie typu *robust* to najlepsze spośród zbioru rozwiązań dopuszczalnych typu *robust*, które spełnia wszystkie ograniczenia problemu dla każdej możliwej wartości parametru ze zbioru  $U$ . Takie podejście ma zagwarantować dopuszczalność rozwiązania bez względu na wartości parametrów modelu. Właściwie zdefiniowany zbiór niepewności jest niezwykle kluczowy dla rozwiązywanego problemu i powinien zapewniać odzwierciedlenie sytuacji w rzeczywistości [57]. Dokładne zasady oraz sposoby tworzenia zbioru niepewności jak i strategie poszukiwania optymalnego rozwiązania typu *robust* problemów decyzyjnych z niepewnością danych zostały szeroko przedstawione w [14]. W podejściu *robust* zmienne parametry modelu nie są opisane żadnym ze znanych rozkładów prawdopodobieństwa w odróżnieniu od podejścia stochastycznego, które również uwzględnia niepewność danych lecz rozkład prawdopodobieństwa tej zmienności jest z założenia znany w całości lub przynajmniej częściowo. Jak pokazują przykłady zawarte w publikacji [53] zarówno jedno jak i drugie podejście ma swoje mocne jak i słabe strony. Niemniej jednak w ciągu ostatnich lat podejście do optymalizacji i sterowania typu *robust* w obszarze kontrolowania zapasów zyskuje coraz bardziej na popularności. Świadczą o tym



coraz to liczniejsze opracowania podejmujące rozwiązanie tego problemu. W pracach [16,17,124] autorzy wykorzystują to podejście aby rozwiązać problem zapasów w dwuszczeblowym łańcuchu dostaw uwzględniając popyt jako zmienny parametr opisany zbiorem niepewności. W publikacjach [11, 146] można odnaleźć analizę wpływu różnych typów zdefiniowanego zbioru niepewności popytu oraz poziomu konserwatywności rozwiązania na jego użyteczność oraz jakość. W publikacji [15] autorzy Ben Tal A., Golany B. oraz Sthern S., rozwiązują problem sterowania zapasami ujmując jako niepewne wartości popytu oraz początkowy poziom zapasów w wieloszczeblowym łańcuchu dostaw. Jako kryterium optymalizacji *robust* przyjmują minimalizację łącznych kosztów łańcucha w skład których wchodzi koszty zakupu, wytworzenia, utrzymania oraz koszty wyczerpania zapasu. Dodatkowo analizują wpływ proponowanego podejścia na łagodzenie efektu Forrestera, dowodząc, iż stosowanie metod odpornościowych typu *robust* zmniejsza jego efekt w łańcuchu dostaw. Wskazują na zalety otrzymanego rozwiązania porównując go z rezultatem deterministycznym. W innych pozycjach autorzy z kolei koncentrują się na sformułowaniu problemu optymalizacji zapasów typu *robust* z uwzględnieniem poziomu niepewności dostawy co ma miejsce w sytuacji kiedy dostawa jest niekompletna bądź spóźniona. Można też odnaleźć dodatkowe rozszerzenia uwzględniające niepewność zysków z dystrybucji składowanych towarów [19]. W pracach naukowych można odnaleźć próbę sformułowania modeli sterowania zapasami typu *robust* z jednoczesnym uwzględnieniem zarówno niepewnego popytu jak i niepewności dostawy [141]. W publikacji [93] badacze sformułowali oraz rozwiązali wieloetapowy, wieloszczeblowy problem sterowania zapasami typu *robust* z niepewnością popytu oraz czasu dostawy dla pojedynczego produktu z możliwością wystąpienia braków oraz dostawami częściowymi. W swoich badaniach dokonali także analizy wpływu parametrów sterowania modelu (R,S) w środowisku niepewnym na koszty całego łańcucha dostaw oraz efekt byczego bicza. W publikacjach [6,7], autorzy Adida E., Perakis G., rozwiązują problem optymalizacji zapasów dla wielu okresów czasu gdzie niepewny popyt jest w pewnym stopniu liniowo uzależniony od ceny produktu. Badacze stosują podejście typu *robust* wykorzystując metodę afinicznie dopasowanego odpowiednika *robust* (AARC - Affinely Adjustable Robust Counterpart), gdzie pewna część zmiennych decyzyjnych jest wyznaczana po realizacji niepewnych parametrów modelu. W odróżnieniu od wersji modelu, w której wszystkie zmienne decyzyjne dotyczące harmonogramu i wielkości dostaw są ustalane na początku okresu dla całego horyzontu planistycznego (*open loop settings* – ustawienia otwartej pętli) autorzy rozważają ten problem w wersji ze sprzężeniem zwrotnym (*closed loop settings* – ustawienia w zamkniętej pętli). W tym przypadku wartości zmiennych decyzyjnych są wyznaczane wraz z upływem czasu w zależności od rozwoju sytuacji. Badacze wskazują, iż jest to podejście które w większym stopniu odwzorowuje realia rzeczywistości. Dodatkowo w swojej pracy porównują otrzymane wyniki z rezultatami podejścia stochastycznego wskazując na jego bardzo dużą wrażliwość. W opracowaniu [7] można także odnaleźć sformułowanie typu *robust* sterowania zapasami dla metody zapasu minimalnego w literaturze zagranicznej jest znana jako *Base Stock Policy*, która zakłada iż, dla każdego przyjętego odstępu czasu można wyodrębnić pewien minimalny zapas krytyczny zapewniający ciągłość dystrybucji czy też produkcji. Podejmowane działania

uzupełniające zapas mają generować poziomy zapasów jak najbliższe zdefiniowanym poziomom krytycznym w poszczególnych okresach. Autorzy Adida E., Perakis G. rozważający wersję typu *robust* takiej metody wskazują na wymierne korzyści z jej stosowania. Inny sposób zagwarantowania cechy odporności rozwiązania optymalizacji poziomu zapasów prezentuje praca [12], w której dokonywana jest próba aproksymacji wariacji popytu w czasie o nieznanym rozkładzie dla okresowego monitorowania zapasów z wykorzystaniem modelu (R,S) oraz (R,Q). Dokonując studiów literatury z omawianego zakresu można napotkać również opracowania, które próbują powiązać ze sobą koncepcję niepewności i ryzyka. W tym rozumieniu ryzyko jest opisywane jako miara niedogodności występowania niepewności danych i parametrów [127,112]. Idea ta jest wykorzystana w opracowaniach [110, 101], w których rozwiązywany jest model optymalizacji typu *robust* dla problemu jednoetapowego optymalizacji zapasów towarów szybko starzejących się. Kryterium stanowią miary ryzyka (Conditional Value-at-Risk – CvaR, Value-at-Risk - VaR) [144] utraconej sprzedaży, bądź pozostałego nieprzydatnego już po określonym czasie towaru. Autorzy podkreślają wysoką odporność otrzymanego rozwiązania na niepewność popytu. W pozycji [10] jest rozwiązywany problem jednoetapowego sterowania zapasami, gdzie popyt jako parametr niepewny jest opisany jedynie średnią i odchyleniem standardowym.

#### 4.1.2 Rozwiązania wykorzystujące podejście stochastyczne

Innym sposobem modelowania niepewności, które można spotkać w literaturze jest wykorzystanie modeli stochastycznych. W optymalizacji stochastycznej niepewne parametry modelu z założenia podlegają znanemu w całości rozkładowi prawdopodobieństwa. W bardziej zaawansowanych podejściach parametry rozkładu znane są tylko częściowo. Idea optymalizacji stochastycznej często jest związana również z założeniem, że ograniczenia problemu mają być spełnione z określonym prawdopodobieństwem. W literaturze zagranicznej jest to określane jako *chance constrained programming*. Na podstawie pracy [14] ogólne sformułowanie takiego problemu, który jest odpowiednikiem deterministycznego problemu opisanego przez formułę (58) można przedstawić w następujący sposób:

$$\min_{x,t} \{t: Prob_{(C,A,b) \sim P} \{C^T x \leq t \ \& \ Ax \leq b\} \geq 1 - \varepsilon\} \quad (61)$$

Gdzie  $\varepsilon \ll 1$  jest poziomem tolerancji a  $P$  jest rozkładem prawdopodobieństwa danych modelu (C, A, b). Teoria oraz metody optymalizacji stochastycznej doczekały się szerokiego zastosowania w obszarze sterowania i optymalizacji poziomów zapasów w warunkach oddziaływania czynników niepewnych, o czym świadczy duża różnorodność prac naukowych z tego zakresu. W wielu opracowaniach rozważany jest problem zarówno okresowego jak i ciągłego przeglądu zapasów, w którym popyt bądź czas dostawy mają charakter stochastyczny. Modele te bazują na strategii zamawiania (R,T) oraz (R,Q). Dodatkowo niektórzy autorzy w swoich badaniach uwzględniają dodatkowe wymagania w postaci ograniczeń przestrzeni składowania, wielkości zamówień, przyjmowanego poziomu obsługi. Do rozwiązania tak postawionych problemów optymalizacji wykorzystywane są różne

techniki najczęściej w postaci programowania dynamicznego, procesów Markowa, symulowanego wyżarzania oraz różnego rodzaju heurystyki. Zestawienie tychże przykładowych opracowań przedstawia Tabela 2.

**Tabela 2.** Wykorzystanie podejścia stochastycznego w modelowaniu parametrów niepewnych problemu zapasów na podstawie strategii zamawiania (R,T) i (R,Q)

Autor opracowania	Okresowa kontrola zapasów	Ciąga kontrola zapasów	Dodatkowe ograniczenia	Parametr Stochastyczny	Wykorzystywana metoda
Chiang C. [32]	(R,T)			Popyt	Programowanie dynamiczne
Mohebbi E., Posner M. [90]		(R,Q)		Popyt i czas dostawy	Heurystyka
Ouyang L., Chang B. [100]	(R,T)		Poziom obsługi	Popyt	Heurystyka
Bylka S. [23]	(R,T)		Zamówienia, przestrzeń	Popyt	Heurystyka, Programowanie dynamiczne
Chiang et al. [31]	(R,T)			Popyt	Programowanie dynamiczne
Mohebbi E. [89]		(R,Q)		Popyt	Heurystyka
Qu et al. [111]	(R,T)		Połączone zam. dla wielu prod.	Popyt	Heurystyka
Taleizadeh et al. [136]	(R,T)		Poziom obsługi, przestrzeń	Okres uzupełniania zapasu	Symulowane wyżarzanie

Założenia stochastycznej optymalizacji są również często wykorzystywane w pracach, które rozważają sterowanie zapasami przez dostawcę (Vendor Managed Inventory - VMI). Podejście to stanowi szczególny przypadek ogólnej klasy modeli współpracy podmiotów w ramach całego łańcucha dostaw. Podstawą jest zacieśnienie więzi pomiędzy dostawcą a klientem, w której to dostawca przejmuje od klienta wszystkie aktywności związane z zarządzaniem zapasami i ich odnawianiem. Wspomniany problem ze stochastycznym popytem jest podejmowany w publikacjach [74, 34, 121, 58, 59]. Jako metodę rozwiązywania autorzy bardzo często wykorzystują rozszerzoną heurystykę Silvera Meala.

W literaturze można odnaleźć opracowania gdzie dokonywana jest analiza wpływu różnych poziomów zmienności popytu opisanego przy użyciu różnych rozkładów prawdopodobieństwa na efektywność sterowania [52]. Występują również publikacje, w których autorzy optymalizują poziom zapasów w całym wieloszczeblowym łańcuchu dostaw w oparciu kryterium najniższych kosztów przy założeniu stochastycznego popytu i czasu dostawy [1, 64]. W opracowaniu [151] autorzy proponują stochastyczny model planowania zapasów w łańcuchu dostaw jednocześnie uwzględniając aspekty optymalizacji wielkości produkcji, wyboru dostawców, w warunkach niepewnego popytu. W pracach [71, 77, 61], rozwiązywany jest problem sterowania zapasami i wielkością produkcji znany jako *Lot-Sizing Problem* jedynie w środowisku niepewnego popytu. Brak jest w nich uwzględnienia innych czynników niepewnych. W opracowaniu [139], prezentowane jest

problem stochastycznej optymalizacji zapasów surowców niezbędnych w produkcji z rabatami cenowymi oraz ograniczonością zasobów w oparciu o strategię (R,Q). W sytuacji zaistnienia braków surowców model dopuszcza, dodatkowe dostawy jednakże ich koszt jest linowo zależny od ich wielkości. W znalezieniu rozwiązań powyższych problemów badacze często wykorzystują mieszane programowanie całkowito liczbowe czy też heurystyczne programowanie dynamiczne. Pomimo wielu podejść i różnorodności metod i modeli probabilistycznych próbujących uwzględniać czynniki niepewne w sterowaniu zapasami praca [140] pokazuje, iż nie zawsze stosowanie teorii stochastycznej jest uzasadnione.

#### **4.1.3. Rozwiązania wykorzystujące narzędzia sztucznej inteligencji**

Problemy sterowania zapasami z parametrami stochastycznymi, jak wspomniano w powyższym podrozdziale, dają się rozwiązać przy zastosowaniu wielu metod analitycznych, algorytmów takich jak metoda Wagnera Withina, metod heurystycznych przykładowo metoda Silvera Meal'a itp. Wedle fundamentalnych założeń teorii prawdopodobieństwa modele stochastyczne są efektywne jeśli informacje wejściowe modelu są opisane za pomocą znanego rozkładu prawdopodobieństwa. W rzeczywistości, często jednak pewne rodzaje wymaganych danych mogą być bardzo niedokładne (incydenty, przepustowości dostawców, itp) lub informacja o nich może nie istnieć w ogóle. Dodatkowo trudność jednoczesnego uwzględnienia wpływu wielu zmiennych parametrów w modelach analitycznych, wysoki poziom skomplikowania modeli, wysoki nakład czasu i obliczeń w przypadku dużych rozmiarów zadania sprawiają, iż pojawiają się prace, które proponują ujmowanie niepewności wprowadzając środowisko rozmyte. Rozmyty model sterowania zapasami proponowany jest w pracy [28], gdzie wielkość popytu jak również poziom zapasu są wartościami rozmytymi. Autorzy opracowania [68] prezentują ciągły model kontroli zapasów w, którym parametrami rozmytymi są zarówno popyt oraz czas dostawy. W artykułach [85,114,137,66,81] można dostrzec podobne podejścia zakładające, iż zmienne takie jak: popyt, czas dostawy, koszty utrzymania zapasów, a nawet przestrzeń czy poziom obsługi są wartościami rozmytymi. Tabela 3. przedstawia wykorzystanie środowiska rozmytego w modelowaniu wybranych parametrów niepewnych w problemie sterowania zapasami.

**Tabela 3.** Wykorzystanie środowiska rozmytego w modelowaniu wybranych parametrów niepewnych w sterowaniu zapasami

Autor opracowania	Parametry							
	Popyt		Dostawa		Czas dostawy		Inne	
	P	NP	P	NP	P	NP	P	NP
Kamal L, Sculfort J.L [68]		+	+			+		+
Chede B, Jain C.K [28]		+	+			+		+
Tanthatemee T., Phruksaphanrat B.[140]		+	+			+	+	
Aengchuan P., Phruksaphanrat B.[8]		+		+	+		+	
Chang H.C.[27]		+				+		+
Liu S.T. [79]		+						+
Maity M.K.[81]		+						+
Taleizadeh A., Niaki S.T.A., [137]								+
Roy A. et al. [114]		+						+

P – parametr przyjmuje wartości deterministyczne, NP. – parametr opisany za pomocą środowiska rozmytego

Pomimo wielu opracowań podejmujących problematykę optymalizacji poziomu zapasów w warunkach oddziaływania czynników niepewnych w większości pozycji proponowane metody nie uwzględniają tych parametrów jednocześnie a także wykazują niewielką zdolność do adaptacji dla nagle zmieniających się warunków zewnętrznych. Proponowane rozwiązania i modele ze względu na duży stopień skomplikowania i złożoności obliczeniowej wymagają zaawansowanych i inteligentnych metod poszukiwania optymalnego rozwiązania. Dlatego też coraz częściej badacze do rozwiązywania problemów logistyki zaopatrzenia proponują metody oparte na wykorzystaniu różnych technik sztucznej inteligencji. W pracach [62, 105], autorzy do rozwiązania problemu zapasów stosują wielokryterialny algorytm optymalizacji rojem cząstek (MOPSO – Multi objective particle swarm optimization). W opracowaniach [106, 3], autorzy do rozwiązania problemu wykorzystują genetyczny algorytm NSGA – II (Non Sorting Genetic Algorithm). W pracach [95,133] prezentowane są przykłady hybrydowego algorytmu genetycznego dla zagadnienia zapasów z możliwością opóźnionej realizacji popytu. Prace te dokonują również porównania otrzymanych wyników z rezultatami algorytmów PSO. W badaniach zawartych w [92] badacze prezentują wielokryterialny, wielo etapowy model zapasów dla wielu produktów z uwzględnieniem czynnika inflacji, rabatów, z możliwością opóźnionej realizacji popytu jak i popytem traconym. Do uzyskania rozwiązania autorzy proponują wykorzystanie trzech typów algorytmów genetycznych w postaci NSGA – II, NPGA (Non-Dominated Ranked Genetic Algorithm) oraz MOPSO. Przeprowadzone przez badaczy analizy na podstawie obliczeniowych przykładów ilustrujących wyjaśniają różnice w efektywności w stosowanych podejściach. Zastosowanie algorytmu genetycznego do



rozwiązania nieliniowego dyskretno ciągłego modelu optymalizacji zapasów ze stochastycznym popytem, oraz zmiennymi kosztami zostało również zaproponowane w pracach [138, 81,134,125,115]. Dostępna literatura zagraniczna prezentuje znacznie większe spektrum rozszerzeń do podstawowych metod sterowania zapasami w porównaniu do krajowych pozycji. Zagraniczni badacze próbują w miarę możliwy sposób maksymalnie dostosować prezentowane w swoich pracach metody do warunków rzeczywistych uwzględniając wiele cech i czynników wpływających na efektywność stosowanej przez przedsiębiorstwo metody kontroli zapasów. Powoduje to znaczące skomplikowanie rozwiązywanego zadania przez co coraz częściej literatura obcojęzyczna rekomenduje rozwiązania oparte na zastosowaniu technik sztucznej inteligencji. Powodem doskonalenia metod i modeli w tym obszarze jest nieustanne dążenie przedsiębiorstw do zmniejszenia poziomu niepewności w podejmowaniu decyzji w obszarze logistyki zapasów oraz zagwarantowanie możliwie najwyższego poziomu obsługi klientów przy równoczesnym ograniczaniu wydatków.

#### **4.2 ZAŁOŻENIA I CHARAKTERYSTYKA PROPONOWANEJ METODY STEROWANIA ZAPASAMI TOWARÓW W WARUNKACH NIEPEWNOŚCI Z WYKORZYSTANIEM NARZĘDZI SZTUCZNEJ INTELIGENCJI**

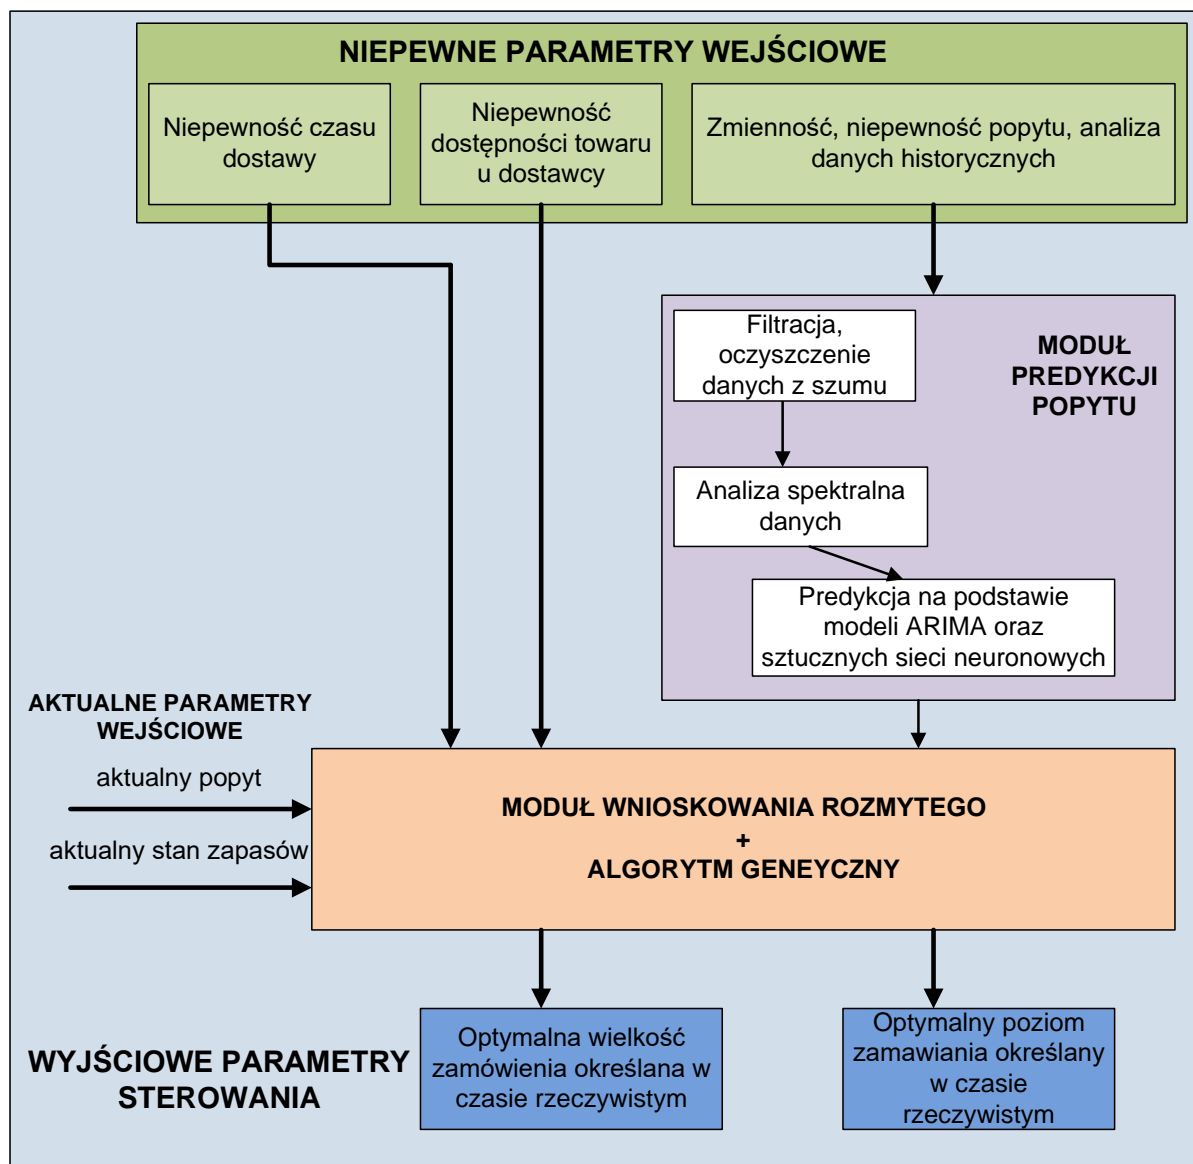
Przeprowadzone w studia literaturowe ukazują duży zasób dostępnych różnych publikacji i opracowań podejmujących problematykę sterowania zapasami w otoczeniu oddziaływania czynników niepewnych. Mimo to w dalszym ciągu istnieje niewiele sprawdzonych rozwiązań, które uwzględniałyby wpływ tychże kilku czynników jednocześnie, bez konieczności analitycznego rozwiązywania złożonych modeli matematycznych. Innym spostrzeżeniem jest brak podejść, które zagwarantowałyby pewien stopień elastyczności i antycypacyjną naturę systemu zapasów umożliwiającą mu dynamiczną reakcję na gwałtownie zachodzące zmiany parametrów. Na podstawie zaobserwowanych przesłanek, w podrozdziale tym zostanie przedstawiona charakterystyka wraz z niezbędnymi założeniami proponowanej przez autora metody rozwiązywania problemu sterowania zapasami towarów w warunkach niepewności z wykorzystaniem dedykowanych narzędzi sztucznej inteligencji w postaci sztucznych sieci neuronowych, logiki rozmytej oraz algorytmów genetycznych. Proponowane podejście dotyczy przepływu strumieni wybranych pozycji asortymentowych rozpatrywanych oddzielnie przez pojedyncze ogniwo w sieci logistycznej w postaci magazynu bądź centrum dystrybucyjnego, które zaopatrywane jest w towar u pojedynczego dostawcy. Celem proponowanej metodyki jest znalezienie takiego harmonogramu dostaw w rozważanym horyzoncie czasu dla wybranego ogniwa, który minimalizuje poziom zapasów, liczbę potencjalnych braków w zapasie oraz liczbę wykonywanych dostaw. Kryteria te w dalszej kolejności przekładają się bowiem na ponoszone przez przedsiębiorstwo koszty utrzymania zapasów, koszty transportu związane z wykonywaniem dostaw oraz na poziom obsługi klienta związany z dostępnością produktu w określonym czasie.

### **Założenia do rozważanego problemu sterowania zapasami w warunkach niepewności:**

- obiekt badań stanowi pojedyncze ogniwo w sieci dostaw stanowiące punkt dystrybucji produktów gotowych,
- dostawy uzupełniające zapas pochodzą od pojedynczego dostawcy,
- zapotrzebowanie na produkty ma charakter niepewny, profile popytu w postaci rozkładów prawdopodobieństwa nie są znane,
- na system zapasów w rozważanym punkcie oddziałują poza nieokreślonością popytu dodatkowe czynniki niepewne w postaci ograniczonej dostępności towaru u dostawcy w określonej chwili czasu, jak również niepewność czasu realizacji dostawy,
- czas realizacji dostawy przybiera wartości z zadanego przedziału nieokreśloności z równym prawdopodobieństwem,
- zakres niepewności dostępności towaru u dostawcy opisany jest wartością średnią oraz odchyleniem standardowym,
- znane są dopuszczalne maksymalne poziomy składowania dla każdego z produktów,
- nieobsłużone zapotrzebowanie na produkt w sytuacji wystąpienia niedoboru zapasu jest w całości tracone,
- monitoring i inteligentny nadzór poziomu zapasów jest ciągły,
- sterowanie poziomem zapasu jest prowadzone indywidualnie dla każdego produktu,
- rabaty cenowe od dostawców nie są rozważane,

Na podstawie tak przyjętych założeń, do rozwiązania postawionego problemu sterowania poziomem zapasów w warunkach niepewności zaproponowano podejście oparte na systemowym wykorzystaniu dedykowanych narzędzi sztucznej inteligencji. Ogólny schemat metody, struktury powiązań jej komponentów przedstawiony jest na rys. 18.





**Rys. 18.** Architektura proponowanego podejścia do rozwiązania problemu sterowania zapasami w warunkach niepewności

*Źródło: opracowanie własne*

Zasadniczymi elementami składowymi prezentowanego podejścia są moduł predykcji oraz moduł wnioskowania rozmytego wsparty działaniem algorytmu genetycznego. Każdy z nich jest powiązany z odpowiednimi strumieniami informacji wejściowych na podstawie których w dalszej kolejności wyznaczane są optymalne normy sterowania. W związku z tym w proponowanym systemie sterowania można wyróżnić dwa typy danych wejściowych: niepewne parametry wejściowe oraz aktualne parametry wejściowe. Pierwszy typ odnosi się do danych niepewnych opisujących równoczesne oddziaływanie na system zmiennych czynników zewnętrznych, natomiast drugi zaobserwowane wartości rzeczywiste niezbędne w procesie monitorowania działania systemu. Szerszy opis funkcjonalności modułów wraz z wykorzystanymi narzędziami badawczymi zostanie przedstawiony w kolejnych podrozdziałach.

#### 4.2.1 Struktura i funkcjonalność modułu predykcji

Moduł predykcji w przedstawianym podejściu jest odpowiedzialny za trafne rozpoznawanie mechanizmów kształtujących zapotrzebowanie na dany produkt, zmieniających się trendów a także za efektywne prognozowanie przyszłych wartości zapotrzebowania na towar. Z uwagi na kształtowanie popytu przez wiele, czynników oraz determinant, o których była mowa w rozdziale 3.3.3 wybór właściwych narzędzi prognozowania jest niezwykle istotny. W sytuacjach rzeczywistych bardzo często spotykane są przykłady produktów, które są istotne dla przedsiębiorstwa lecz cechują się dużą zmiennością zapotrzebowania w czasie. W takich przypadkach bardzo trudno jest sporządzać wiarygodne prognozy na podstawie przedstawionych dotychczas podstawowych modeli predykcji. Dlatego też w ramach modułu predykcji występują trzy elementy: filtracja i oczyszczanie danych z szumu, analiza spektralna danych oraz predykcja na podstawie modelu autoregresyjnego ARIMA (Autoregressive Integrated Moving Average) i sztucznych sieci neuronowych.

##### 4.2.1.1 Filtracja danych o zapotrzebowaniu na towary

W analizie i predykcji popytu, który jest zazwyczaj reprezentowany w postaci szeregów czasowych zakłada się, że w danych można wyodrębnić składnik systematyczny oraz losowy szum (zakłócenia), przez który utrudniony jest proces identyfikacji mechanizmów oraz struktury czynników kształtujących dane zjawisko. Szum informacyjny może występować w postaci niepoprawnych, brakujących czy też nieistotnych informacji w danym szeregu. Wpływ na to ma wiele czynników np. niedokładność urządzeń pomiarowych, przerwy w działaniu urządzenia rejestrującego, wpływ kalendarza. Zatem na wstępie nieprzetworzone historyczne dane o popycie, które trafiają do modułu predykcji podlegają filtracji w celu eliminacji zbędnych zakłóceń. Odbywa się to przy użyciu odpowiedniego filtra. Filtr matematycznym nazywany jest taki operator transformacji, który dokonuje przetworzenia szeregu czasowego czy też sygnału wejściowego w inny szereg bądź sygnał wyjściowy a transformacja taka nazywana jest filtracją. Na potrzeby prezentowanego rozwiązania został wykorzystany filtr Hodricka – Prescottta. Przekształcenie to pozwala na wyłonienie z szeregu czasowego stochastycznego, gładko zmieniającego się w czasie trendu. Innymi słowy z szeregu odseparowywane są wahania o wysokich częstotliwościach. Stąd ten typ filtracji zaliczany jest do grona filtrów górno pasmowych [65]. Po wykonaniu takiego przekształcenia szereg można przedstawić jako sumę następujących dwóch składowych:

$$y_t = g_t + c_t \quad (62)$$

gdzie:

$g_t$  - wygładzony zmienny trend

$c_t$  – składowa cykliczna

Poszukiwana składowa  $g_t$  dla wszystkich  $g_1 \dots g_T$  jest otrzymywana przez filtr w wyniku rozwiązania problemu minimalizacji funkcji:

$$PO_{min}: \sum_{t=1}^T c_t^2 + \lambda \sum_{t=2}^{T-1} ((g_{t+1} - g_t) - (g_t - g_{t-1}))^2 \quad (63)$$

gdzie:

$t = 1 \dots T$  - zmienna czasowa,

$\lambda$  – parametr wygładzania,

Pierwsza składowa funkcji ma na celu minimalizowanie różnicy pomiędzy wartościami rzeczywistymi a składową trendu, natomiast druga składowa kwadrat różnicy drugiego rzędu składowej trendu, co jest analogiczne do minimalizacji pochodnej drugiego rzędu ze składowej trendu. Poprzez poddanie danych popytowych tego typu filtracji otrzymany nowy szereg jest już w mniejszym stopniu poddany wpływowi zakłóceń dzięki czemu składowa systematyczna jest lepiej wyeksponowana i możliwa do rozpoznania.

#### 4.2.1.2 Analiza spektralna danych o zapotrzebowaniu na towary

Kolejnym ważnym elementem w module predykcji jest przeprowadzenie analizy historycznych danych popytowych w dziedzinie częstotliwości (Analiza spektralna). Bardzo często istotnym komponentem szeregów czasowych reprezentujących popyt jest występowanie cykli o różnych długościach, które wpływają na poziom zmienności zapotrzebowania dla danego produktu. Nałożenie się wielu składowych cyklicznych o różnych częstotliwościach w połączeniu z wahaniami przypadkowymi powoduje, iż powszechnie stosowane metody prognozowania w tego typu przypadkach są często mało dokładne. Podstawowym celem analizy spektralnej jest zwrócenie uwagi na cykliczność procesów. Zakłada ona falową strukturę przebiegów zmiennych procesów stochastycznych pozwalając analizować szereg w dziedzinie częstotliwości. Jest to możliwe dzięki zastosowaniu funkcji trygonometrycznych w postaci funkcji sinus i cosinus, które często nazywa się harmonikami. Liczba harmonik dla  $n$  obserwacji wynosi  $n/2$ . Pierwsza harmonika posiada okres równy  $n$ , druga  $n/2$ , kolejna  $n/3$  etc. Warunkiem stosowania takiego podejścia jest stacjonarność szeregu czasowego. W przeciwnym wypadku z szeregu należy usunąć trend lub sprowadzić do stacjonarności poprzez operację różnicowania [98], W ten sposób przebieg danego procesu można przedstawić w następujący sposób:

$$Y_t = Y^{sr} + \sum_{i=1}^{n/2} \left[ a_i \sin\left(\frac{2\pi}{n} it\right) + b_i \cos\left(\frac{2\pi}{n} it\right) \right] \quad (64)$$

gdzie:

$i$  - numer harmoniki,

$a_1, a_2, b_1, b_2 \dots$  - wartości parametrów (stałe),

$Y^{sr}$  – przeciętny poziom zmiennej prognozowania,

Wartości parametrów  $a_1, a_2, b_1, b_2$  są otrzymywane przy pomocy metody najmniejszych kwadratów, korzystając z następujących wzorów:

$$a_i = \frac{2}{n} \sum_{t=1}^n \left[ Y_t \sin \left( \frac{2\pi}{n} it \right) \right] \quad \text{dla } i = 1 \dots \frac{n}{2} - 1 \quad (65)$$

$$b_i = \frac{2}{n} \sum_{t=1}^n \left[ Y_t \cos \left( \frac{2\pi}{n} it \right) \right] \quad \text{dla } i = 1 \dots \frac{n}{2} - 1 \quad (66)$$

Dla ostatniej harmoniki należy przyjąć iż:

$$a_{n/2} = 0 \quad (67)$$

$$b_{n/2} = \frac{1}{n} \sum_{t=1}^n [Y_t \cos(\pi t)] \quad (68)$$

Wykorzystując dyskretną transformatę Fouriera rozważanego szeregu czasowego otrzymuje się widmo, które jest funkcją częstotliwości. Wyznaczone widmo pozwala określić, które z częstotliwości są w stanie wyjaśnić zmienność szeregu w największym stopniu, czyli te, mające największy wpływ na wariancję prognozowanej zmiennej [153]. Część całkowitej wariancji zmiennej wyjaśnianej przez  $i$ -tą harmonikę przedstawiają poniższe wzory:

$$\omega_i = \frac{a_i^2 + b_i^2}{2\sigma^2} \quad \text{dla } i = 1 \dots \frac{n}{2} - 1 \quad (69)$$

$$\omega_i = \frac{a_i^2 + b_i^2}{\sigma^2} \quad \text{dla } i = \frac{n}{2} \quad (70)$$

gdzie:

$\sigma^2$  - wariancja prognozowanej zmiennej po uprzednim odjęciu trendu,

Wykorzystanie tego typu analizy w przedstawianym podejściu pomoże zidentyfikować istotne składowe cykliczne o różnych częstotliwościach, które w znacznym stopniu wyjaśniają zmienność rozpatrywanych danych popytu, przez co w dalszej kolejności będą stanowić składową modelu predykcji zapotrzebowania.

#### 4.2.1.3 Hybrydowy model predykcji popytu na podstawie modeli autoregresyjnych ARIMA oraz sztucznych sieci neuronowych

Ostatnim etapem w module predykcji jest budowa modelu predykcji popytu, wykorzystującego dotychczasową wiedzę o rozpatrywanym zapotrzebowaniu na produkt z przeprowadzonych analiz w poprzednich elementach modułu. Wspomniany model został stworzony w oparciu o wykorzystanie zintegrowanych modeli autoregresji i średnich ruchomych ARIMA, modelu spektralnego oraz sztucznych sieci neuronowych. Modele ARIMA (Auto - Regressive Integrated Moving Average) należą do grupy zaawansowanych narzędzi prognozowania, odpowiednich dla modelowania procesów cechujących się dużą dynamiką oraz trudnością w określeniu jednoznacznych zależności kształtujących przebieg analizowanego szeregu czasowego. Wykorzystują zjawisko autokorelacji, co oznacza korelację wartości zmiennej prognozowanej z wartościami tej samej zmiennej opóźnionymi w czasie. Ich podstawową cechą charakterystyczną jest fakt, iż wartość prognozowanej zmiennej w chwili  $t$  jest kombinacją liniową wartości tej samej zmiennej z okresów poprzednich  $t-1, t-2, \dots, t-p$  powiększoną o pewną wartość składnika losowego. Wśród tego typu modeli można wyodrębnić trzy podstawowe ich rodzaje:

- modele autoregresji (AR),
- modele średniej ruchomej (MA),
- zintegrowane modele autoregresji i średniej ruchomej (ARIMA),

W ogólny sposób model autoregresji rzędu  $p$  można przedstawić następująco:

$$Y_t = \varphi_0 + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + e_t \quad (71)$$

gdzie:

$Y_t, Y_{t-1}, Y_{t-2}, Y_{t-p}$  - wartości badanej zmiennej odpowiednio w chwili  $t, t-1, t-2, t-p$ ,

$\varphi_0, \varphi_1, \varphi_2, \dots, \varphi_p$  - parametry modelu,

$e_t$  - wartość składnika losowego w okresie  $t$ ,

$p$  - rząd opóźnienia,

Parametr opóźnienia  $p$  określa jak daleko należy sięgnąć w przeszłość, aby określić wartość zmiennej prognozowanej w chwili  $t$ . W rzeczywistości mogą zdarzyć się procesy, w których niezależnie od procesu autoregresyjnego, każdy element szeregu może pozostawać pod wpływem realizacji składnika losowego w okresach przeszłych, gdzie wpływ ten nie może być wyjaśniony przez składnik autoregresyjny. Mamy wtedy do czynienia z procesem średniej ruchomej (MA), który można zapisać wzorem:

$$Y_t = \vartheta_0 - \vartheta_1 e_{t-1} - \vartheta_2 e_{t-2} - \dots - \vartheta_q e_{t-q} + e_t \quad (72)$$

gdzie:

$e_t, e_{t-1}, e_{t-2}, e_{t-q}$  - reszty modelu odpowiednio w chwili  $t, t-1, t-2, t-q$ ,

$\vartheta_0, \vartheta_1, \vartheta_2, \vartheta_p$  - parametry modelu,

$q$  - rząd opóźnienia,

Bardzo często jednak, w celu lepszej adaptacji do danych historycznych modelowanego procesu stochastycznego, dokonuje się połączenia modelu (AR) i (MA) w jeden model autoregresji i średniej ruchomej, zwany (ARIMA), posiadający zarówno parametr  $p$  jak i  $q$ . Dodatkowo do postaci modelu wprowadzany jest operator różnicowania  $d$  opisujący stopień zintegrowania szeregu. W ten sposób otrzymywany jest model oznaczany według notacji Boxa Jenkinsa jako ARIMA ( $p,d,q$ ) posiadający wszystkie trzy parametry. Takie połączenie można przedstawić w następujący sposób:

$$Y_t = \varphi_0 + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + e_t - \vartheta_0 - \vartheta_1 e_{t-1} - \vartheta_2 e_{t-2} - \dots - \vartheta_q e_{t-q} \quad (73)$$

W przedstawionym modelu wartość prognozowanej zmiennej w określonej chwili  $t$  zależy od jej wartości z przeszłości, jak również od reszt z modelu w poprzednich chwilach czasu. Warunkiem wymaganym do stosowania rozważanych modeli jest stacjonarność szeregu czasowego danych wejściowych. Najogólniej poprzez stacjonarność można rozumieć stałą w czasie średnią, wariancję i autokorelację dla rozpatrywanego szeregu danych. Zazwyczaj szereg wymaga różnicowania aż do osiągnięcia stacjonarności. To, ile razy szereg powinien być różnicowany, aby osiągnąć stacjonarność, wyraża parametr  $d$ . W celu określenia koniecznego poziomu różnicowania, analizowany jest wykres danych i wykres funkcji autokorelacji dla kolejnych opóźnień (autokorelogram).

Wybór właściwego modelu ARIMA stanowi jedną z zasadniczych trudności w stosowaniu ich jako narzędzia do prognozowania. Proces doboru jego parametrów zawiera się zazwyczaj w trzech etapach:


- identyfikacji,
- estymacji,
- weryfikacji.

Na początku należy dokonać identyfikacji szeregu czasowego, reprezentującego dany proces, czyli określić czy jest on stacjonarny. W tym celu najczęściej wykonuje się test statystyczny pierwiastka jednostkowego zwany testem Dickey'a Fullera. W przypadku stwierdzenia braku stacjonarności szereg poddaje się operacji różnicowania. Następnie wymagane jest określenie rzędu opóźnień czasowych  $p$  i  $q$ . Zazwyczaj dokonuje się tego poprzez analizę funkcji autokorelacji (ACF - *autocorrelation function*) oraz autokorelacji częściowej (PACF - *partial autocorrelation function*). Alternatywnie można również skorzystać z kryteriów informacyjnych Schwarz'a lub Akaike. Metody te zostały szerzej przedstawione w pracy B. Choi [33,40].



Kolejnym etapem w budowie modelu jest estymacja jego współczynników. Można jej dokonać przy pomocy metody najmniejszych kwadratów, największej wiarygodności lub korzystając z równań Yule'a - Walkera, która jest szeroko opisana przez G. E. P. Boxa [21]. W końcowym etapie zbudowany model predykcji poddawany jest weryfikacji. Na tym poziomie należy zbadać autokorelację reszt (różnicy pomiędzy wartościami przyjętego modelu a wartościami rzeczywistymi). Współczynniki autokorelacji reszt modelu nie powinny różnić się istotnie od zera. W przeciwnym wypadku należy wrócić do etapu identyfikacji i dobrać parametry modelu ponownie. Jeżeli analiza reszt modelu nie wykaże autokorelacji, zbudowany model można wykorzystać do sporządzenia prognozy.

Z uwagi na możliwość występowania przebiegów popytu o nieliniowym charakterze, bądź też zależności pomiędzy elementami szeregu, które nie są możliwe do opisanie przy pomocy matematycznych formuł, zastosowane powyżej metody w pewnych przypadkach mogą okazać się niewystarczające. Dlatego w module predykcji jako wsparcie dla modeli ARIMA wykorzystane zostały sztuczne sieci neuronowe (ANN). Ich głównym celem jest rozpoznanie potencjalnych informacji i zależności, które nie zostały zidentyfikowane przez model ARIMA. Zasadność takiego podejścia potwierdzają zagraniczne opracowania, które coraz częściej ukazują rosnące zastosowanie inteligentnych narzędzi, jakimi są sztuczne sieci neuronowe oraz modele hybrydowe w obszarze modelowania i prognozowania popytu w łańcuchach dostaw [2,41,48,63]. Sztuczne sieci neuronowe jako struktury modelowane przy użyciu narzędzi komputerowych mają zdolność przekształcania informacji wzorując się na działaniu mózgu istot żywych. Mózg taki pracuje w oparciu o połączone ze sobą neurony. Strukturę pojedynczego neuronu przedstawia rys. 19.



**Rys. 19.** Model pojedynczego nieliniowego neuronu

*Źródło: opracowanie własne na podstawie [116]*

Pojedynczy neuron jest zbudowany z zestawu wejść oznaczonych jako  $x_1, x_2, x_3 \dots x_n$ , zbioru wag przypisanych do każdego z wejść  $w_0 \dots w_n$ , wartości wyjściowej neuronu  $y$  oraz funkcji aktywacji  $f(s)$ . Formalnie działanie neuronu można przedstawić w poniższy sposób:

$$y = f(s) \quad (73)$$

gdzie:

$$s = \sum_{i=0}^n x_i w_i \quad (74)$$

Zgodnie z przedstawionym schematem sygnały wejściowe zostają przemnożone przez odpowiadające im wagi. Otrzymane wartości są sumowane dając sygnał  $s$ , który następnie poddawany jest nieliniowej funkcji aktywacji  $f(s)$ . Pomimo iż, zasada działania neuronu jest prosta, to dzięki występowaniu ich w dużej liczbie i we wzajemnych połączeniach – sieć neuronów zagregowana w warstwy z odpowiednio dobranymi wagami jest w stanie odzwierciedlać pewną wiedzę i może być użyteczna do rozwiązania postawionych zadań. Zatem potęga sieci neuronowych kryje się w odpowiedniej strukturze sieci, co jest rozumiane jako właściwy dobór liczby neuronów i zorganizowanie go w odpowiednią liczbę warstw a także w odpowiedniej metodzie uczenia sieci. Ze względu na architekturę sieci wyróżniane są sieci jednowarstwowe, wielowarstwowe oraz rekurencyjne. Na potrzeby realizacji zadania prognozowania w rozważanym module predykcji przedstawione treści będą dotyczyły sieci wielowarstwowych jednokierunkowych. Każda sieć wielowarstwowa składa się z neuronów w warstwie wejściowej, na którą podawany jest sygnał wejściowy, neuronów w warstwach ukrytych oraz warstwy wyjściowej, w której otrzymywana jest odpowiedź sieci na zadany sygnał wejściowy. Jeżeli przepływ sygnału w sieci następuje tylko w jednym kierunku to taka sieć nazywana jest jednokierunkową, w odróżnieniu od sieci rekurencyjnych ze sprzężeniem. Efektywność działania sieci oraz jej zdolność do reprezentowania wiedzy o postawionym problemie zależy również od doboru metody trenowania bądź inaczej uczenia sieci. Podstawową ideą opisującą metodę uczenia sieci z nauczycielem, na której bazuje większość innych algorytmów nauczania jest metoda DELTA. Przedstawia ona sposób modyfikacji wag neuronów dla każdej iteracji w procesie uczenia. Uczenie sieci z nauczycielem polega na pomiarze różnicy pomiędzy otrzymaną wartością sygnału na wyjściu sieci  $y$  a odpowiadającym mu sygnałem wzorcowym  $d$  dla każdego elementu ciągu uczącego. Ciąg ten jest definiowany jako zbiór par mających postać  $\langle X_j, d_j \rangle$  w którym  $X$  zadany w  $j$ -tym kroku procesu uczenia jest wektorem sygnału wejściowego. Ogólnie ciąg uczący  $U$  ma postać:

$$U = \{ \langle X_1, d_1 \rangle, \langle X_2, d_2 \rangle, \dots, \langle X_N, d_N \rangle \} \quad (75)$$

Zatem celem procesu nauczania jest minimalizacja błędu odpowiedzi neuronu w odniesieniu do wartości wzorcowej. Funkcję mierzącą ten błąd można zapisać w poniższy sposób:

$$E(W) = \frac{1}{2} \left[ d - f \left( \sum_{i=0}^n w_i x_i \right) \right]^2 \quad (76)$$

Ze względu na to iż funkcja aktywacji wykorzystanych do predykcji neuronów jest funkcją ciągłą i różniczkowalną poszukiwane minimum błędu jest wyznaczane zazwyczaj przy użyciu metod gradientowych. Sposób aktualizacji  $i$ -tej wagi neuronu w  $t+1$  iteracji procesu uczenia przedstawia wzór:

$$w_i(t + 1) = w_i(t) - \mu \frac{\partial E(w_i)}{\partial w_i} \quad (77)$$

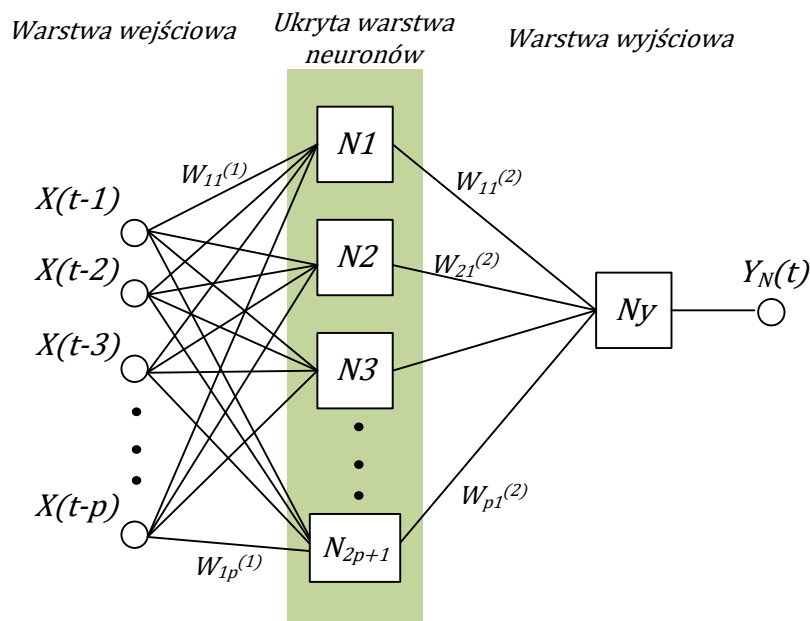
gdzie:

$\mu$  - współczynnik uczenia,

Występujący w formule (77) współczynnik uczenia  $\mu$  jest istotnym parametrem mającym wpływ na skuteczność uczenia. Decyduje on o długości kroku w kierunku poprawy rozwiązania funkcji błędu. Zbyt niska jego wartość powoduje, że uczenie jest długotrwałe i mało efektywne. Zbyt wysoka wartość może sprawić, że optymalne rozwiązanie (kombinacja wartości wag) zostanie zgubione co w konsekwencji spowoduje brak zbieżności algorytmu. Właściwy dobór tego współczynnika jest zależny od typu zadanego problemu i jego wartość jest zazwyczaj ustalana eksperymentalnie. W przypadku sieci wielowarstwowych w których wyjścia neuronów jednej warstwy ukrytej stanowią wejścia drugiej przedstawiona metoda korekcji wag wymaga uogólnienia. Tym uogólnieniem jest algorytm wstecznej propagacji błędu w którym informacja o błędzie odpowiedzi sieci jest przekazywana od warstw końcowych do początkowych, dzięki czemu istnieje możliwość modyfikacji wag we wszystkich warstwach. Dokładny opis algorytmu wraz z jego modyfikacjami oraz inne metody uczenia sieci są szeroko przedstawione w [135]. Dodatkowym elementem bez którego sieć nie będzie realizowała postawionego zadania jest ustalenie właściwej liczby neuronów zorganizowanych odpowiednio w warstwy. Zbyt mała liczba neuronów w stosunku do złożoności postawionego problemu może okazać się niewystarczająca do efektywnego nauczenia sieci, natomiast zbyt duża ich liczba może doprowadzić do sytuacji przeuczenia sieci. W zjawisku tym sieć dopasowuje się jedynie do danych uczących bez zdolności uogólnienia wiedzy przez co nie radzi sobie z danymi z poza zestawów uczących. Dlatego wykorzystywane ciągi uczące dzieli się na zestawy uczące i testujące. Uczenie sieci odbywa się tylko i wyłącznie na podstawie danych z zestawu uczącego, ale dodatkowo na bieżąco jest również oceniana jej skuteczność poprzez dane ze zbioru testowego. W sytuacji kiedy wyznaczane w kolejnych epokach uczenia błędy odpowiedzi sieci dla zbioru testującego zaczynają rosnać a błędy dla zbioru uczącego maleć wówczas sieć dopasowując się do konkretnych przypadków w zbiorze uczącym traci swoją zdolność do poprawnego uogólniania wiedzy.

Zatem wstępny dobór architektury oraz liczby neuronów w do wsparcia procesu prognozowania popytu realizowanego przez blok predykcji został wykonany w oparciu o twierdzenie Kołmogorowa znane w teorii sieci neuronowych. Dowodzi ono, iż dla funkcji ciągłych przekształcających  $K$  - wymiarowy zbiór wejść  $x$  w  $M$  – wymiarowy wektor wyjściowy możliwa jest aproksymacja takiego odwzorowania przy użyciu sieci z jedną warstwą ukrytą. Według twierdzenia, przy  $K$  – wejściach wystarczające jest użycie  $(2K+1)$

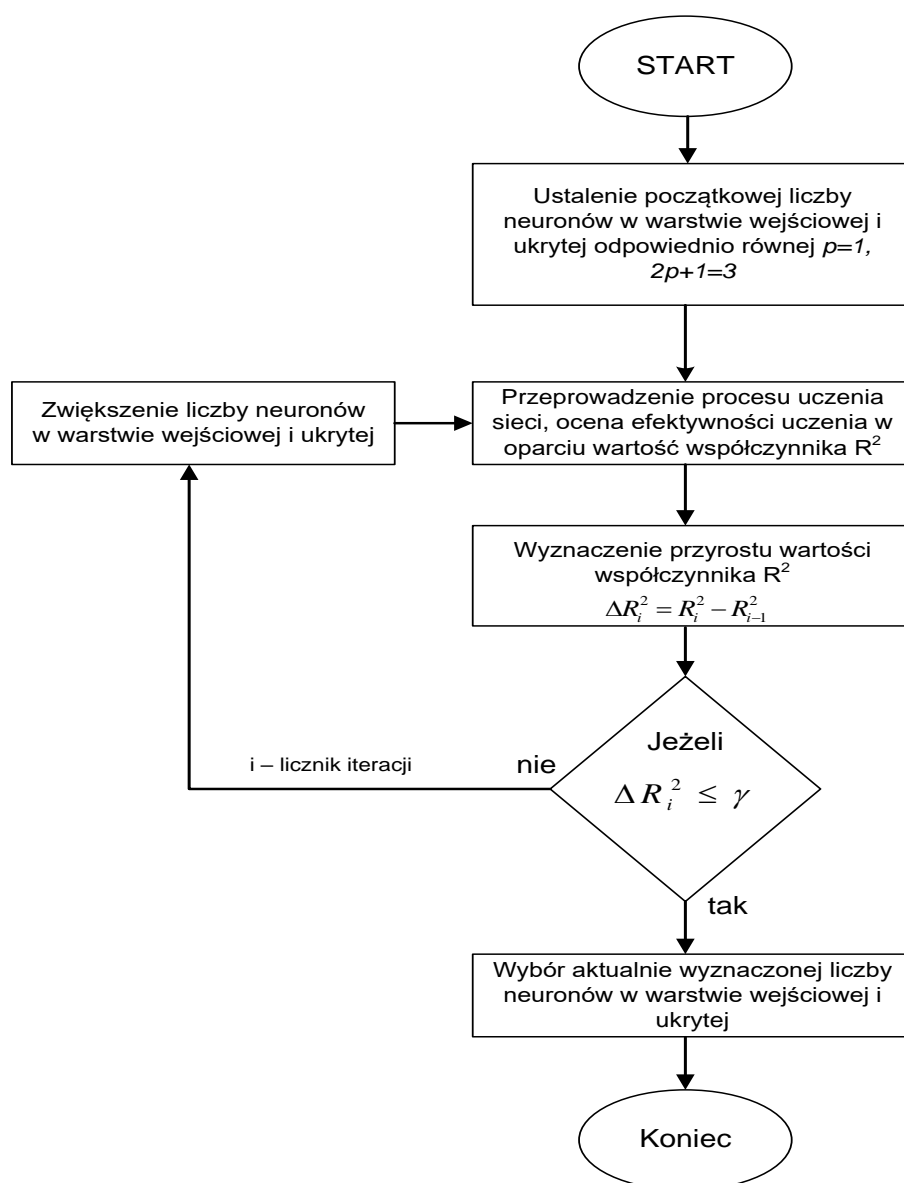
neuronów w warstwie ukrytej. W sytuacji odwzorowania nieciągłego w ogólnym wypadku wymagane jest użycie dwóch warstw ukrytych [99]. Na potrzeby pracy zostało przyjęte założenie, że dane na temat popytu na rozpatrywane towary mają naturę ciągłą. Wobec tego jako wyjściową przyjęto sieć z jedną warstwą ukrytą poniższej strukturze rys. 20.



**Rys. 20.** Struktura wykorzystywanej sieci neuronowej

Źródło: opracowanie własne

Oznaczenia  $X(t-1), X(t-2), \dots, X(t-p)$  będące sygnałami wejściowymi do sieci stanowią odpowiednio wartości zmiennej prognozowanej w okresach  $t-1, t-2, t-3, t-p$ . Sygnał wyjściowy natomiast ma wartość  $Y_N(t)$ . W praktyce bardzo często bezpośrednie zastosowanie twierdzenia Kołmogorowa nie gwarantuje optymalnej efektywności sieci. Dlatego w sporządzanych modelach prognozy popytu liczba neuronów w warstwie ukrytej wyznaczona za pomocą tego twierdzenia będzie wartością bazową, która w dalszej drodze eksperymentalnej będzie odpowiednio dostosowywana jak również opcja optymalnej liczby warstw będzie dostępną alternatywą. Zastosowana procedura dostosowywania architektury sieci zakłada przeprowadzenie procesu trenowania sieci dla kolejnych konfiguracji liczby neuronów w warstwie wejściowej i ukrytej. Punktem wyjściowym jest liczba neuronów wejściowych równa  $p=1$ , liczba neuronów w warstwie ukrytej równa  $2p+1=3$ . W dalszej kolejności na podstawie rezultatów procesu uczenia mierzonego wartością współczynnika  $R^2$  (dla ciągów uczących oraz testujących) liczba neuronów w warstwie wejściowej i ukrytej jest stopniowo zwiększana do momentu kiedy przyrost wartości współczynnika  $R^2$  w kolejnych iteracjach jest mniejszy od wartości zadanego progu  $\gamma$ . Schemat procedury doboru struktury dla sztucznej sieci neuronowej w budowanym hybrydowym modelu predykcji popytu przedstawia rys. 21.



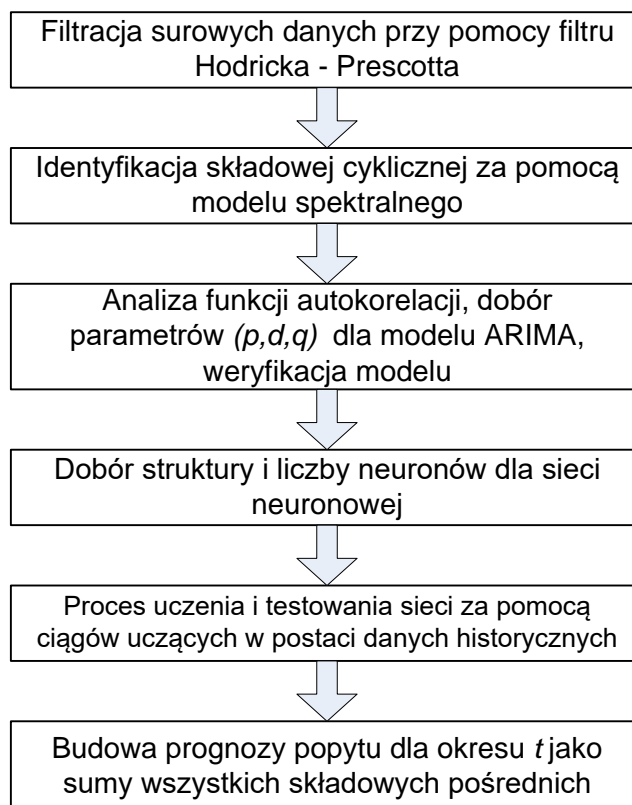
**Rys. 21.** Procedura doboru struktury sieci neuronowej

*Źródło: opracowanie własne*

Reasumując aby ograniczyć w jak największym stopniu poziom niepewności popytu dla danego artykułu, utworzony hybrydowy model predykcji popytu ma na celu wykorzystanie zalet wszystkich przywołanych powyżej technik poprzez odpowiednie ich połączenie i zastosowanie. W związku z tym prognozowaną wartość popytu  $Y^P(t)$  dla pojedynczego artykułu w chwili  $t$  będzie można wyrazić w następujący sposób:

$$Y^P(t) = Y^{sr} + \sum_{i=1}^{\frac{n}{2}} \left[ a_i \sin\left(\frac{2\pi}{n} it\right) + b_i \cos\left(\frac{2\pi}{n} it\right) \right] + Y(t)^{(ARIMA)} + Y(t)^{(ANN)} \quad (78)$$

We wzorze (78) pierwsze dwa składniki sumy stanowią odpowiednio wartość przeciętną popytu w szeregu czasowym oraz składową cykliczną pochodzącą z modelu spektralnego. Kolejne dwa składniki  $Y(t)^{(ARIMA)}$  oraz  $Y(t)^{(ANN)}$  pochodzą odpowiednio ze składowej modelu ARIMA oraz sztucznej sieci neuronowej. Poprzez takie wyrażenie zmiennej prognozowania model może uwzględnić występujące w popycie okresowości, zależności liniowe pomiędzy wartościami opóźnionymi w czasie a także trudne do opisanego przez modele analityczne wzorce i zależności nieliniowe. Najważniejsze etapy budowy prognozy popytu w ramach przedstawianego modułu predykcji obrazuje schemat rys. 22.



**Rys. 22.** Najważniejsze etapy budowy prognozy popytu  
*Źródło: opracowanie własne*

#### 4.2.2 Struktura i funkcjonalność modułu wnioskowania rozmytego

Drugim elementem prezentowanego w niniejszej rozprawie podejścia jest moduł wnioskowania rozmytego. Odpowiada on za przetworzenie wpływających do niego informacji wejściowych w optymalne wartości norm sterowania na wyjściu w dowolnej chwili czasu  $t$  w oparciu o wykorzystanie techniki rozumowania rozmytego typu Mamdaniego oraz algorytmu genetycznego. Parametry wejściowe modułu stanowią aktualnie zaobserwowane wartości popytu na produkt w danym dniu, ilość zapasu produktu w odpowiadających mu jednostkach, informacje o czasach dostawy oraz parametr opisujący jakość dostawy (ewentualne braki w towarze, uszkodzenia, pomniejszoną dostawę ze względu na ograniczoną dostępność produktu u dostawcy itp.) Elementami wyjściowymi modułu są optymalne wartości wielkości dostawy oraz punktu ponownego zamawiania wyznaczane na



bieżący w trakcie analizowanego okresu planistycznego. Idea działania modułu, wraz z opisem niezbędnych parametrów została przedstawiona w kolejnych podrozdziałach.

#### 4.2.2.1 Istota rozumowania rozmytego i zbiorów rozmytych

Działanie systemów wnioskowania rozmytego jest oparte o wykorzystanie teorii logiki i zbiorów rozmytych. Zazwyczaj precyzyjny opis danych zjawisk gospodarczych, procesów zachodzących dynamicznie w otoczeniu oddziaływania czynników niepewnych, jest utrudniony. Rozwiązaniem jest wykorzystanie zalet teorii zbiorów rozmytych oraz technik wnioskowania rozmytego, dzięki czemu w efektywny sposób można radzić sobie z niepewnością, nieprecyzyjnością, wieloznacznością informacji o parametrach procesów. Logika rozmyta stanowi przykład logiki wielowartościowej. Ściśle powiązana z teorią zbiorów rozmytych została przedstawiona przez L. Zadeha. W przeciwieństwie do logiki klasycznej, teoria logiki rozmytej zakłada iż pomiędzy stanem fałsz „0” a stanem prawda „1” może wystąpić nieskończenie wiele wartości pośrednich. To oznacza, iż pewien element danego zbioru może należeć do niego tylko w pewnym stopniu. Na potrzeby niniejszej pracy przywołano definicje wybranych niezbędnych pojęć do opisu funkcjonowania modułu wnioskowania rozmytego w proponowanej metodzie sterowania zapasami.

##### *Definicja 1.*

Zbiorem rozmytym  $A$  w pewnej niepustej przestrzeni  $X$  nazywamy zbiór par:

$$A = \{(x, \mu_A(x)) : x \in X\}$$

gdzie:

$$\mu_A: X \rightarrow [0,1]$$

jest nazywana funkcją przynależności zbioru rozmytego  $A$ . Odwzorowanie to każdemu elementowi  $x \in X$  przyporządkowuje jego stopień przynależności do zbioru rozmytego  $A$ . Można wyróżnić następujące przypadki:

$\mu_A(x) = 1$  w sytuacji gdy mamy do czynienia z pełną przynależnością elementu  $x$  do zbioru rozmytego  $A$  ( $x \in A$ ).

$\mu_A(x) = 0$  gdy brak jest przynależności elementu  $x$  do zbioru rozmytego  $A$  ( $x \notin A$ ).

$0 < \mu_A(x) < 1$  w sytuacji gdy mamy do czynienia z częściową przynależnością elementu  $x$  do zbioru rozmytego  $A$ .

Powszechnie można rozróżnić wiele typów funkcji przynależności o różnym kształcie między innymi typu gaussowskiego, sigmoidalne, trójkątne, trapezowe, prostokątne itp.

**Definicja 2.**

Zbiór rozmyty  $A$  zawiera się w zbiorze rozmytym  $B$  co jest zapisywane jako  $A \subset B$  wtedy i tylko wtedy gdy  $\mu_A(x) \leq \mu_B(x) \forall x \in X$

**Definicja 3.**

$\alpha$  - Przekrojem zbioru rozmytego  $A \subseteq X$  oznaczanym jako  $A_\alpha$  nazywany jest zbiór nie rozmyty taki że  $A_\alpha = \{x \in X: \mu_A(x) \geq \alpha \forall \alpha \in [0,1]$

Na zbiorach rozmytych tak jak przypadku ujęcia klasycznego można dokonywać szeregu operacji w postaci sumy, iloczynu itp. Poniżej zostaną przywołane z literatury wybrane definicje tych operacji, które są niezbędne do opisu mechanizmu egzekwowania wiedzy przez moduł wnioskujący. Szersze informacje dotyczące zbiorów rozmytych są zawarte w [118]

**Definicja 4.**

Przecięciem zbiorów rozmytych  $A, B \subseteq X$  jest zbiór rozmyty  $A \cap B$  z funkcją przynależności postaci:  $\mu_{A \cap B} = \min(\mu_A(x), \mu_B(x)) \forall x \in X$

**Definicja 5.**

Iloczynem algebraicznym zbiorów rozmytych  $A$  i  $B$  jest zbiór rozmyty  $C = A \cdot B$  opisany w następujący sposób:  $C = \{(x, \mu_A(x) \cdot \mu_B(x)) \forall x \in X\}$

**Definicja 6.**

Sumą zbiorów rozmytych  $A$  i  $B$  jest zbiór rozmyty  $A \cup B$  określony przez funkcję przynależności:  $\mu_{A \cup B}(x) = \max(\mu_A(x), \mu_B(x)) \forall x \in X$ . Dla zbiorów rozmytych  $A_1, A_2, \dots, A_n$  ich suma jest wyrażona jako:  $\mu_{A_1 \cup A_2 \cup \dots \cup A_n}(x) = \max(\mu_{A_1}(x), \mu_{A_2}(x), \dots, \mu_{A_n}(x)) \forall x \in X$

**Definicja 7.**

Dopełnieniem zbioru rozmytego  $A \subseteq X$  jest zbiór rozmyty  $\hat{A}$  którego funkcja przynależności przybiera postać:  $\mu_{\hat{A}}(x) = 1 - \mu_A(x) \forall x \in X$

**Definicja 8.**

Iloczyn kartezjański zbiorów  $A \subseteq X$  i  $B \subseteq Y$  oznaczany jest jako  $A \times B$  i oznaczany w następujący sposób:  $\mu_{A \times B}(x, y) = \min(\mu_A(x), \mu_B(y))$

**Definicja 9.**

Relacją rozmytą  $R$  między dwoma niepustymi zbiorami (nierozmytymi)  $X$  i  $Y$  nazywamy zbiór rozmyty określony na iloczynie kartezjańskim  $X \times Y$  to jest  $R \subseteq X \times Y = \{(x, y) : x \in X, y \in Y\}$ . Innymi słowy relacja rozmyta jest zbiorem par  $R = \{(x, y), \mu_R(x, y)\} \forall x \in X, \forall y \in Y$

gdzie:

$\mu_R: X \times Y \rightarrow [0,1]$  jest funkcją przynależności. Przypisuje ona dla każdej pary  $(x, y)$  jej stopień przynależności  $\mu_R(x, y)$ , który jest interpretowany jako siła powiązania między elementami  $x$  i  $y$ .

Przywołane definicje sumy czy też iloczynu zbiorów rozmytych nie są jedynymi ponieważ w literaturze funkcjonują również nieco inne definicje znane jako T- normy oraz S – normy. Innym ważnym pojęciem niezbędnym do opisu systemów rozmytych jest zmienna lingwistyczna czyli wielkość wejściowa bądź wyjściowa systemu rozmytego, która jest oceniana przy pomocy wartości lingwistycznych (*duży popyt, długi czas realizacji zamówienia itp.*)

Idea proponowanego w pracy podejścia zakłada opisanie niepewności wejściowych i wyjściowych parametrów systemu poprzez zbiory rozmyte. Jednakże kluczowym elementem modułu wnioskowania rozmytego jest informacja o zachowaniu się systemu w określonych warunkach wejściowych (parametry wejściowe). Informacja ta zgromadzona jest w postaci wiedzy zawartej w regułach rozmytych. Dla przykładu uogólnioną rozmytą regułę wnioskowania *modus tollens* można określić w następujący sposób:

Przesłanka	$y$ jest $B'$
Implikacja	<b>JEŻELI</b> $x$ jest $A$ <b>TO</b> $y$ jest $B$
Wniosek	$x$ jest $A'$

Gdzie:  $A, A' \subseteq X$  oraz  $B, B' \subseteq Y$  są zbiorami rozmytymi, natomiast  $x$  i  $y$  są zmiennymi lingwistycznymi.

Wniosek, który płynie z powyższej reguły rozmytej odnosi się do pewnego zbioru rozmytego  $A'$ , i jest określany jako złożenie zbioru rozmytego  $B'$  i rozmytej implikacji  $A \rightarrow B$ , gdzie  $A' = (A \rightarrow B) \circ B'$

W sytuacji kiedy wykorzystywany jest operator T- normy typu min to zbiór rozmyty  $A'$  można przedstawić jako:

$$\mu_{A'}(x) = \sup_{y \in Y} \{\min(\mu_{A \rightarrow B}(x, y), \mu_{B'}(y))\} \quad (79)$$

Podobne rozumowanie można przeprowadzić dla uogólnionej reguły rozmytej typu *modus ponens*. Funkcje przynależności we wnioskach schematów rozumowania *modus tollens* czy to *modus ponens* są uzależnione od funkcji przynależności  $\mu_{A \rightarrow B}(x, y)$  rozmytej implikacji

$A \rightarrow B$ , która jest równoważna realacji rozmytej  $R \subseteq X \times Y$ . W przypadku modelu wnioskowania typu Mamdaniego, który wykorzystywany jest w niniejszej metodzie sterowania zapasami funkcja  $\mu_{A \rightarrow B}(x, y)$  jest określana na podstawie danych funkcji  $\mu_A(x), \mu_B(y)$  najczęściej za pomocą reguły typu minimum określonej poniżej:

$$\mu_{A \rightarrow B}(x, y) = \mu_R(x, y) = \mu_A(x) \wedge \mu_B(y) = \min\{\mu_A(x), \mu_B(y)\} \quad (80)$$

#### 4.2.2.2 Budowa i dobór parametrów modułu wnioskowania rozmytego

Jedną z głównych zalet wykorzystania teorii zbiorów rozmytych w sterowaniu różnymi procesami w tym sterowaniu zapasami jest brak wymagania na temat znajomości dokładnych modeli analitycznych tychże procesów. Sterowanie zatem sprowadzone jest do sformułowania zbioru reguł i instrukcji postępowania typu JEŻELI... TO, które odzwierciedlają pewną wiedzę o procesie.

##### Definicja 10.

Bazą reguł nazywany jest zbiór reguł rozmytych  $R^{(k)}$  dla  $k = 1 \dots N$  postaci:

$R^{(k)}$ : **Jeżeli**  $x_1$  jest  $A_1^k$  **I**  $x_2$  jest  $A_2^k$  **I** ... **I**  $x_n$  jest  $A_n^k$  **to**  $y_1$  jest  $B_1^k$  **I**  $y_2$  jest  $B_2^k$  **I** ... **I**  $y_m$  jest  $B_m^k$   
gdzie:

$N$  – to liczba rozmytych reguł

$A_i^k$  - to zbiory rozmyte takie że  $A_i^k \subseteq X_i \subset R$ ,  $i = 1, \dots, n$

$B_j^k$  - to zbiory rozmyte takie że  $B_j^k \subseteq Y_j \subset R$ ,  $j = 1, \dots, m$

$x_1, x_2, \dots, x_n$  - to zmienne wejściowe modułu oraz  $[x_1, x_2, \dots, x_n]^T = x \in X_1 \times X_2 \times \dots \times X_n$

$y_1, y_2, \dots, y_m$  - to zmienne wyjściowe modelu oraz  $[y_1, y_2, \dots, y_m]^T = y \in Y_1 \times Y_2 \times \dots \times Y_m$

$X_i, i = 1 \dots n$  oraz  $Y_j, j = 1 \dots m$  stanowią odpowiednio przestrzenie zmiennych wejściowych i wyjściowych.

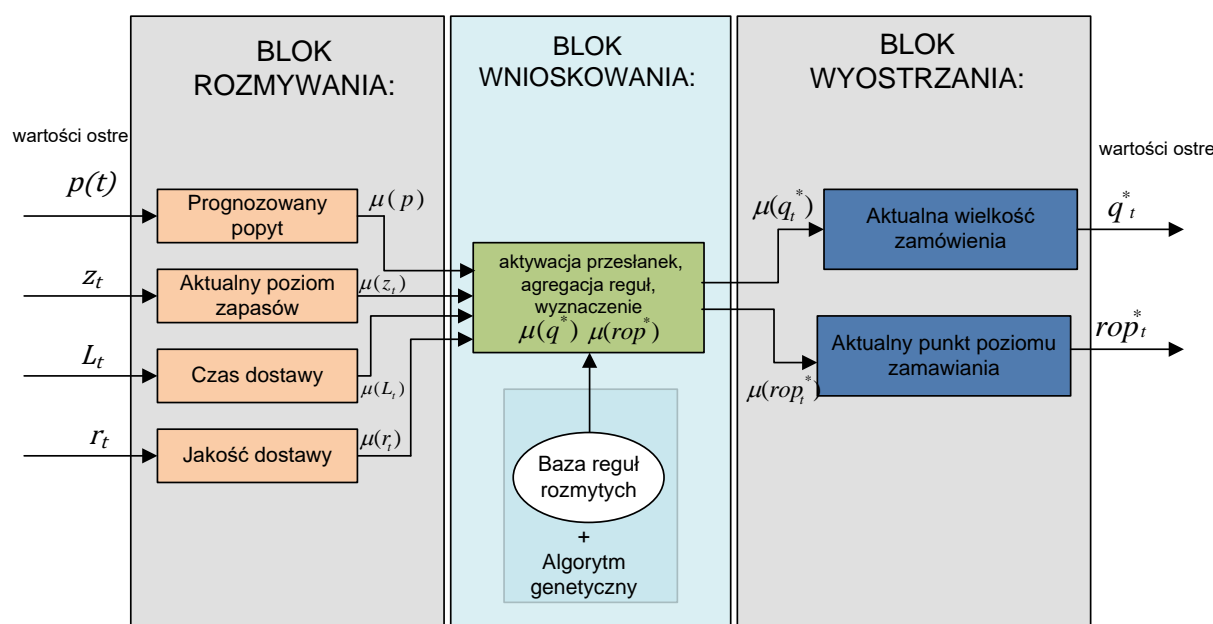
Każda reguła zatem składa się z poprzednika, który zawiera zbiór warunków oraz następnika zawierającego wniosek. Wykorzystując dotychczasowe rozumowanie każdą regułą  $R^{(k)}$  można przedstawić jako rozmytą implikację o postaci  $R^{(k)} : A^k \rightarrow B^k$ ,  $k = 1, \dots, N$

W związku z tym każda z reguł stanowi relację rozmytą (Definicja 9.), określoną na rozmytym iloczynie kartezjańskim zbiorów  $X \times Y$  (Definicja 8.), która jest zbiorem rozmytym o funkcji przynależności postaci:

$$\mu_{R^k}(x, y) = \mu_{A^k \rightarrow B^k}(x, y) \quad (81)$$

Przeprowadzone powyższe rozumowanie w dalszej kolejności pozwoli na dokładniejsze wyjaśnienie działania całego modułu. Rozważany moduł rozumowania rozmytego klasycznie składa się z czterech elementów: wspomnianej wyżej bazy reguł, bloku rozmywania,

wnioskowania oraz wyostrzania. Jego strukturę dla rozwiązywanego w pracy problemu sterowania poziomem zapasów przedstawia poniższy schemat rys. 23.



**Rys. 23.** Struktura modułu rozumowania rozmytego dla rozważanego problemu zapasów  
Źródło: opracowanie własne

Na podstawie tak skonstruowanej struktury modułu można zdefiniować wszystkie zmienne zarówno wejściowe jak i wyjściowe jako zmienne lingwistyczne należące do zbioru  $Z_L$ , określone na pewnym zbiorze wartości lingwistycznych  $W_L$  odpowiednio:

$$Z_L = \left\{ \begin{array}{l} \text{prognozowany popyt, akt. poziom zapasów, czas dostawy,} \\ \text{jakość dostawy, akt. wielkość dostawy, akt. pkt. zamawiania} \end{array} \right\}$$

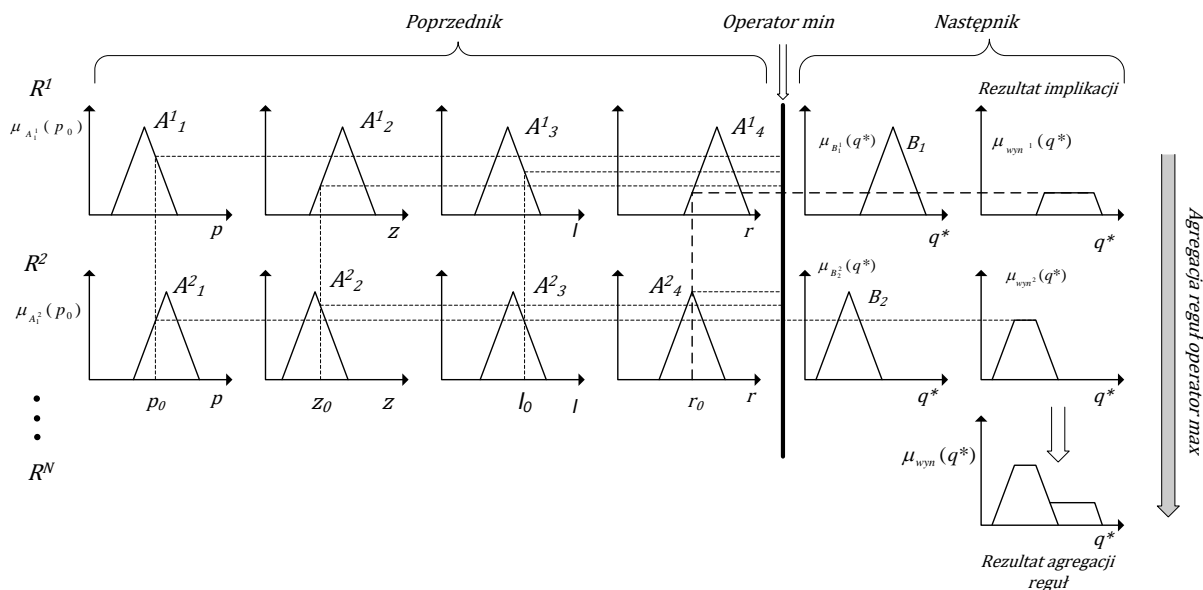
$$W_L = \{ \text{mały, duży, średni, krótki, długi} \}$$

Ostre wartości zmiennych wejściowych w postaci prognozowanego popytu  $p(t)$ , aktualnego poziomu dostępnych zapasów  $z_t$ , parametru opisującego czas dostawy  $L_t$  oraz jakości dostawy  $r_t$  (która może opisywać stopień dostępności towaru u dostawcy) podawane są na blok rozmywania, gdzie wyznaczane są dla nich stopnie przynależności do zbiorów rozmytych. Zbiory te są przypisane dla każdej z ocen lingwistycznych. W dalszej kolejności w bloku wnioskowania wyznaczane są stopnie aktywacji przesłanek zawartych w regułach rozmytych oraz wartości implikacji rozmytych przy użyciu operatora *min*. Następnie w toku agregacji wszystkich reguł zawartych w bazie za pomocą operatora typu *max* wyznaczana jest funkcja przynależności opisująca zmienne wyjściowe. Sposób ten dla dwóch zmiennych wyjściowych można przedstawić za pomocą poniższych wzorów:

$$\mu_{wyn}(q_t^*) = \max_{k=1,2,\dots,N} \left\{ \min(\mu_{A_i^k}(p), \mu_{A_i^k}(z), \mu_{A_i^k}(l), \mu_{A_i^k}(r), \mu_{B_j^k}(q^*)) \right\} \quad (82)$$

$$\mu_{wyn}(rop_t^*) = \max_{k=1,2,\dots,N} \left\{ \min(\mu_{A_i^k}(p), \mu_{A_i^k}(z), \mu_{A_i^k}(l), \mu_{A_i^k}(r), \mu_{B_j^k}(rop^*)) \right\} \quad (83)$$

Bardziej obrazowy sposób wyznaczania wynikowego zbioru rozmytego dla zadanego wektora wejściowego  $[p_0, z_0, l_0, r_0]$  jest przedstawiony na rys. 24



**Rys. 24.** Przyjęty schemat wnioskowania w modelu rozmytego

Źródło: opracowanie własne

Schemat na rys. 24 przedstawia proces rozumowania rozmytego na podstawie zgromadzonej wiedzy w regułach rozmytych w odniesieniu do podejmowanego w pracy problemu zapasów dla zmiennej wyjściowej systemu  $q_t^*$  (wielkość dostawy). Dobór operatora w procesie inferencji zależy od specyfiki rozwiązywanego problemu i jest wybierany ten który daje lepsze rezultaty. Jednakże do agregacji reguł najczęściej używany jest operator typu *max* lub *sum*. Mają one tę zaletę, że podczas wyznaczania wynikowej funkcji przynależności dla zmiennej wyjściowej uwzględniają składowe pochodzące z wszystkich reguł [107]. Oprócz zmiennej  $q_t^*$  w podobny sposób jest wyznaczana również druga norma sterowania jaką jest aktualny punkt ponownego zamawiania  $rop_t^*$ . Końcowym elementem całego procesu rozumowania jest przekształcenie wyjściowego sygnału z dziedziny rozmytej do ilościowej poprzez operację wyostrzania. Powszechnie rozróżnianych jest wiele metod wyostrzania takich jak: metoda środka maksimum, metoda pierwszego maksimum, metoda ostatniego maksimum, metoda środka ciężkości, metoda wysokości. W proponowanym podejściu została przyjęta metoda środka ciężkości jako sposób wyznaczania wartości ostrych. Jej podstawową zaletą jest że wszystkie aktywne reguły biorą udział w wyostrzaniu, przez co model jest bardziej czuły na zmiany wejść do modelu. Wadą metody jest jednakże

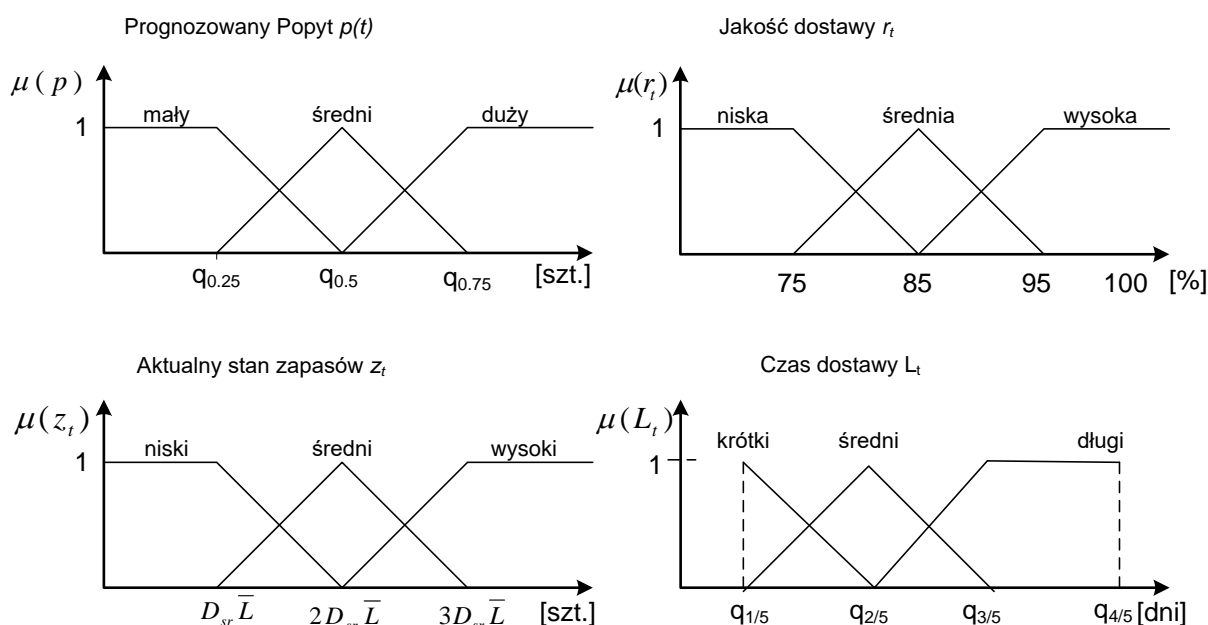


zwiększony nakład obliczeniowy. Formułę wyznaczającą ostrą wynikową wartość zmiennej wyjściowej przy użyciu metody środka ciężkości przedstawia poniższy wzór:

$$q_t^* = \frac{\int q^* \mu_{wyn}(q^*) dq^*}{\int \mu_{wyn}(q^*) dq^*} \quad (84)$$

Całkowanie jest przeprowadzane w granicach określonych zbiorem wynikowym. Jedną z wad pozostałych metod jest uwzględnianie w procesie wyostrzania tylko najbardziej zaktywizowanych reguł. Metody te są szerzej przedstawione w [116, 150].

Ważnym elementem w proponowanym podejściu jest odpowiedni opis wykorzystywanych zmiennych wejściowych poprzez zbiory rozmyte, określone za pomocą funkcji przynależności o odpowiednich parametrach. Sposób opisu wejść systemu przedstawia rys. 25.



Gdzie:

$q_{1/5}, \dots, q_{4/5}$  – kwintyle rzędów I, II, III, IV, V

$q_{0.25}, q_{0.5}, q_{0.75}$  – kwartyle rzędów I, II, III

$\bar{D}_{sr}$  – średni popyt w rozpatrywanym okresie

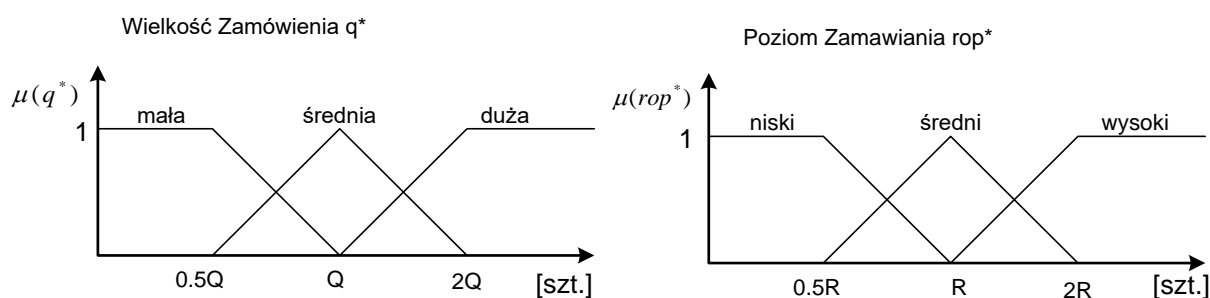
$\bar{L}$  – średni czas realizacji dostawy w rozpatrywanym okresie planistycznym  $T_p$

**Rys. 25.** Parametry wejściowe systemu opisane przy pomocy zbiorów rozmytych

Źródło: opracowanie własne

Wykorzystane zbiory rozmyte są opisane przez zaproponowane trójkątne oraz trapezowe funkcje przynależności. Punkty charakterystyczne na poziomych osiach wykresów są wyznaczane w oparciu o historyczne obserwacje danej zmiennej w ustalonym horyzoncie czasowym. W przypadku jednego z wejściowych parametrów niepewnych jakim jest jakość

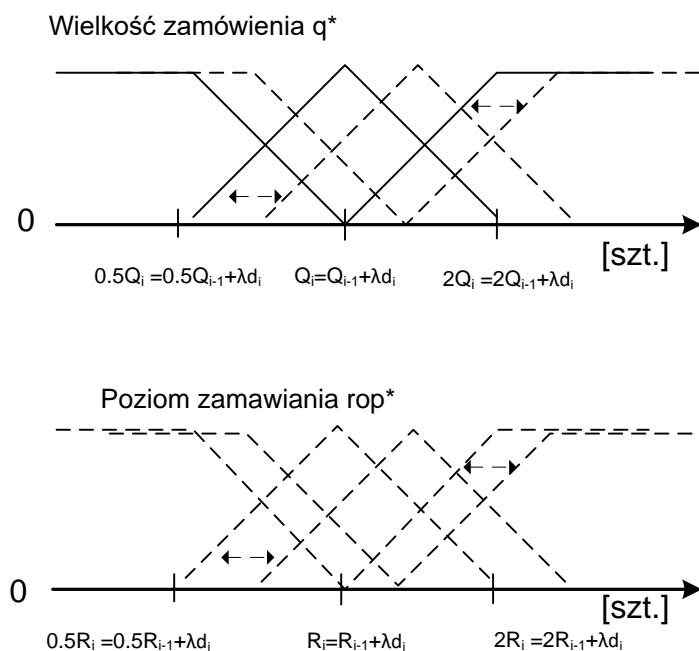
dostawy  $r_t$  jego opis przy pomocy zbiorów rozmytych rozumiany jako procentowa ilościowa zgodność zgłoszonego zamówienia z otrzymaną dostawą. W sytuacji kiedy dostawca w określonym momencie nie dysponuje wymaganą wielkością towaru na jaką zostało złożone zamówienie bądź zaistniały inne okoliczności, nadchodząca wielkość dostawy w rozważanym punkcie składowana zostanie pomniejszona o odpowiednią wartość na podstawie parametru  $r_t$ . Na podobnej zasadzie jak zmienne wejściowe opisane zostały parametry wyjściowe systemu przedstawione na rys.26



**Rys. 26.** Parametry wyjściowe systemu opisane przy pomocy zbiorów rozmytych

*Źródło: opracowanie własne*

Punkty charakterystyczne na osi poziomej zostały wyznaczone na podstawie przytoczonych w rozdziale 2 wzorów (11) i (13). Proponowane w pracy podejście stanowi przykład ciągłego systemu monitorowania i sterowania zapasami. Dla przyjętego odstępu czasowego np. jeden dzień zmienne wejściowe i wyjściowe są aktualizowane. Stąd wyznaczone punkty charakterystyczne w przestrzeni rozmytej dla zmiennych wyjściowych są jedynie wartościami początkowymi w symulacji całego rozpatrywanego okresu planistycznego. W każdym kolejnym jednodniowym odstępie czasu parametry funkcji przynależności opisujące wyjścia z systemu są modyfikowane w oparciu o wyznaczony błąd prognozy popytu rys. 27. Dzięki temu system ma większą zdolność do adaptacji i inteligentnej identyfikacji sytuacji nietypowych, zmieniających się trendów.



Gdzie:

$\lambda_{d_i}$  – błąd prognozy popytu w  $i$ -tym okresie czasu

$i=1\dots$ ;  $T_P$  – rozpatrywany planistyczny okres czasu

**Rys. 27.** Sposób aktualizacji parametrów funkcji przynależności dla zmiennych wyjściowych systemu

*Źródło: opracowanie własne*

#### 4.2.2.3 Wielokryterialna optymalizacja bazy reguł rozmytych modułu wnioskowania z wykorzystaniem algorytmu genetycznego

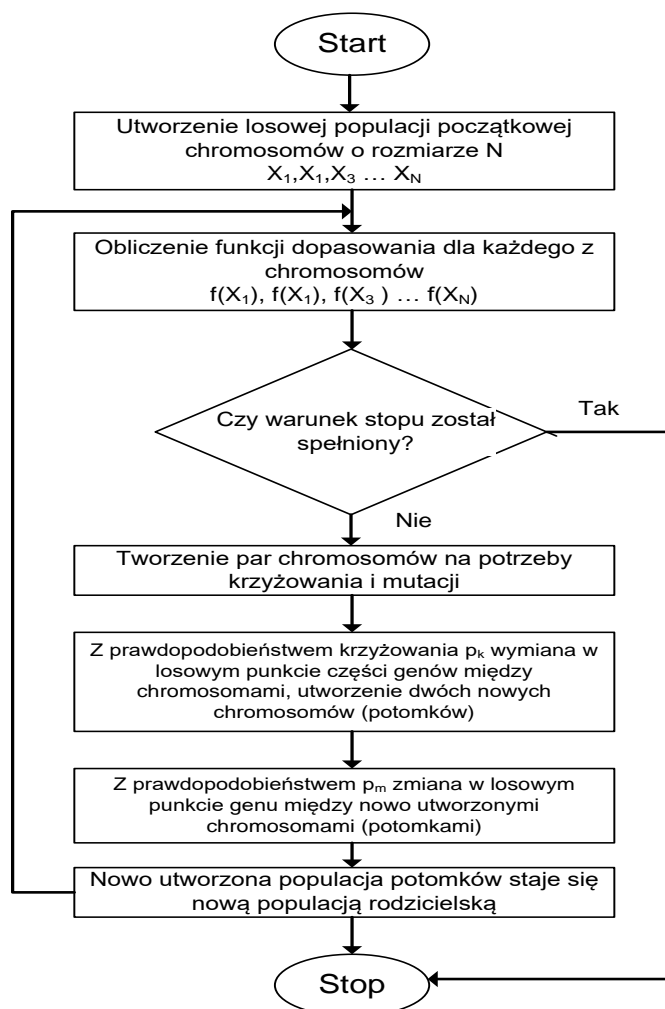
Baza reguł stanowi kluczowy element całego modułu rozmytego, determinując efektywność jego działania. Zawiera ona główną część wiedzy o modelowanym problemie, stanowiąc w dużej mierze o „inteligencji” proponowanej metody. Zatem właściwe zaprojektowanie tego elementu jest bardzo istotne. Tworzenie bazy reguł może sprawiać jednak trochę kłopotów. Duża liczba parametrów wejściowych/wyjściowych, zbiorów rozmytych co prawda sprawia, że rośnie potencjalna możliwa zdolność modelu do dokładnego odwzorowania procesu bądź systemu rzeczywistego, lecz tym samym wzrasta liczba reguł w bazie. Dodatkowo powstaje trudność właściwego rozpoznania zależności pomiędzy przesłankami a konkluzjami w regułach, tak aby przykładowo uniknąć problemu wykluczania się pewnych reguł. Zatem związek między liczbą zmiennych, liczbą opisujących je zbiorów rozmytych a liczbą reguł wzrasta wykładniczo. W rozpatrywanym problemie sterowania poziomem zapasów dla czterech zmiennych wejściowych, dwóch wyjściowych, każdą opisaną przez trzy zbiory rozmyte, liczba wszystkich możliwych reguł do utworzenia przedstawia się następująco:

$$\begin{array}{cc} \text{Ilość możliwości} & \text{Ilość możliwości} \\ \text{w poprzedniku} & \text{w następniku} \end{array}$$

$$\text{Liczba możliwych reguł: } 3 \times 3 \times 3 \times 3 \times 3 \times 3 = 729$$

Opisanie wiedzy o zachowaniu systemu przy użyciu takiej liczby reguł z zagwarantowaniem cechy spójności, braku wykluczania się reguł zawartych w bazie jest zadaniem trudnym. W takich przypadkach wiedza ekspercka co do tworzenia bazy reguł może okazać się niewystarczająca. W związku z tym w proponowanym w niniejszej rozprawie podejściu wykorzystany zostanie algorytm genetyczny do optymalizacji bazy reguł rozmytych.

Algorytmy genetyczne stanowią przykład algorytmów mających na celu poszukiwanie optymalnych rozwiązań, sztucznych stworzonych przez człowieka problemów optymalizacyjnych. W swoim działaniu bazują one na mechanizmach doboru naturalnego oraz procesie dziedziczności. Łączą w sobie ewolucyjną zasadę przeżycia najlepiej przystosowanych osobników (rozwiązań problemu decyzyjnego). Rozpatrując pewien zbiór rozwiązań problemu decyzyjnego można go bowiem w pewien sposób porównać do populacji organizmów. Dla każdego z rozwiązań (osobnika) można przypisać mu jego indywidualne cechy przystosowania do postawionych warunków (funkcja kryterialna mierząca jakość danego rozwiązania). Dzięki temu można symulować procesy ewolucyjne reprodukcją w kolejnych „pokoleniach” lepsze spośród rozwiązań, natomiast eliminując te które gorzej spełniają postawione kryteria problemu optymalizacyjnego. Operacja ta dokonywana jest w oparciu o reprodukcję kodu genetycznego a ściślej o możliwość zestawiania ze sobą (na wzór krzyżowania) idei cząstkowych pochodzących z różnych rozwiązań, dzięki temu otrzymując innowacyjne, lepsze rozwiązania postawionego problemu. W praktyce wymaga to przyjęcia sposobu przekształcania konkretnego rozwiązania w jednoznacznie reprezentujący go ciąg kodowy nazywany często chromosomem. W ten sposób na tak zdefiniowanych ciągach kodowych (populacji rozwiązań) można dokonywać przetwarzania np. operacji krzyżowania, mutacji otrzymując nowe lepiej przystosowane rozwiązania [55]. W algorytmach genetycznych kandydujące rozwiązania problemu są reprezentowane zazwyczaj jako ciągi binarne. W każdej iteracji nowa populacja rozwiązań jest generowana losowo w oparciu o wartość funkcji dopasowania dla każdego pojedynczego osobnika (rozwiązania). W każdej generacji aktualne rozwiązania są dobierane parami i ich kod genetyczny jest modyfikowany poprzez operator krzyżowania i możliwą losową mutację czyli zamianę jednego bitu z wartości 0 na 1 lub odwrotnie. Powstałe w ten sposób nowe rozwiązania stanowią populację rodzicielską w kolejnej iteracji. Powtarzająca się procedura jest wykonywana do momentu osiągnięcia jednego z przyjętych kryteriów zatrzymania (przykładowo do osiągnięcia zadowalającego poziomu funkcji dopasowania, braku istotnej poprawy rozwiązania w kolejnych iteracjach bądź po upływie ich zadanej liczby iteracji itp.) Kolejne podstawowe etapy klasycznego algorytmu genetycznego przedstawia schemat na rys.28.



Rys. 28. Podstawowy schemat działania algorytmu genetycznego

Źródło: opracowanie własne na podstawie [55]

W odniesieniu do rozwiązywanego w pracy problemu zastosowanie algorytmu genetycznego w optymalizacji bazy reguł jest następujące:

Na wstępie przyjęto założenie, że każdej regule ze zbioru możliwych do utworzenia zostanie przypisana pewna waga  $w_i^R$ . Dzięki temu reguły z wyższą wagą mają większy wpływ na wyznaczanie wartości zmiennych wyjściowych. Zmienną decyzyjną w procesie optymalizacji stanowić będzie zatem wektor  $W^R$ , taki że:


$$W^R = [w_1^R, w_2^R, \dots, w_{k_R}^R] \quad (85)$$

gdzie:

$k_R$  – to liczba możliwych do zbudowania reguł,

$$w_1^R, w_2^R, \dots, w_{k_R}^R \in R_+ \cup \{0\},$$

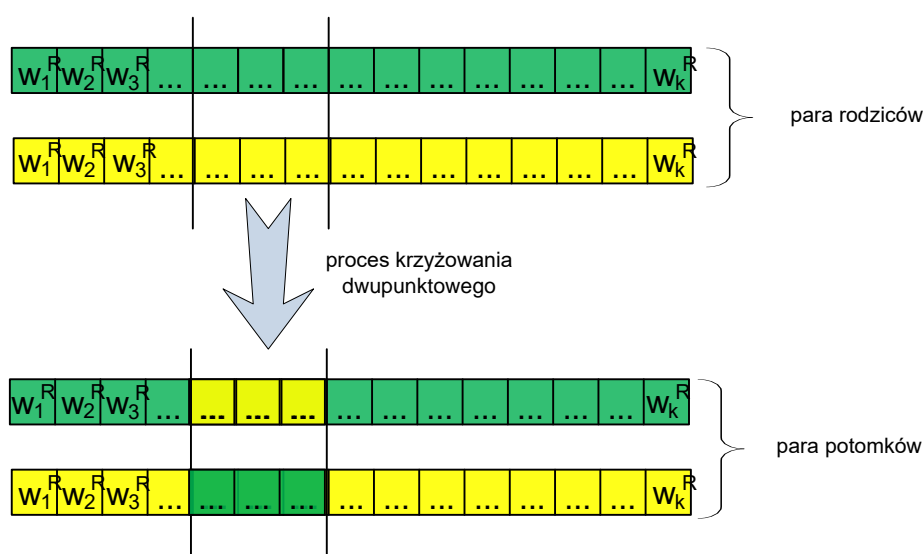
Zatem struktura pojedynczego chromosomu może być przedstawiona w sposób zaprezentowany na rys.29.



Rys. 29. Przykład struktury chromosomu

Źródło: opracowanie własne

W zastosowanym algorytmie do tworzenia osobników dla kolejnych populacji rozwiązań wykorzystano dwupunktowy operator krzyżowania, w którym miejsca rozcięcia kodu chromosomu wybierane są w losowy sposób. Sposób działania tego operatora przedstawia poniższy schemat rys.30.



Rys. 30. Działanie dwupunktowego operatora krzyżowania

Źródło: opracowanie własne

Do selekcji rozwiązań dla kolejnych iteracji została wykorzystana metoda ruletkowa. Dokładne wartości parametrów algorytmu genetycznego zostaną przedstawione w następnym rozdziale przy okazji prezentacji wyników weryfikacji całego podejścia. Proces optymalizacji jest wykonywany w oparciu o minimalizację funkcji będącej ważoną sumą trzech kryteriów cząstkowych: średniego poziomu zapasów, liczby braków w zapasach oraz liczby dostaw dla ustalonego przedziału czasu, na podstawie zestawów danych uczących. Powyższy problem można przedstawić w następujący sposób:

$$F(W^R) = \varphi_1 \frac{f_1(W^R) - f_1^{**}}{f_1^* - f_1^{**}} + \varphi_2 \frac{f_2(W^R) - f_2^{**}}{f_2^* - f_2^{**}} + \varphi_3 \frac{f_3(W^R) - f_3^{**}}{f_3^* - f_3^{**}} \rightarrow \min \quad (86)$$

$$W^R \geq 0 \quad (87)$$



$$\sum_{i=1}^3 \varphi_i = 1 \quad (88)$$

gdzie:

$F(W^R)$  - funkcja kryterium zbiorczego,

$W^R$  - wektor wag dla zbioru reguł,

$f_1^*$ ,  $f_1^{**}$  - odpowiednio maksimum i minimum dla funkcji określającej przeciętny stan zapasów,

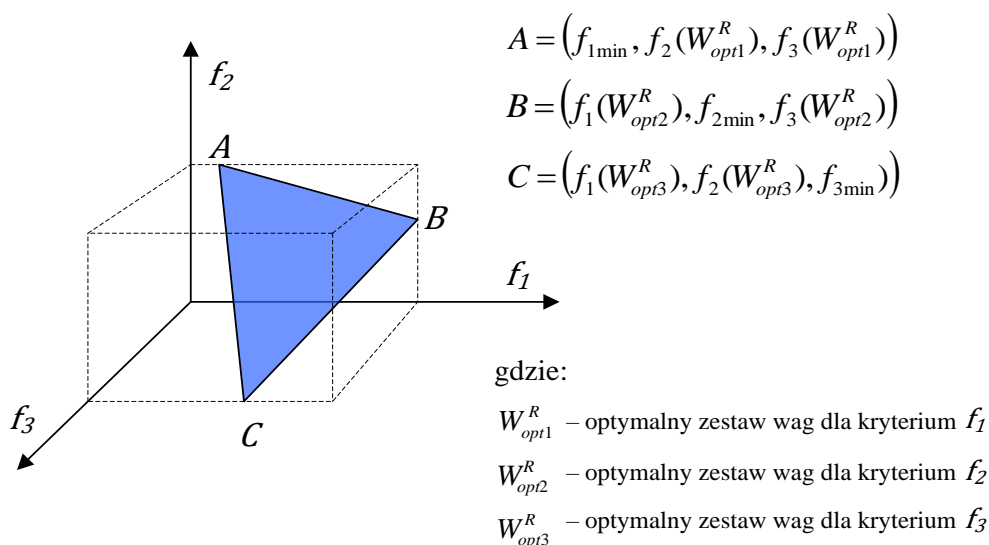
$f_2^*$ ,  $f_2^{**}$  - odpowiednio maksimum i minimum dla funkcji określającej liczbę braków zapasów,

$f_3^*$ ,  $f_3^{**}$  - odpowiednio maksimum i minimum dla funkcji określającej liczbę wymaganych dostaw,

$\varphi_1, \varphi_2, \varphi_3$  - wagi dla kryteriów cząstkowych,

W ten sposób reguły które w niewielkim stopniu wyjaśniają zachowanie całego systemu mają przypisaną niską wagę, dzięki temu możliwe jest również odchudzenie bazy reguł poprzez pozostawienie tylko tych z istotnymi wagami. W przypadku pojawiających się symptomów niewłaściwej odpowiedzi systemu na wartości sygnałów wejściowych (rosnący poziom zapasów, pojawiające się braki zapasu itp.) przeprowadzany jest ponowny proces optymalizacji reguł celem lepszego dopasowania ich do zmieniających się tendencji rozwojowych.

Uzasadnieniem wyboru metody skalaryzacji kryteriów i rozwiązania problemu jednokryterialnego jako kombinacji wypukłej kryteriów jest fakt, że zbiór kompromisów w sformułowanym problemie jest zwarty, więc suma ważona ma swoje uzasadnienie gdyż daje punkty z tego zbioru kompromisów, co gwarantuje znalezienie rozwiązania. Przedstawioną sytuację obrazuje schemat rys. 31.



**Rys. 31.** Ilustracja zbioru kompromisów w przestrzeni kryteriów

Źródło: opracowanie własne

### 4.3 MATEMATYCZNE SFORMUŁOWANIE ROZWAŻANEGO PROBLEMU ZAPASÓW

Aby przedstawić specyfikę podejmowanego w niniejszej rozprawie problemu optymalnego sterowania poziomem zapasów w warunkach niepewności, dokonano jego ogólnego formalnego sformułowania w sposób matematyczny w poniższy sposób:

**Przyjęte w problemie funkcje kryterialne:**

$$f_1 = \frac{1}{T_p} \sum_{t=1}^{T_p} z_t \rightarrow \min \quad (89)$$

$$f_2 = \sum_{t=1}^{T_p} Nb_t \rightarrow \min \quad (90)$$

$$f_3 = \sum_{t=1}^{T_p} ld_t \rightarrow \min \quad (91)$$

**Zbiór warunków ograniczających, wyznaczający zbiór rozwiązań dopuszczalnych problemu:**

$$d_t = q_t^* \cdot r_t \cdot 1(rop_t^* - z_t) \quad (92)$$

gdzie:

$1(\cdot)$  jest funkcją jednostkową Heaviside'a,

$$Nb_t = 1(lb_t) \quad (93)$$

$$lb_t = |z_t - p_t| \cdot 1(p_t - z_t) \quad (94)$$

$$ld_t = 1(d_t) \quad (95)$$

$$\tau_{tv} = 1(L_t + t - v) \quad (96)$$

$$z_t = z_0 + \sum_{t=1}^v (r_t \cdot \tau_{tv} \cdot d_t - p_t) \quad \bigwedge t \in [1 \dots T_p] \quad (97)$$

$$z_t \leq S_{max} \quad \bigwedge t \in [1 \dots T_p] \quad (98)$$

$$d_t \leq M \cdot U_t \quad \bigwedge t \in [1 \dots T_p] \quad (99)$$

$$d_t = q_t^* \cdot r_t \quad \bigwedge t \in [1 \dots T_p] \quad (100)$$

$$(U_t - 1) \cdot (rop_t^* - z_t + \varepsilon) \geq 0 \quad \bigwedge t \in [1 \dots T_p] \quad (101)$$

$$rop_t^* - z_t + \varepsilon \geq M \cdot (U_t - 1) \quad \bigwedge t \in [1 \dots T_p] \quad (102)$$

$$d_t \geq 0, \quad d_t \in C \quad (103)$$

$$d_t \leq d_{max} \quad d_{max} \in C \quad (104)$$

$$q_t^* \geq 0 \quad q_t^* \in C \quad (105)$$

$$rop_t^* \geq 0 \quad rop_t^* \in C \quad (106)$$

$$U_t \in \{1,0\} \quad (107)$$

#### Parametry niepewne rozważane w problemie:

$$r_t \in [r_{t \min}, r_{t \max}] \quad (108)$$

$$L_t \in [L_{t \min}, L_{t \max}] \quad (109)$$

$$p_t \in [p_{t \min}, p_{t \max}] \quad (110)$$

#### Przyjęte oznaczenia:

$S_{max}$  – maksymalny dopuszczalny poziom zapasu,

$p_t$  – wartość zapotrzebowania na produkt w okresie  $t$ ,

$z_t$  – ilość zapasu w okresie  $t$ ,

$z_0$  – początkowa ilość zapasu w chwili  $t=1$ ,

$rop_t^*$  – poziom zamawiania w chwili  $t$ ,

$q_t^*$  – wielkość zamówienia w chwili  $t$ ,

$d_t$  – wielkość dostawy w chwili  $t$ ,

$d_{max}$  – maksymalna wielkość pojedynczej dostawy,

$lb_t$  – wielkość braków zapasu w chwili  $t$ ,

$L_t$  – czas realizacji dostawy dla zamówienia złożonego w okresie  $t$ ,

$r_t$  – parametr określający stopień wypełnienia dostawy oraz opisujący ograniczoną dostępność produktu u dostawcy w chwili  $t$ ,  
 $\tau_{tv}$  – parametr związany z czasem realizacji dostawy,  
 $v$  – znacznik czasowy opisujący moment nadejścia dostawy,  
 $Nb_t$  – zmienna pomocnicza określająca czy zaistniał brak towaru w chwili  $t$ ,  
 $ld_t$  – zmienna pomocnicza określająca czy wystąpiła dostawa w chwili  $t$ ,  
 $T_p$  – rozpatrywana długość okresu planistycznego obejmująca jeden rok, liczona w dniach,  
 $U_t$  – zmienna pomocnicza,  
 $M$  – duża liczba naturalna,  
 $\varepsilon$  – bliska zeru dodatnia liczba rzeczywista,

Rozważany problem jest rozwiązywany dla przyjętego okresu planistycznego  $T_p$ . Optymalny harmonogram dostaw jest oceniany pod względem trzech kryteriów: funkcje  $f_1$ ,  $f_2$ ,  $f_3$ , optymalizują odpowiednio przeciętny poziom zapasu, liczbę braków zapasu, liczbę dostaw dla ustalonego okresu  $T_p$ . Formuły (93) – (96) definiują zmienne decyzyjne modelu. Równanie (97) opisuje stan zapasu w magazynie w okresie  $t$ . Nierówność (98) wskazuje na dopuszczalny maksymalny poziom zapasu. Ograniczenia (99) – (102) gwarantują zapewnienie sytuacji, w której zamówienie na  $q_t^*$  jednostek artykułu jest wystawiane kiedy  $z_t \leq rop_t^*$  oraz sytuacji kiedy nie są podejmowane żadne czynności kiedy  $z_t \geq rop_t^*$ . Oddziaływanie warunków niepewnych jest uwzględnione poprzez parametry  $r_t$ ,  $L_t$ ,  $p_t$ , które mogą przyjmować dowolne wartości ze zbiorów określonych przez (108) – (110). Przy tym dodatkowo przyjęto założenie, że rozkład prawdopodobieństwa tych parametrów nie jest znany. Wielokryterialny problem optymalizacji można sformułować następująco:

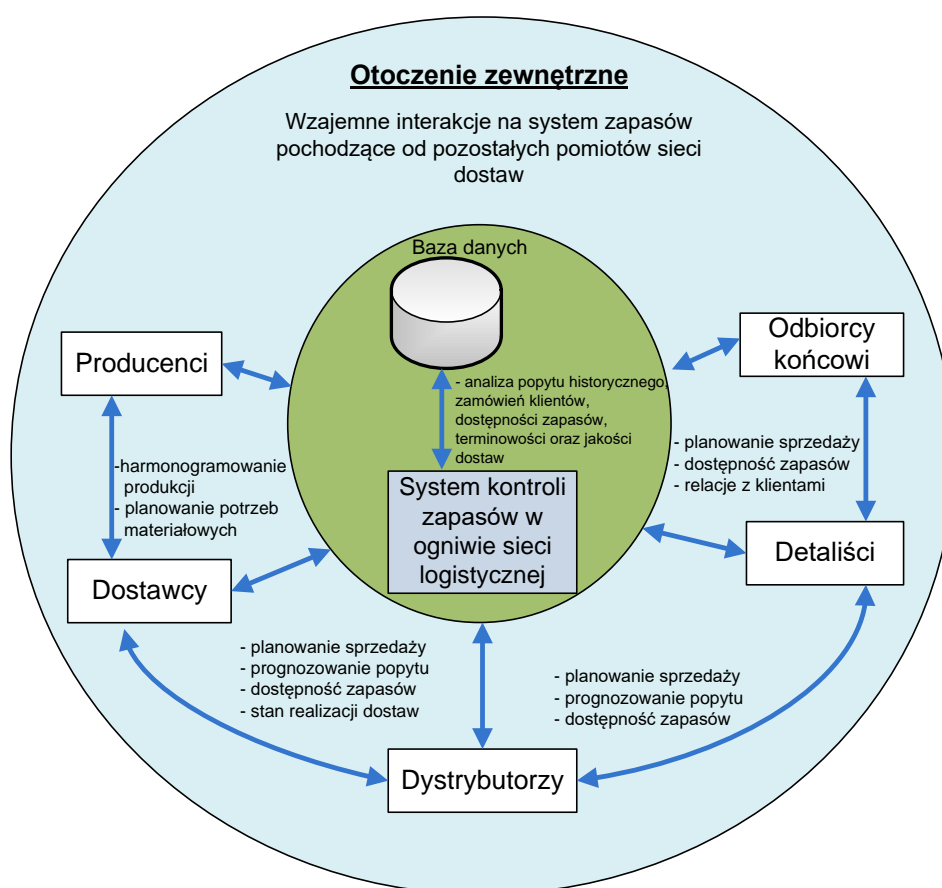
$$MOP_{min} \text{ zmienne decyzyjne z (92)-(95) } f = (f_1, f_2, f_3) \quad | \quad T_p \text{ - dany; (92) - (110)}$$

W przedstawionej formie problem ze względu na niepewność co do wartości wielu parametrów wejściowych jest dosyć trudny do rozwiązania za pomocą powszechnie znanych metod optymalizacji. Zatem zostanie on rozwiązany przy pomocy zaprezentowanej metody autora na przykładzie danych rzeczywistych w kolejnym rozdziale.

#### 4.4 PROBLEM STEROWANIA ZAPASAMI TOWARÓW W UJĘCIU SYSTEMOWYM

Rozważany w niniejszej pracy problem sterowania zapasami towarów w pojedynczym punkcie składowania nie stanowi wyizolowanego elementu, lecz jest poddawany różnym oddziaływaniom ze strony pozostałych podmiotów sieci logistycznej, co stanowi pewnego rodzaju otoczenie zewnętrzne. Zatem w celu zagwarantowania wymaganego poziomu korzyści oraz efektywności przedstawionej w pracy metodyki niezbędne jest spojrzenie na całość zagadnienia z szerszej perspektywy jako całego systemu. Według teorii istotą podejścia systemowego, które zaproponował po raz pierwszy L. von Bertalanffy jest traktowanie badanych obiektów jako zbiorów elementów powiązanych w taki sposób, że

tworzą one nową całość działającą w pewnym otoczeniu. Koncepcja ta opiera się na założeniu, że wszystkie działania w przedsiębiorstwie, zaangażowane w fizyczny przepływ i składowanie surowców, półproduktów oraz wyrobów gotowych, powinny być traktowane jako całość, a nie jako indywidualne części [72]. Istotnie bowiem na proces kontrolowania zasobów towarów w pojedynczym ogniwie na różnych poziomach sieci dostaw ma wpływ szereg elementów w postaci dostawców surowców, producentów, dystrybutorów, detalistów, przewoźników transportowych, odbiorców końcowych itp. a także szereg wykonywanych czynności, zadań i podprocesów. Wszystkie te składowe są ze sobą powiązane pewnymi interakcjami oraz relacjami wzajemnie na siebie oddziałując. Wielość tychże elementów, wielość powiązań, wysoki stopień dynamizmu, zmienna intensywność przepływów sprawiają, iż proces sterowania zasobami w ramach takiego systemu jest poddawany wielu oddziaływaniom losowym oraz zakłóceniom. Taka specyfika systemu sprawia, że utrudniony jest proces analizowania, modelowania, rozpoznawania stanu systemu zasobów oraz jego reakcji na zmiany wskutek działań sterujących i zarządzających. Przykładowe oddziaływania na system zasobów w pojedynczym ogniwie logistycznym pochodzące od pozostałych podmiotów sieci logistycznej przedstawia rys. 32.



**Rys. 32.** Przykładowe oddziaływania na system zasobów w ogniwie logistycznym

Źródło: opracowanie własne

Zaproponowane w pracy podejście do rozwiązania problemu sterowania poziomem zapasów w warunkach niepewności powinno funkcjonować w ramach inteligentnego zintegrowanego hierarchicznego systemu logistycznego HILS (*Hierarchical Intelligent Logistics System*), zapewniającego dostęp do określonych danych w czasie rzeczywistym, w którym za realizację pewnych zadań, czynności logistycznych i transportowych odpowiedzialne są dedykowane warstwy systemowe. Koncepcja ta wraz z pełnymi specyfikacjami jest szeroko przedstawiona w pracach [3,4,5]. Idea tego podejścia zakłada istnienie pięciu warstw powiązanych ze sobą, które mają na celu koordynowanie, nadzorowanie, optymalizowanie i sterowanie zadaniami, procesami logistycznymi i transportowymi zachodzącymi w danej sieci logistycznej w czasie rzeczywistym. Schemat na rys.33. przedstawia umiejscowienie rozwiązywanego problemu zapasów w strukturze hierarchicznej ILS. W ramach tej struktury funkcjonują hierarchicznie zestawione warstwy zarządzania i koordynacji, adaptacji, optymalizacji, nadzoru i monitoringu oraz sterowania. Każda z warstw realizuje pewne zadania w ramach problemu sterowania zapasami dla proponowanej metodyki rozwiązania problemu wymieniając ze sobą aktualne dane, informacje i wiedzę w oparciu dostępne bazy danych i bazy wiedzy.

#### **Warstwa zarządzania i koordynacji:**

W warstwie tej ma miejsce zarządzanie zamówieniami, nadchodzącymi dostawami. Na tym poziomie jest kreowana strategia przedsiębiorstwa w zakresie obsługi transportowo logistycznej oraz w aspekcie tworzenia, utrzymania zapasów. Następuje określanie sposobu współpracy i kooperacji pomiędzy pozostałymi uczestnikami sieci dostaw (nawiązywanie umów, kontraktów, optymalny wybór dostawców itp.). W warstwie tej tworzone są priorytety dla poziomu zapasów, określonych w toku analizy kluczowych produktów, poziomu obsługi kluczowych klientów. Odbywa się to poprzez wyznaczenie optymalnych preferencji dla kryteriów w sterowaniu zapasami dla konkretnych produktów z uwzględnieniem ograniczeń zapasu maksymalnego, ograniczeń kapitałowych, rachunku zysków i strat. Na tym poziomie odbywa się również identyfikacja istotnych strategicznych czynników niepewnych oddziałujących na system sterowania zapasami.

#### **Warstwa adaptacji:**

W warstwie tej następuje adaptacja systemu zapasów do aktualnie zachodzących warunków w środowisku operacyjnym sieci dostaw. Proces adaptacji odbywa się poprzez analizę zmieniających się wzorców zachowań klientów, zmieniających się trendów w popycie na poszczególne towary, surowce. Wskutek tego w warstwie tej dokonywany jest optymalny wybór rzędów modeli predykcji ARIMA, liczby składowych harmonicznych wykorzystywanych w składowej spektralnej modelu predykcji popytu, architektury dla sieci neuronowych oraz wybór właściwego horyzontu prognozowania w aktualnym momencie.

#### **Warstwa optymalizacji:**

W warstwie tej przeprowadzana jest wielokryterialna optymalizacja bazy wiedzy w postaci reguł, parametrów oraz liczby zbiorów rozmytych z wykorzystaniem GA dla rozmytego sterowania poziomem zapasów poszczególnych pozycji asortymentowych. Wyznaczanie



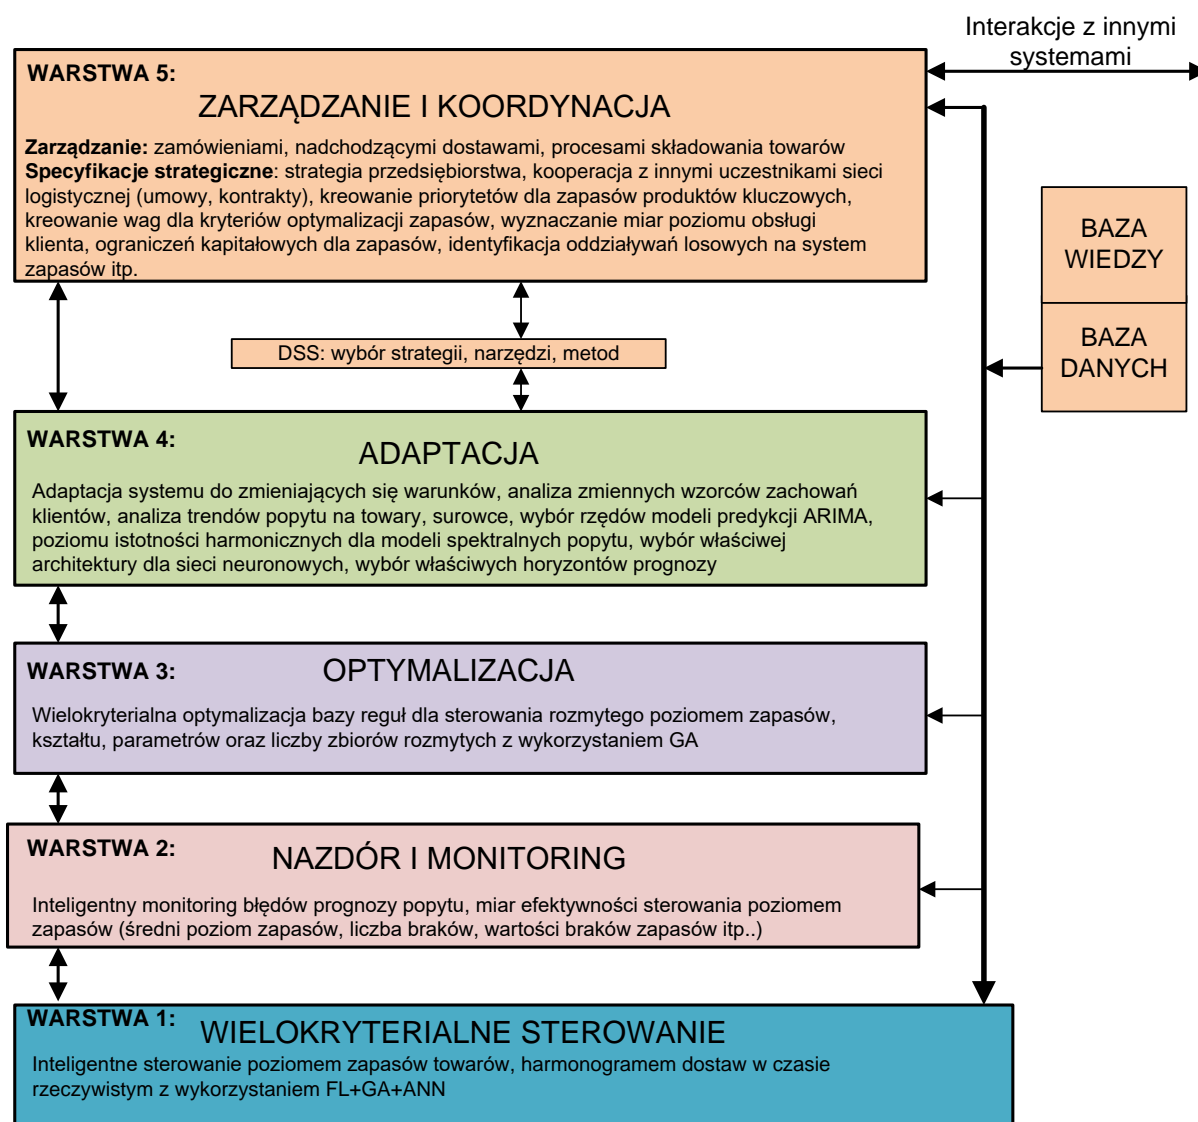
harmonogramów dostaw z wykorzystaniem FL+GA+ANN w oparciu o kryteria, priorytety i wytyczne wyznaczone przez wyższe warstwy.

### Warstwa nadzoru i monitoringu:

Na tym poziomie ma miejsce nadzór oraz monitoring w czasie rzeczywistym nad stabilnością systemu zapasów. Prowadzony jest monitoring błędów predykcji popytu, miar efektywności sterowania zapasami (poziom zapasów, liczba występujących braków towarów, wartości braków, kosztów utraconych możliwości wskutek braków). W sytuacji gdy aktualne miary efektywności odbiegają od wartości zdefiniowanych przekazywana jest informacja w górne warstwy w celu aktualizacji i re-ptymalizacji parametrów systemu.

### Warstwa sterowania:

W warstwie tej następuje predycyjne sterowanie bezpośrednie poziomem zapasów poszczególnych towarów, referencyjne stabilizowanie reprezentatywnych harmonogramów dostaw.



Rys. 33. Problem sterowania zapasami w strukturze ILS

Źródło: opracowanie własne [3,4]

Zaletą przedstawionej idei systemowego ujęcia problemu zapasów w ramach struktury HILS jest możliwość dynamicznej reakcji systemu zapasów na zmieniające się warunki rozwiązywanego problemu w czasie. Umożliwia to maksymalizację poziomu obsługi klienta, minimalizację strat, osiąganie większych korzyści ekonomicznych poprzez ograniczanie kosztów. Realizacja tych celów jest możliwa nie tylko na poziomie pojedynczego przedsiębiorstwa, lecz także globalnie w ramach całej sieci dostaw. Podstawowym warunkiem zagwarantowania efektywności takiego podejścia jest zapewnienie sprawnego przepływu informacji oraz danych o aktualnym stanie procesów logistycznych i transportowych pomiędzy warstwami dla całej sieci dostaw. Ponadto oferowana w pracy metoda poprzez wspomniane ujęcie systemowe posiada naturę uniwersalności. Dzięki temu może być wykorzystywana w inteligentny sposób dla różnych typów przedsiębiorstw, produktów o różnej specyfice i wzorcu zapotrzebowania.

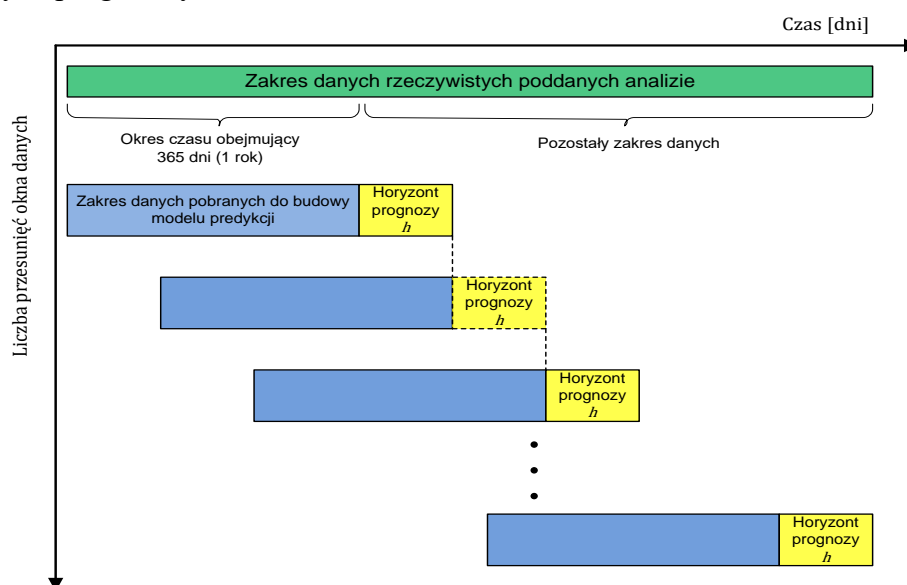
## 5. WERYFIKACJA EFEKTYWNOŚCI PROPONOWANEJ METODY STEROWANIA ZAPASAMI TOWARÓW W WARUNKACH NIEPEWNOŚCI

W celu określenia poziomu efektywności przedstawianego w dysertacji podejścia, w niniejszym rozdziale zostaną zaprezentowane wyniki symulacji poziomu zapasów wedle przyjętych założeń, dla określonego horyzontu czasowego. Badania zostały przeprowadzone na podstawie rzeczywistych zestawów danych o zapotrzebowaniu na produkty, pochodzących z przedsiębiorstwa. W kolejnych podrozdziałach zostaną przedstawione odpowiednio wyniki analizy efektywności oddzielnie dla modułu predykcji oraz całego systemu sterowania zapasami wraz z jego analizą wrażliwości.

### 5.1 ANALIZA EFEKTYWNOŚCI MODUŁU PREDYKCJI


#### 5.1.1 Charakterystyka danych empirycznych

Zgodnie z ideą proponowanego systemu sterowania poziomem zapasów towarów w warunkach oddziaływania czynników niepewnych, element prognozowania przyszłych wartości zapotrzebowania na towar stanowi jego niezwykle ważny element, mając na uwadze dążenie do zmniejszenia poziomu niepewności w tym zakresie. Zatem aby określić stopień efektywności działania modułu predykcji opisanego w rozdziale 4 oraz trafności otrzymywanych prognoz, przeprowadzono badania i symulacje komputerowe na podstawie 25 zestawów danych rzeczywistych z przedsiębiorstwa zajmującego się dystrybucją produktów płynnych. Zestawy danych pochodzą z różnych punktów sieci dystrybucji tegoż przedsiębiorstwa. Szeregi czasowe przedstawiające dzienny popyt na dany produkt obejmują okres dwóch lat. Na podstawie danych z pierwszego roku budowany jest model predykcji dla danego produktu, następnie druga ich część jest wykorzystywana w celu testowania trafności sporządzanych prognoz rys. 34.



Rys. 34. Sposób testowania prognoz

Zgodnie ze schematem rys.34. każdorazowo dla każdego produktu model predykcji jest budowany na podstawie 365 ostatnio zaobserwowanych wartości zmiennej prognozowania, następnie wyznaczana jest prognoza wartości na okres  $h$  dni w przód. Po zaobserwowaniu wartości rzeczywistych popytu w okresie  $h$  wyznaczone wartości prognozy są porównywane z wartościami rzeczywistymi na podstawie wyznaczonych dla tego okresu mierników trafności prognozy w postaci procentowego błędu bezwzględnego MAPE oraz pierwiastka błędu średniokwadratowego RMSE. W następnej kolejności zakres danych używanych do budowy modelu przesuwany jest zgodnie z osią czasu o  $h$  dni uwzględniając ostatnie  $h$  zrealizowanych obserwacji w budowie kolejnego modelu na następny okres. Proces ten był powtarzany do momentu zrealizowania popytu dla drugiej części danych w pojedynczym szeregu czasowym. Taka sama analiza została wykonana dla każdego zestawu danych oraz dla różnych wartości horyzontu prognozy  $h$  gdzie  $h = \{2, \dots, 5 \text{ dni}\}$ . Aby zbadać elastyczność modułu predykcji, jego kompleksowość oraz zdolność dopasowania do różnych wzorców popytowych, zestawy danych zostały dobrane w taki sposób aby zawierały możliwie szeroki przedział współczynników zmienności, które są wskaźnikiem dynamiki dla wartości szeregu czasowego. Przykładowe zestawy danych wykorzystane w analizie z różnym współczynnikiem zmienności przedstawia rys. 35.




**Rys. 35.** Przykładowe zestawy danych wykorzystane w analizie  
Źródło: opracowanie własne

Z analizy wykresu wynika iż rozważane zestawy danych charakteryzują się różną specyfiką i wzorcem zapotrzebowania. Jedne posiadają wyraźnie zaznaczone szczyty w równych odstępach świadczące o wahaniami długo okresowych. Dodatkowo obecne są wahania krótko okresowe oraz przypadkowe, silnie utrudniając proces prognozowania. Poniżej w kolejnych podrozdziałach zostaną przedstawione rezultaty poszczególnych etapów budowy modelu predykcji dla pojedynczego szeregu czasowego (Zestaw 1) zgodnie z wytycznymi przedstawionymi w podrozdziale 4.2.1.


### 5.1.2 Estymacja parametrów składowej spektralnej oraz modelu ARIMA w hybrydowym modelu predykcji

Zgodnie ze wzorem (78) pierwszą składową pojedynczego modelu predykcji dla rozważanego zestawu danych jest komponent pochodzący z analizy częstotliwościowej szeregu po uprzednim minimalnym przefiltrowaniu danych filtrem Hodricka – Prescottta o przyjętej stałej wygładzania równej 0.2. Tak wybrana stała w minimalnym tylko stopniu wpływa na utratę informacji w szeregu. Po wykonaniu transformaty Fouriera dla wybranego szeregu określono te składowe harmoniczne spośród  $n/2$ , które w największym stopniu wyjaśniają wariancję szeregu. Dla rozważanego szeregu czasowego przyjęto, że jeśli któraś z harmonik wyjaśnia wariancję szeregu w większym stopniu niż 5% to jest uwzględniana w spektralnej składowej całego modelu. Poniższy wykres rys. 36. przedstawia wykaz harmonik szeregu które w największym stopniu wyjaśniają jego wariancję.



**Rys. 36.** Wykaz najistotniejszych harmonik szeregu dla zestawu danych nr 1  
*Źródło: opracowanie własne*

Z wykresu na rys.36. wynika, iż w badanym szeregu można wyodrębnić trzy znaczące cykle: roczny, półroczny i kwartalny odpowiednio harmoniczne 1,2 oraz 3. Kolejne harmoniczne większe od siódmej mają bardzo niewielki udział w wariancji szeregu więc zostały pominięte na wykresie. Zatem w pierwszej składowej modelu predykcji dla rozważanego przykładu występują trzy pierwsze harmoniczne, wyjaśniając 43% zmienności. Sytuację tą przedstawia rys. 37.



**Rys. 37.** Dopasowanie składowej spektralnej do wartości rzeczywistych szeregu


*Źródło: opracowanie własne*

Wykorzystując wzory (65), (66) wyznaczono współczynniki dla składowej spektralnej modelu, którą dla rozważanego przypadku przedstawia poniższa formuła:

$$y_t = 7461 - 21,5 \cdot \sin\left(\frac{2\pi}{365}t\right) - 1154 \cdot \cos\left(\frac{2\pi}{365}t\right) + 49,8 \cdot \sin\left(\frac{2\pi}{365}2t\right) + 665,2 \cdot \cos\left(\frac{2\pi}{365}2t\right) - 85,4 \cdot \sin\left(\frac{2\pi}{365}3t\right) - 225,2 \cdot \cos\left(\frac{2\pi}{365}3t\right) \quad (111)$$

Reszty z tak wyznaczonego komponentu spektralnego posłużyły do estymacji parametrów dla składowej modelu ARIMA,  $Y(t)^{(ARIMA)}$  zgodnie ze wzorem (78). Kluczowym elementem na tym etapie było ustalenie optymalnego rzędu dla modelu ARIMA czyli wartości (p,d,q). W tym celu wykorzystano kryterium informacyjne Schwartz'a bazujące na minimalizacji logarytmicznego kryterium wiarygodności [123]. Pomaga ono wybrać model o najlepszej liczbie parametrów. Dodatkowo proces wyboru optymalnego rozmiaru modelu wsparty został analizą wartości funkcji autokorelacji (ACF) oraz autokorelacji cząstkowej (PACF), co przedstawia rys.38.





**Rys. 38.** Wykresy funkcji autokorelacji ACF oraz autokorelacji cząstkowej PACF dla rozważanego przykładu

Źródło: opracowanie własne

Na podstawie wartości funkcji Autokorelacji oraz Autokorelacji cząstkowej dla kolejnych opóźnień wybrano zakres rozmiaru modelu ARIMA ze względu na parametr  $p$  opisujący rząd autoregresji oraz  $q$  wskazujący na rząd średniej ruchomej, rozważając  $k$  pierwszych istotnych statystycznie wartości dla obu funkcji. Zatem przyjęto odpowiednio zakresy dla  $p = \{1 \dots 3\}$  oraz  $q = \{1 \dots 2\}$ . Dla każdej kombinacji wartości  $p$  i  $q$  estymowany model poddano ocenie ze względu na kryterium informacyjne Schwartz'a. Wartości logarytmicznej funkcji wiarygodności dla poszczególnych wariantów rozmiarów modelu ARIMA przedstawia poniższa Tabela 4.

**Tabela 4.** Wartości kryterium informacyjnego Schwartz'a dla wariantów modelu

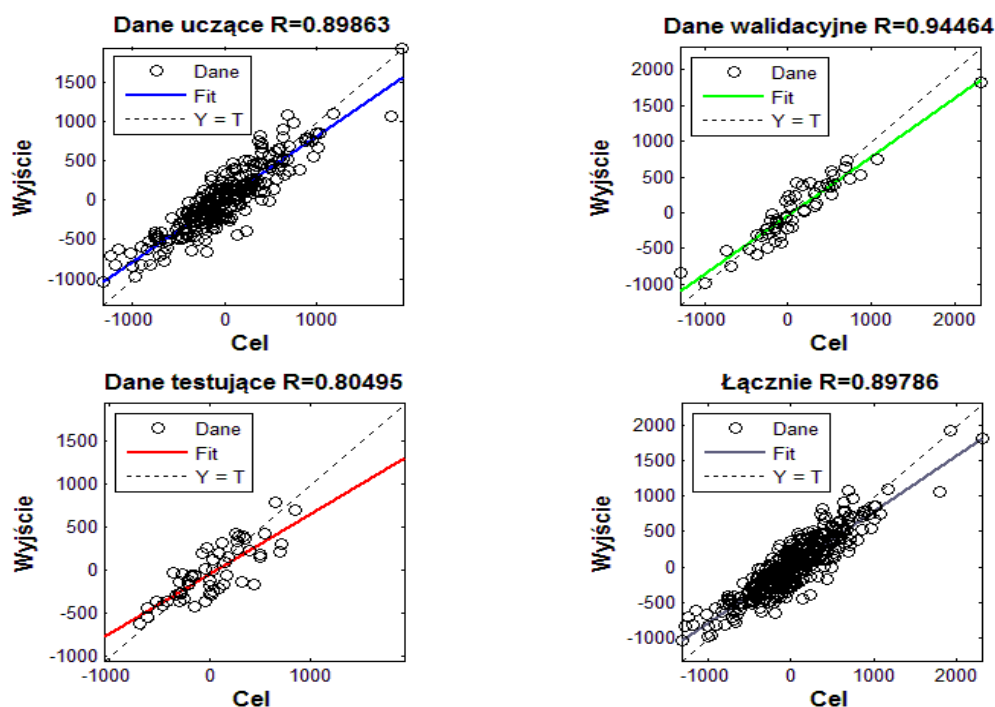
Rozmiar części autoregresyjnej $p$	Rozmiar składowej średniej ruchomej $q$	
	$q=1$	$q=2$
$p=1$	6113	6045
$p=2$	6039	6040
$p=3$	5938	6059

Ze względu na kryterium informacyjne z powyższej tabeli najlepszym modelem dla tego przypadku okazał się model o parametrach ARIMA (3,1,1), (najmniejsza wartość z tabeli wskazuje wartości  $p$ ,  $q$ ) Aby zagwarantować wymóg stacjonarności przeprowadzono jednokrotne różnicowanie stąd  $d=1$ . Dodatkowo należy nadmienić, że wartości kryterium Schwartz'a dla poszczególnych wariantów są bezwymiarowe, a rząd ich wartości nie ma większego znaczenia. Oszacowane wartości parametrów tak przyjętego modelu ARIMA przedstawiono poniżej:

$$Y(t)^{(ARIMA)} = 2,1 + 0,92 \cdot Y_{t-1} - 0,51 \cdot Y_{t-2} + 0,06 \cdot Y_{t-3} - 0,86 \cdot e_{t-1} \quad (112)$$

### 5.1.3 Ocena efektywności procesu uczenia sieci neuronowej w hybrydowym modelu predykcji

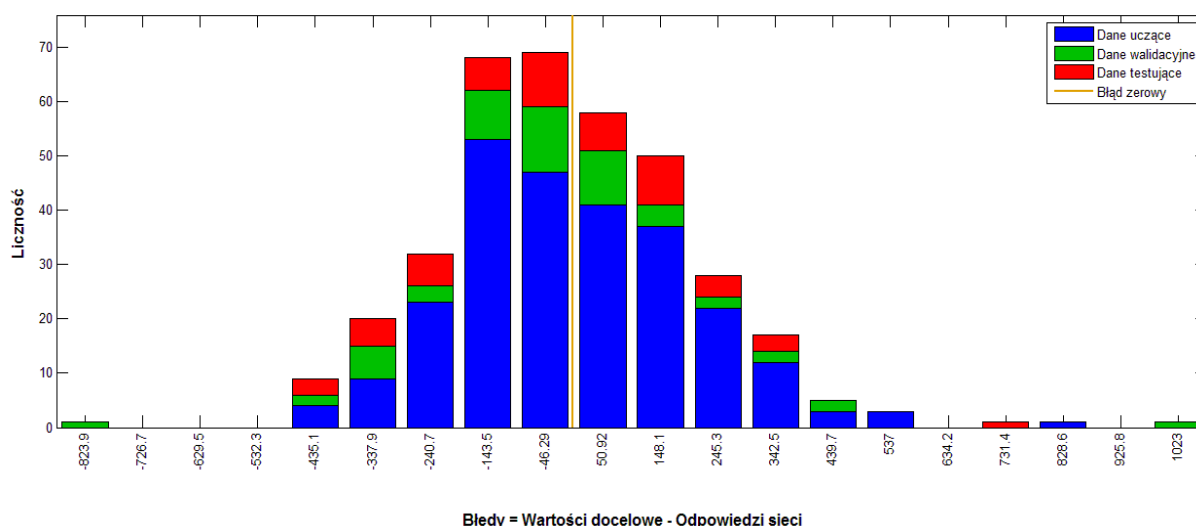
Ostatnim już elementem całego modułu predykcji jest składowa prognozy pochodząca z sztucznej sieci neuronowej  $Y(t)^{(ANN)}$ . Wyznaczone reszty z modelu ARIMA posłużyły jako ciąg wartości uczących dla sieci neuronowej. Początkowa architektura sieci została ustalona na podstawie przywołanego w sekcji 4.2.1.3 twierdzenia Kołmogorowa dla sieci neuronowych. W dalszej kolejności na podstawie procedury doboru liczby neuronów docelowo dla rozważanego przykładu wybrano sieć składającą się z 3 neuronów w warstwie wejściowej, 8 neuronów w warstwie ukrytej oraz 1 neuronu wyjściowego z godnie ze schematem przedstawionym na rys. 20. Tak dobrana struktura sieci w rozważanym przypadku osiągnęła najlepsze rezultaty uczenia. Efektywność uczenia sieci, jej stopień dopasowania do danych dla rozważanego przykładu przedstawia rys. 39.



Rys. 39. Efektywność procesu uczenia sieci

Źródło: opracowanie własne

Na podstawie powyższego wykresu można stwierdzić, iż proces uczenia przebiegł pomyślnie. Wartości otrzymywane z sieci są dobrze dopasowane do wartości docelowych szeregu rzeczywistego. Świadczą o tym wysokie wartości współczynnika  $R^2$  nie tylko dla danych uczących ale również dla zestawu walidacyjnego oraz testującego, na które został podzielony cały ciąg uczący. Wysoka wartość współczynnika  $R^2$  wyłącznie dla części uczącej danych sugerowałaby bowiem efekt przeuczenia sieci dopasowując się wyłącznie do zbioru wykorzystywanego w jej trenowaniu. Natomiast w tym przypadku w wartościach wag połączeń między neuronami została zapisana pewna wiedza o pewnym wzorcu popytowym obecnym w rozważanym przykładzie, który nie został rozpoznany przez poprzednie składowe moduły prognostycznego. O efektywności wytrenowanej sieci w rozważanym przypadku świadczy również struktura błędów powstała w trakcie procesu uczenia. Została ona przedstawiona na rys. 40.



**Rys. 40.** Histogram błędów odpowiedzi sztucznej sieci neuronowej

Źródło: opracowanie własne

Z zamieszczonego diagramu wynika, że zdecydowanie dominują błędy o niskich wartościach niewiele odchylających się od zera zarówno w zbiorze danych uczących jak i walidacyjnych oraz testujących. Reasumując prognoza dla chwili czasowej  $t$  dla rozważanego przykładowego zestawu danych może być przedstawiona za pomocą sformułowania, będącego sumą wszystkich składowych:

$$Y^P(t) = 7461 - 21,5 \cdot \sin\left(\frac{2\pi}{365}t\right) - 1154 \cdot \cos\left(\frac{2\pi}{365}t\right) + 49,8 \cdot \sin\left(\frac{2\pi}{365}2t\right) + 665,2 \cdot \cos\left(\frac{2\pi}{365}2t\right) - 85,4 \cdot \sin\left(\frac{2\pi}{365}3t\right) - 225,2 \cdot \cos\left(\frac{2\pi}{365}3t\right) + 2,1 + 0,92 \cdot Y_{t-1} - 0,51 \cdot Y_{t-2} + 0,06 \cdot Y_{t-3} - 0,86 \cdot e_{t-1} + Y(t)^{(ANN)} \quad (113)$$


Wyznaczone optymalne struktury sieci neuronowych dla całości rozpatrywanych zestawów danych wraz z oceną efektywności procesu uczenia we wszystkich kolejnych horyzontach prognozowania przedstawiono w Tabeli 5.

**Tabela 5.** Wyznaczone struktury sieci neuronowych dla wszystkich zestawów danych

Nr zestawu danych	Wybrana struktura sieci neuronowej		Wartość współczynnika $R^2$			
	L. neuronów wejściowych	L. neuronów ukrytych	Horyzont prognozy $h=2$ dni	Horyzont prognozy $h=3$ dni	Horyzont prognozy $h=4$ dni	Horyzont prognozy $h=5$ dni
Z1	3	8	0,89	0,89	0,88	0,85
Z2	3	7	0,91	0,9	0,9	0,88
Z3	2	7	0,92	0,9	0,89	0,88
Z4	2	6	0,88	0,88	0,87	0,85
Z5	3	8	0,81	0,8	0,81	0,8
Z6	3	8	0,82	0,82	0,8	0,78
Z7	2	6	0,86	0,84	0,84	0,82
Z8	3	7	0,8	0,79	0,78	0,75
Z9	3	8	0,85	0,85	0,84	0,82
Z10	4	10	0,91	0,9	0,88	0,85
Z11	4	9	0,84	0,83	0,83	0,81
Z12	4	11	0,85	0,85	0,84	0,81
Z13	3	9	0,81	0,81	0,78	0,74
Z14	3	9	0,82	0,82	0,8	0,78
Z15	4	10	0,8	0,78	0,76	0,72
Z16	4	10	0,82	0,81	0,79	0,75
Z17	4	11	0,81	0,79	0,79	0,78
Z18	3	7	0,81	0,78	0,75	0,72
Z19	4	11	0,84	0,84	0,83	0,81
Z20	4	11	0,83	0,82	0,82	0,81
Z21	3	9	0,82	0,8	0,79	0,79
Z22	4	11	0,8	0,79	0,79	0,76
Z23	5	12	0,81	0,8	0,78	0,77
Z24	5	12	0,8	0,82	0,83	0,8
Z25	5	12	0,81	0,81	0,8	0,78

Na podstawie Tabeli 5. można sformułować wniosek, iż proces doboru struktury dla sieci neuronowych oraz trenowanie przebiegło pozytywnie nie tylko w rozważanym przykładowym zestawie danych nr 1. lecz także dla pozostałego zbioru danych. Świadczą o tym wysokie wartości współczynnika  $R^2$  przekraczające w niektórych przypadkach wartość 0,9. Jednocześnie można dostrzec pewną zależność iż wraz ze wzrostem horyzontu prognozowania efektywność uczenia nieznacznie spada. Powodem mogą być zwiększające błędy otrzymywane przez poprzednie składowe hybrydowego modelu predykcji.

W rozpatrywanym aktualnie przykładzie danych dla horyzontu prognozy  $h=2$  dni przeprowadzono sekwencję wszystkich czynności niezbędnych do budowy modelu wymaganą liczbę razy, za każdym razem aktualizując cały model po zrealizowaniu się  $h$  ostatnich wartości w szeregu tak aby otrzymać prognozy dwudniowe dla kolejnego roku. Fragment wykresu ukazujący dopasowanie prognoz do wartości rzeczywistych szeregu przedstawia rys. 41.



**Rys. 41.** Dopasowanie wartości prognoz dwudniowych szeregu nr 1 do danych rzeczywistych


*Źródło: opracowanie własne*

Na podstawie wykresu można stwierdzić, iż wyznaczane kolejne prognozy dwudniowe przy pomocy modułu predykcji dosyć dobrze odwzorowują przyszłe zapotrzebowanie na analizowany produkt. Można zaobserwować także, iż otrzymane w ten sposób wartości szeregu prognoz „nadażają” za dynamicznie postępującymi zmianami w szeregu rzeczywistym.

#### 5.1.4 Weryfikacja trafności otrzymanych prognoz zapotrzebowania na towary

Powyższa analiza została przeprowadzona dla wszystkich 25 zestawów danych a wyznaczane prognozy obejmowały horyzont prognozy  $h$  należący do zbioru  $h = \{2,3,4,5\}$ . Otrzymane szeregi prognoz porównano z metodami powszechnie stosowanymi w praktyce czyli modelami wykładniczego (Holta, Wintersa) oraz ważoną średnią ruchomą. Każdorazowo parametry wykładniczego dla metod porównawczych zostały wyznaczone w drodze minimalizacji błędu średniokwadratowego RMSE. Całość procedury została zaprogramowana w środowisku obliczeniowym Matlab. Aby określić jakość oraz dokładność sporządzanych prognoz dla całego analizowanego okresu wyznaczono kwartyli ( $Q_{0.25}$ ,  $Q_{0.5}$ ,  $Q_{0.75}$ ) błędów prognoz dla poszczególnych metod prognozowania i kolejnych horyzontów prognozy  $h$ . Czynność ta pozwoli określić strukturę popełnianych błędów dla wszystkich porównywanych metod. Dokładne wartości liczbowe kwartyli błędów prognozowania przedstawia Załącznik A.


- wartości poszczególnych kwartyli błędów prognoz dla horyzontu prognozy  $h=2$



**Rys. 42.** Wartości  $Q_{0.25}$  błędów MAPE wyznaczonych prognoz dwudniowych

Źródło: opracowanie własne

Z przedstawionego wykresu można zaobserwować, że wartości błędów MAPE w kwartylu  $Q_{0.25}$  dla wszystkich analizowanych zestawów danych osiągają niewielkie wartości dla prezentowanego modelu hybrydowego. Nieco słabiej wypadły prognozy wykonane przy pomocy modelu Holta. W dalszej kolejności znalazły się model średniej ruchomej oraz model Wintersa. Łatwo dostrzec również, iż dla niektórych zestawów przewaga modelu hybrydowego jest niewielka. Jednak w pozostałych przypadkach różnice są zdecydowanie większe na korzyść prezentowanego podejścia hybrydowego.




**Rys. 43.** Wartości  $Q_{0.5}$  błędów MAPE wyznaczonych prognoz dwudniowych

Źródło: opracowanie własne

Dokonując analizy wykresu rys. 43. można dostrzec, iż wartości błędów MAPE w kwartylu  $Q_{0.5}$  dla prognoz wyznaczonych przez moduł predykcji wykorzystujący podejście hybrydowe wzrosły nieznacznie w porównaniu do  $Q_{0.25}$ . Jednak w porównaniu do poprzedniego zestawienia tutaj pojawiają się coraz to większe różnice na korzyść hybrydowego podejścia dla coraz to większej liczby zestawów danych.






**Rys. 44.** Wartości  $Q_{0.75}$  błędów MAPE wyznaczonych prognoz dwudniowych

Źródło: opracowanie własne

Wartości kwartyła  $Q_{0.75}$  błędów MAPE dla modelu Wintersa oraz średniej ruchomej w wielu przypadkach przekraczają wartości 50%. Zdarzają się również sytuacje kiedy wartość  $Q_{0.75}$  przekracza 100%. Oznacza to, iż 25% populacji błędów w badanym okresie posiada wartości większe niż 50%. Natomiast dla metody hybrydowej maksymalna wartość kwartyła  $Q_{0.75}$  wyniosła 51% jedynie w dwóch przypadkach spośród 25 rozważanych zestawów danych. Stąd można wnioskować, że dla całej populacji dominują zdecydowanie niższe wartości błędów w porównaniu do innych metod. Średnie wartości procentowego błędu MAPE dla całego analizowanego okresu przedstawia rys. 45.




**Rys. 45.** Średnie wartości błędu MAPE dla prognoz dwudniowych


Źródło: opracowanie własne

Średnie wartości błędu prognozy MAPE dla wszystkich zestawów danych są najmniejsze w przypadku metody hybrydowej. Dla pewnych zestawów danych rezultaty otrzymane z modelu Holta są nieznacznie gorsze w porównaniu do metody hybrydowej. Najślabiej w zestawieniu wypada średnia ruchoma, gdzie dla pewnych zestawów danych przeciętny błąd w całej populacji przekracza nawet 250%. Analogiczna analiza została przeprowadzona dla pozostałych horyzontów czasowych.


- wartości poszczególnych kwartyli błędów prognoz dla horyzontu prognozy  $h=3$




**Rys. 46.** Wartości  $Q_{0.25}$  błędów MAPE wyznaczonych prognoz trzydniowych  
*Źródło: opracowanie własne*



**Rys. 47.** Wartości  $Q_{0.5}$  błędów MAPE wyznaczonych prognoz trzydniowych  
*Źródło: opracowanie własne*




**Rys. 48.** Wartości  $Q_{0.75}$  błędów MAPE wyznaczonych prognoz trzydniowych  
*Źródło: opracowanie własne*




**Rys. 49.** Średnie wartości błędów MAPE dla prognoz trzydniowych  
Źródło: opracowanie własne

Analizując rezultaty otrzymanych prognoz o horyzoncie prognozy  $h=3$  dni można stwierdzić, iż wartości kwartyli  $Q_{0.25}$ ,  $Q_{0.5}$ ,  $Q_{0.75}$  błędów są najniższe dla modelu hybrydowego. Dla większości rozpatrywanych zestawów danych niewiele gorzej spisuje się model Holta, lecz dla zbioru danych nr 5, 6, 8, 22 różnice sięgają już kilkunastu procent. Zdecydowanie najgorsze rezultaty otrzymano dla modeli średniej ruchomej oraz modelu Wintersa. Rys. 49 przedstawiający średnie wartości błędów w całej ich populacji dla kolejnych zestawów danych wskazuje, iż model hybrydowy osiąga zdecydowanie lepsze wyniki, średnia błędów dla wszystkich zestawów nie przekracza 30%. Natomiast w przypadku modelu średniej ruchomej konieczne było utworzenie osi pomocniczej, gdyż przeciętna wartość błędów wyniosła 150%. W niektórych przypadkach średni błąd sięgnął wartości 700%.


- wartości poszczególnych kwartyli błędów prognoz dla horyzontu prognozy  $h=4$




**Rys. 50.** Wartości  $Q_{0.25}$  błędów MAPE wyznaczonych prognoz czterodniowych  
Źródło: opracowanie własne



**Rys. 51.** Wartości  $Q_{0.5}$  błędów MAPE wyznaczonych prognoz czterodniowych  
*Źródło: opracowanie własne*



**Rys. 52.** Wartości  $Q_{0.75}$  błędów MAPE wyznaczonych prognoz czterodniowych  
*Źródło: opracowanie własne*




**Rys. 53.** Średnie wartości błędów MAPE dla prognoz czterodniowych  
*Źródło: opracowanie własne*


Wyniki symulacji prognoz dla horyzontu  $h=4$  dni wskazują, iż pomimo dłuższego horyzontu prognozy proponowana metoda hybrydowa w dalszym ciągu daje lepsze rezultaty w porównaniu do innych rozważanych podejść. Wartości kwartyli  $Q_{0.25}$ ,  $Q_{0.5}$ ,  $Q_{0.75}$  błędów (rys. 50 – 52) w przeważającej liczbie przypadków są najmniejsze dla metody hybrydowej. Jednakże dla zestawów danych 12, 15, 16, 18 wartości kwartyli  $Q_{0.25}$ ,  $Q_{0.5}$ ,  $Q_{0.75}$  są najlepsze

dla modelu Holta. Mimo to na podstawie rys. 53. można zaobserwować, iż wartość średnia dla całej populacji wszystkich błędów w poszczególnych zestawach danych jest najmniejsza dla modelu hybrydowego. Jego średnia wartość ze wszystkich zestawów wynosi 32% a więc tylko 2% gorzej niż dla horyzontu  $h=3$ . Najslabiej w zestawieniu kształtują się wyniki dla średniej ruchomej, w niektórych przypadkach np. dla zestawu nr 8 średnia wartość błędu wyniosła blisko 600%.


- wartości poszczególnych kwartyli błędów prognoz dla horyzontu prognozy  $h=5$



**Rys. 54.** Wartości  $Q_{0.25}$  błędów MAPE wyznaczonych prognoz pięciodniowych  
*Źródło: opracowanie własne*




**Rys. 55.** Wartości  $Q_{0.5}$  błędów MAPE wyznaczonych prognoz pięciodniowych  
*Źródło: opracowanie własne*



**Rys. 56.** Wartości  $Q_{0.75}$  błędów MAPE wyznaczonych prognoz pięciodniowych

Źródło: opracowanie własne



**Rys. 57.** Średnie wartości błędu MAPE dla prognoz pięciodniowych

Źródło: opracowanie własne

Rezultaty przeprowadzonych symulacji dla budowanych prognoz o horyzoncie  $h=5$  dni pokazują, iż pomimo tak długiego horyzontu prognozy, wartości błędów w poszczególnych kwartylach  $Q_{0.25}$ ,  $Q_{0.5}$ ,  $Q_{0.75}$  w większości analizowanych zestawów danych są najmniejsze dla metody hybrydowej (rys.54 -56.). Jednak podobnie jak w przypadku horyzontu prognozy  $h=4$  dla zestawów o numerze 12, 15, 16 i 18 wartości kwartyli dla modelu hybrydowego są nieznacznie gorsze w porównaniu do modelu Holta. Wartości kwartyli błędów dla pozostałych metod okazały się zdecydowanie wyższe, co przekłada się również na uśrednioną wartość błędu dla kolejnych zestawów danych rys. 57. Zbiorcze zestawienie całej przeprowadzonej analizy dla błędów MAPE oraz RMSE przedstawia Tabela. 6 oraz Tabela. 7.



**Tabela 6.** Zbiorcze zestawienie względnych procentowych błędów prognoz


HORYZONT PROGNOZY h	WARTOŚCI ŚREDNIE DLA KWARTYLI	BŁĄD MAPE [%]			
		METODA HYBRYDOWA	MODEL HOLTA	ŚREDNIA RUCHOMA	MODEL WINTERSA
h=2	Śr. Q0.25	11,9	16,6	21,6	31,3
	Śr. Q0.5	20,3	26,2	36,5	47,0
	Śr. Q0.75	51,5	80,6	249,9	154,5
	<b>Średnia łącznie</b>	<b>25,6</b>	<b>36,2</b>	<b>109,1</b>	<b>64,5</b>
h=3	Śr. Q0.25	14,6	18,9	25,9	34,6
	Śr. Q0.5	22,7	28,1	42,1	51,1
	Śr. Q0.75	35,0	42,9	73,9	75,5
	<b>Średnia łącznie</b>	<b>28,9</b>	<b>37,2</b>	<b>152,0</b>	<b>58,2</b>
h=4	Śr. Q0.25	19,0	20,0	30,8	38,0
	Śr. Q0.5	25,8	28,5	47,2	53,5
	Śr. Q0.75	38,5	42,4	76,4	77,4
	<b>Średnia łącznie</b>	<b>32,1</b>	<b>37,0</b>	<b>146,2</b>	<b>60,8</b>
h=5	Śr. Q0.25	20,6	20,5	32,9	40,2
	Śr. Q0.5	29,2	28,6	46,7	56,9
	Śr. Q0.75	42,6	41,2	72,8	81,4
	<b>Średnia łącznie</b>	<b>30,8</b>	<b>36,2</b>	<b>156,0</b>	<b>63,6</b>

**Tabela 7.** Zbiorcze zestawienie pierwiastka średniokwadratowego błędu prognoz

HORYZONT PROGNOZY h	WARTOŚCI ŚREDNIE DLA KWARTYLI	BŁĄD RMSE			
		METODA HYBRYDOWA	MODEL HOLTA	ŚREDNIA RUCHOMA	MODEL WINTERSA
h=2	Śr. Q0.25	707	1346	1633	2615
	Śr. Q0.5	1183	1989	2596	4009
	Śr. Q0.75	1939	2761	4016	5663
	<b>Średnia łącznie</b>	<b>1488</b>	<b>2243</b>	<b>2975</b>	<b>4386</b>
h=3	Śr. Q0.25	1019	1489	1912	3044
	Śr. Q0.5	1517	2102	2949	4210
	Śr. Q0.75	2261	2850	4213	5536
	<b>Średnia łącznie</b>	<b>1884</b>	<b>2387</b>	<b>3258</b>	<b>4525</b>
h=4	Śr. Q0.25	1141	1592	2273	3468
	Śr. Q0.5	1583	2089	3048	4457
	Śr. Q0.75	2239	2844	4129	5531
	<b>Średnia łącznie</b>	<b>1845</b>	<b>2466</b>	<b>3383</b>	<b>4742</b>
h=5	Śr. Q0.25	1212	1582	2334	3885
	Śr. Q0.5	1719	2034	3024	4619
	Śr. Q0.75	2454	2710	4215	5722
	<b>Średnia łącznie</b>	<b>2058</b>	<b>2393</b>	<b>3458</b>	<b>4913</b>

Na podstawie miar błędów prognoz wyrażonych przez RMSE oraz MAPE, zagregowanych w powyższych tabelach można w jednoznaczny sposób stwierdzić, iż proponowana w module predykcji hybrydowa metoda wyznaczania przyszłych wartości zapotrzebowania na towary dla zróżnicowanego pod względem współczynnika zmienności 25 zestawów danych okazała się najlepsza spośród innych wziętych do porównania metod. Przewaga metody hybrydowej nad drugim w kolejności modelem Holta okazała się największa dla krótszych horyzontów prognozowania (od kilkunastu do nawet kilkudziesięciu procent) im dłuższy horyzont prognozy tym uśrednione wyniki między tymi metodami stawały się coraz bardziej wyrównane, jednak z przewagą na korzyść podejścia hybrydowego. Pozostałe metody dostarczyły wyników zdecydowanie gorszych. Dodatkowo aby w sposób obrazowy określić

wpływ wzrastającego współczynnika zmienności dla kolejnych zestawów danych oraz horyzontu prognozowania  $h$  na średnie wartości względnych błędów procentowych metody hybrydowej przeprowadzono analizę, której rezultaty przedstawia rys. 58.



**Rys. 58.** Zależność względnego procentowego błędu prognozy od współczynnika zmienności oraz horyzontu prognozy  $h$  dla rozpatrywanego zestawu danych

*Źródło: opracowanie własne*

Na podstawie wykresu rys.58. można stwierdzić, iż proponowana metoda hybrydowa prognozowania zapotrzebowania na towar zachowuje pewien stopień elastyczności mimo wzrostu współczynnika zmienności danych oraz horyzontu prognozy. Przez to może być użyteczna dla różnych zbiorów danych o różnej specyfice, jak również dłuższym niż jeden czy dwa horyzontach prognozowania. Jednakże w rozważanym zbiorze danych pojawiły się zestawy gdzie wrażliwość metody na wzrastający horyzont prognozowania  $h$  jest większa, co oznacza, że dla pewnego ustalonego współczynnika zmienności procentowy błąd prognozowania szybciej narastał wraz ze wzrostem  $h$  w porównaniu do innych zestawów. Mimo to otrzymane rezultaty symulacji w szerokim zbiorze analizowanych zestawów danych o różnych współczynnikach zmienności świadczą iż zaproponowany hybrydowy model predykcyjny posiada cechę uniwersalności co oznacza, że może być użyteczny do wyznaczania prognoz dla różnych typów produktów.

## 5.2 ANALIZA EFEKTYWNOŚCI MODUŁU STEROWANIA

Kolejnym etapem w weryfikacji proponowanego podejścia jest analiza efektywności modułu rozmytego sterowania poziomem zapasów. Proces weryfikacji polegał na przeprowadzeniu eksperymentów obliczeniowych w postaci symulacji komputerowej poziomu zapasów, w rozważanym zbiorze danych według przedstawionej w rozdziale 4 metodyki. Zgodnie z rys. 18 na tym poziomie zostały wykorzystane wartości wyznaczonych prognoz zapotrzebowania na produkt dla 25 zestawów danych z poprzedniego paragrafu oraz odpowiadające im względne błędy procentowe prognozy. Ponadto proces weryfikacji został wzbogacony o analizę poziomu wrażliwości całego podejścia na zakres zmian wybranych czynników niepewnych w postaci czasu dostawy  $L_t$  oraz jakości dostawy  $r_t$ . Na tej podstawie zostało zdefiniowanych osiem wariantów symulacji, które reprezentują wzrastający poziom niepewności w kontekście wartości jakie mogą przyjmować wspomniane parametry. Charakterystykę zdefiniowanych wariantów symulacji przedstawia Tabela 8. Wszystkie kolejne obliczenia i analizy zostały wykonane oddzielnie dla każdego wariantu.

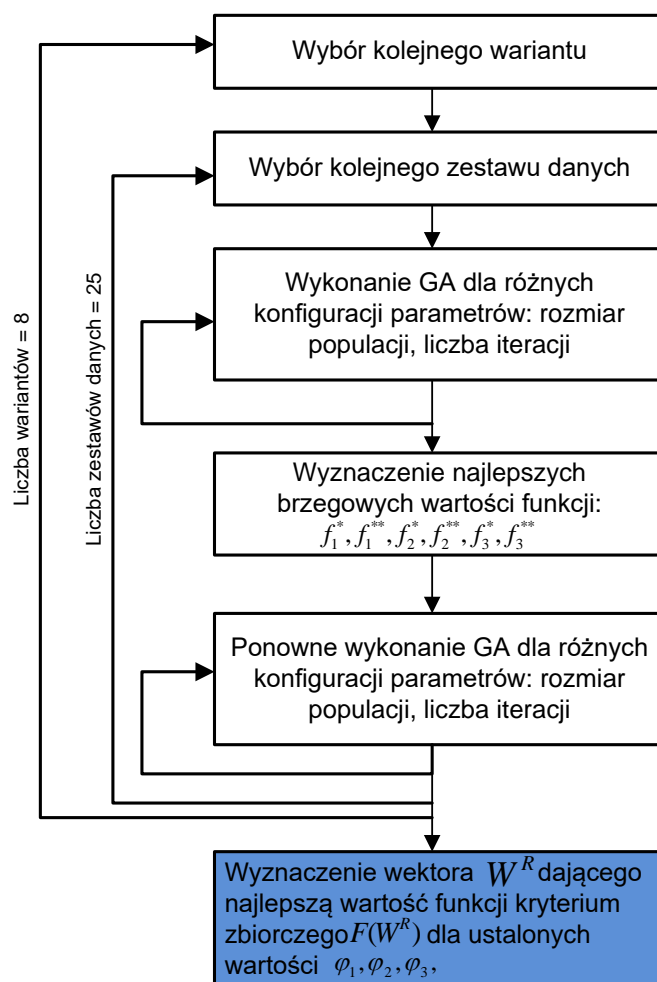
**Tabela 8.** Analizowane warianty symulacji

Nr wariantu	Zakres zmienności czasu dostawy $L_t$ [dni]	Odchylenie standardowe jakości dostawy $r_t$
Wariant 1	<1,4>	$\sigma_{r_t} = 0.15$
Wariant 2	<1,4>	$\sigma_{r_t} = 0.30$
Wariant 3	<1,5>	$\sigma_{r_t} = 0.15$
Wariant 4	<1,5>	$\sigma_{r_t} = 0.30$
Wariant 5	<1,6>	$\sigma_{r_t} = 0.15$
Wariant 6	<1,6>	$\sigma_{r_t} = 0.30$
Wariant 7	<1,7>	$\sigma_{r_t} = 0.15$
Wariant 8	<1,7>	$\sigma_{r_t} = 0.30$

### 5.2.1 Wyniki wielokryterialnej optymalizacji bazy reguł rozmytych z zastosowaniem algorytmu genetycznego

Kluczowym elementem w całym procesie weryfikacji metody była optymalizacja bazy reguł rozmytych poprzez odpowiedni dobór wag dla reguł, zgodnie ze wzorami (86 – 88) przy zastosowaniu algorytmu genetycznego. W celu oszacowania minimalnych oraz maksymalnych wartości funkcji kryteriów cząstkowych (przeciętny zapas produktu, liczba braków, liczba dostaw) przeprowadzono proces optymalizacji oddzielnie ze względu na każde z trzech kryterium, dla każdego z 25 zestawów danych wziętych do analizy. Procedurę optymalizacyjną powtórzono 10 krotnie dla każdego zestawu ustawień kluczowych parametrów algorytmu genetycznego. Takie działanie miało na celu odnalezienie możliwie jak najlepszych rozwiązań brzegowych dla poszczególnych kryteriów cząstkowych. Rozważano przy tym trzy warianty rozmiaru populacji początkowej chromosomów na

poziomie 100, 150 oraz 200 a także trzy warianty liczby wykonywanych generacji 100, 150 oraz 200. Na podstawie rekomendacji zawartych w [55] prawdopodobieństwo krzyżowania przyjęto na stałym poziomie równym 0.7 oraz prawdopodobieństwo mutacji na poziomie 0.1. Jako operator krzyżowania przyjęto krzyżowanie dwupunktowe z losowym wyborem punktów rozcięcia chromosomu. W efekcie dla każdego zestawu danych wybrano najlepsze osiągnięte rozwiązanie w postaci zestawu wag dla reguł rozmytych generujące najkorzystniejsze wartości funkcji kryteriów cząstkowych. Powyższa procedura optymalizacyjna została wykonana odrębnie dla każdego wariantu symulacji. Dokładna sekwencja wykonywanych kroków procedury optymalizacyjnej bazy reguł została przedstawiona na rys. 59.



**Rys. 59.** Procedura optymalizacyjna bazy reguł rozmytych

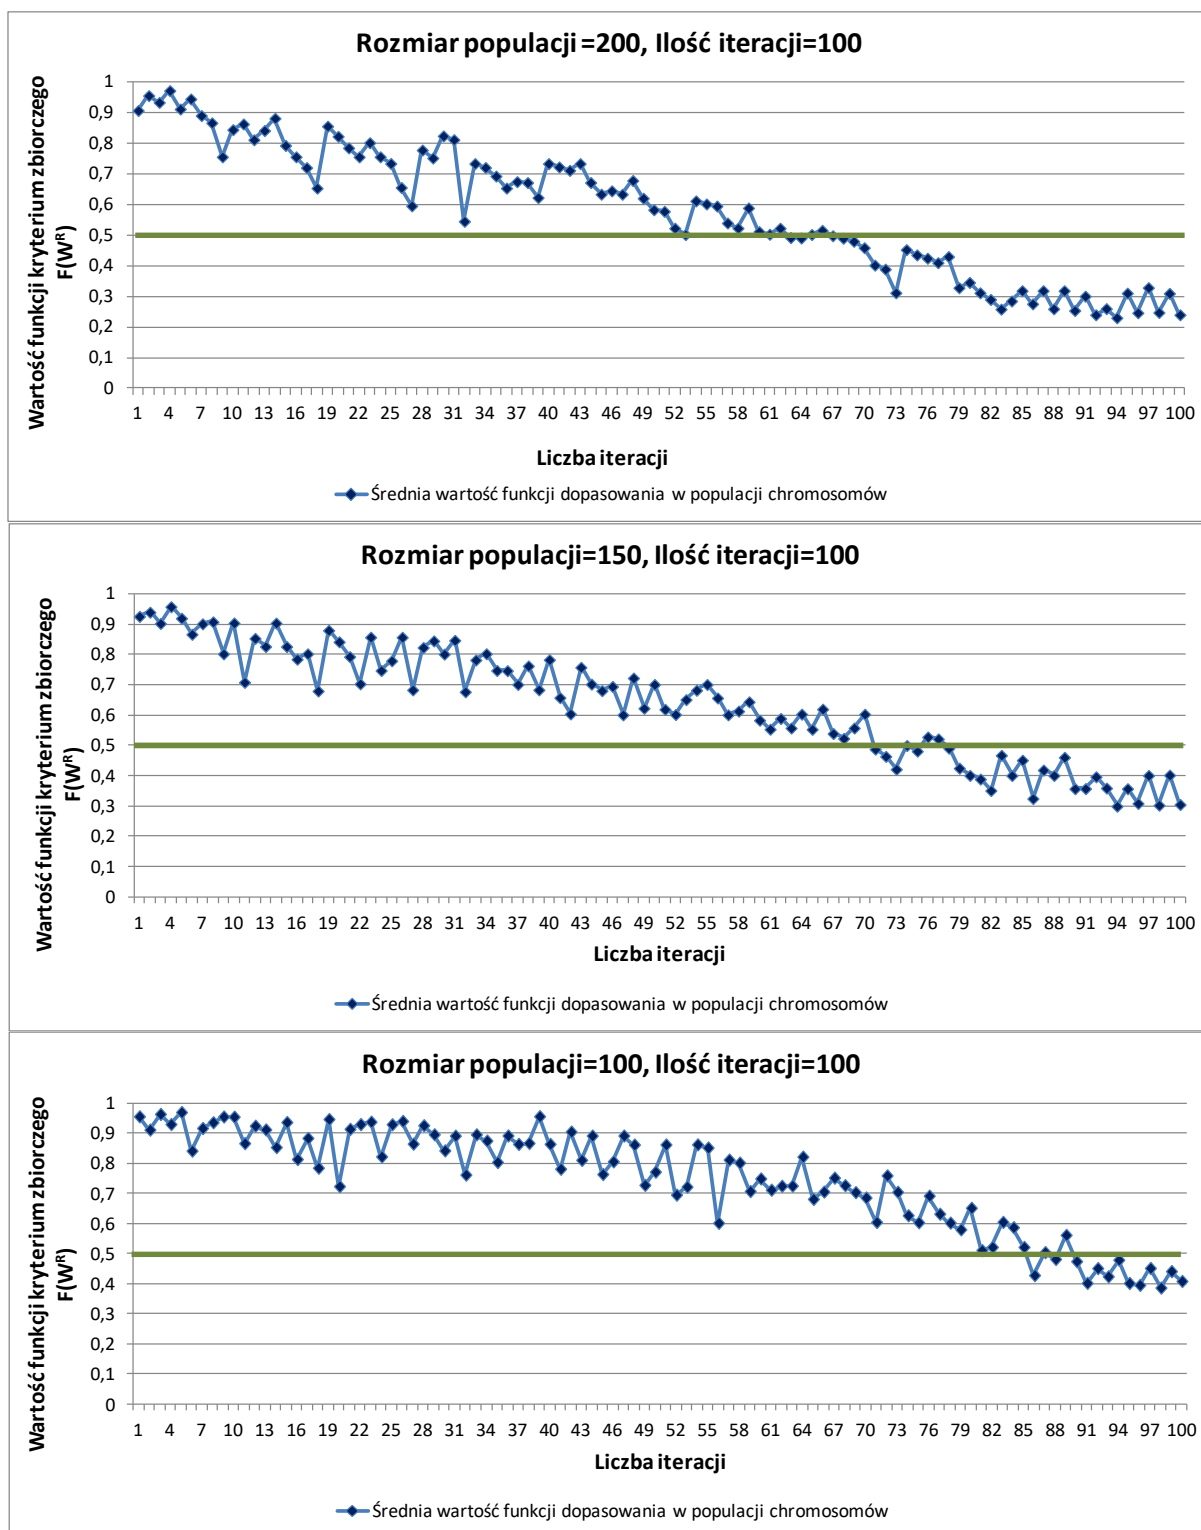
*Źródło: opracowanie własne*

Na podstawie powyższej procedury uzyskano oszacowania górne i dolne kryteriów cząstkowych dla każdego zestawu danych. W Tabeli. 9. przedstawiono otrzymane wartości tychże oszacowań dla wariantu symulacji nr 1. Horyzont planistyczny  $T_p$ , który podlegał analizie obejmował jeden rok. W celu zachowania przejrzystości przeciętny poziom zapasu wyrażono procentowo w odniesieniu do maksymalnej dopuszczalnej wielkości zapasu.

**Tabela 9.** Górne i dolne oszacowanie wartości kryteriów dla wariantu 1

Numer zestawu danych	minimalny przeciętny zapas [%]	maksymalny przeciętny zapas [%]	minimalna l. dostaw	maksymalna l. dostaw	maksymalna l. braków
1	29	59	29	43	17
2	26	54	33	52	21
3	28	55	33	50	16
4	26	62	26	55	19
5	31	58	66	80	38
6	29	52	36	55	23
7	25	54	36	53	22
8	29	60	27	56	25
9	28	58	39	53	21
10	32	56	38	52	13
11	30	67	7	21	20
12	35	65	12	23	16
13	32	72	3	12	18
14	29	65	11	37	14
15	31	59	3	7	14
16	29	71	3	7	16
17	33	62	11	27	14
18	25	75	3	8	21
19	29	61	15	30	19
20	29	65	13	26	17
21	27	63	15	26	25
22	26	70	6	23	21
23	25	62	5	18	26
24	28	65	45	58	32
25	25	61	25	43	27

Wartości przedstawione w powyższej tabeli są jedynie wartościami suboptymalnymi wyznaczonymi przez algorytm genetyczny, lecz niezbędnymi do dalszej analizy. Rzeczywiste optima globalne dla tychże kryteriów cząstkowych mogą się nieznacznie różnić od otrzymanych. Kolejnym krokiem było wyznaczenie optymalnego zestawu wag dla reguł rozmytych, z uwzględnieniem wszystkich trzech kryteriów jednocześnie, minimalizując funkcję kryterium zbiorczego zgodnie z formułą (86). Na podstawie przeprowadzonego wywiadu z przedsiębiorstwem przyjęto równe wartości wag dla kryteriów cząstkowych:  $\varphi_1 = 0,30$   $\varphi_2 = 0,4$   $\varphi_3 = 0,3$ , co stanowi jeden spośród wielu możliwych przypadków ze zbioru kompromisów określonego w paragrafie 4.2.2.3. Najlepsze rezultaty osiągnięto dla następujących ustawień algorytmu genetycznego: rozmiar populacji początkowej równy 200, liczba generacji równa 100. Reszta ustawień pozostała bez zmian. Zbieżność działania algorytmu genetycznego w procesie wielokryterialnej optymalizacji bazy reguł rozmytych dla wariantu symulacji nr 1. przedstawia rys.60.



**Rys. 60.** Zbieżność zastosowanego algorytmu genetycznego dla różnych konfiguracji rozmiaru populacji i liczby iteracji

Źródło: opracowanie własne

Efektywność działania algorytmu genetycznego została zaprezentowana w postaci oceny przeciętnej wartości funkcji przystosowania (funkcja kryterium zbiorczego  $F(W^R)$ ) w populacji chromosomów w kolejnych wykonywanych iteracjach algorytmu. Zgodnie z założeniem im niższa wartość zestandaryzowanej funkcji kryterium (86) tym wyznaczony

wektor wag w bazie reguł rozmytych będzie generował lepsze rozwiązanie problemu sterowania poziomem zapasów w wyznaczonym horyzoncie planistycznym  $T_p$  wedle przyjętych kryteriów oceny. Na podstawie wykresu rys. 60. działanie algorytmu genetycznego dla wariantu symulacji nr 1. jest najbardziej efektywne dla rozmiaru populacji liczącej 200 osobników i liczby iteracji równej 100. Dla takiej konfiguracji parametrów algorytm genetyczny szybciej osiągnął wymaganą zbieżność, generując najlepszą wartość funkcji dopasowania, która jest odległa od wartości idealnej tylko o 0,2. Pozostałe konfiguracje osiągnęły zdecydowanie gorszą zbieżność i słabsze rezultaty. Pozioma zielona linia zaznaczona na wykresie stanowi punkt odniesienia, dzięki któremu można efektywniej ocenić szybkość opadania funkcji przystosowania wraz z upływem iteracji algorytmu oraz wartość rozwiązania końcowego dla kolejnych wartości rozmiaru populacji chromosomów. Dla rozmiaru populacji chromosomów równej 200, po upływie 60 iteracji algorytmu wartość funkcji dopasowania wyraźnie zaczęła spadać poniżej wartości 0,5 oscylując w ostatnich iteracjach wokół wartości z przedziału 0,25 – 0,30. Dla porównania wartość funkcji dopasowania, w konfiguracji uruchomienia algorytmu z rozmiarem populacji równym 100, po upływie 60 iteracji wyraźnie znajdowała się powyżej wartości odniesienia 0,5. Ostateczna wartość funkcji dopasowania w końcowych iteracjach w tej konfiguracji ustawień oscylowała wokół wartości 0,4 co było wyraźnie gorszym rezultatem.

W wyniku wykonania procedury optymalizacyjnej dla każdego zestawu danych, oddzielnie dla każdego wariantu symulacji opisującego poziom zmienności czasu dostawy oraz parametru jakości dostawy, otrzymano zestaw optymalnych wag dla reguł w rozmytej bazie wiedzy. Tabela. 10. przedstawia zbiór reguł, których uśrednione wagi dla wszystkich zestawów danych okazały się największe. Pozostałe reguły ze względu na bardzo niską wagę wyznaczoną w trakcie optymalizacji pominięto.



**Tabela 10.** Zbiór najważniejszych reguł z uśrednionymi wagami dla wariantu 1

WEJŚCIA SYSTEMU					WYJŚCIA SYSTEMU		
Numer reguły	Prognozowany popyt $p(t)$	Poziom zapasów $z_t$	Czas dostawy $L_t$	Jakość dostawy $r_t$	Akt. wielkość zamówienia $q_t^*$	Akt. poziom zamawiania $rop_t^*$	Waga reguły $w_i^R$
1	mały	mały	krótki	niska	mała	niski	1,48
2	mały	mały	krótki	niska	mała	średni	1,20
3	mały	mały	krótki	niska	mała	wysoki	0,19
4	mały	mały	krótki	niska	średnia	niski	1,02
5	mały	mały	krótki	niska	średnia	wysoki	1,47
6	mały	mały	krótki	niska	duża	średni	0,39
7	mały	mały	krótki	niska	duża	wysoki	1,78
8	mały	mały	krótki	średnia	mała	niski	0,54
9	mały	mały	krótki	średnia	mała	średni	0,92
10	mały	mały	krótki	średnia	mała	wysoki	0,93
11	mały	mały	krótki	średnia	średnia	niski	2,04
12	mały	mały	krótki	średnia	duża	średni	0,49
13	mały	mały	krótki	średnia	duża	wysoki	1,51
14	mały	mały	krótki	wysoka	mała	średni	0,63
15	mały	mały	krótki	wysoka	mała	wysoki	0,28
16	mały	mały	krótki	wysoka	średnia	wysoki	0,32
17	mały	mały	średni	niska	mała	niski	0,39
18	mały	mały	średni	niska	średnia	średni	0,52
19	mały	mały	średni	średnia	średnia	wysoki	0,20
20	mały	mały	średni	średnia	duża	wysoki	0,52
21	mały	mały	średni	wysoka	mała	średni	1,20
22	mały	mały	średni	wysoka	średnia	średni	0,57
23	mały	mały	średni	wysoka	duża	wysoki	0,84
24	mały	mały	długi	niska	mała	wysoki	0,97
25	mały	mały	długi	średnia	mała	średni	0,80
26	mały	mały	długi	wysoka	mała	średni	0,38
27	mały	mały	długi	wysoka	średnia	średni	0,84
28	mały	mały	długi	wysoka	duża	wysoki	0,34
29	mały	średni	krótki	niska	mała	wysoki	1,60
30	mały	średni	krótki	niska	średnia	wysoki	1,42
31	mały	średni	krótki	niska	duża	średni	1,08
32	mały	średni	krótki	średnia	średnia	średni	0,20
33	mały	średni	krótki	średnia	średnia	wysoki	0,61
34	mały	średni	krótki	średnia	duża	średni	0,35
35	mały	średni	krótki	średnia	duża	wysoki	0,17
36	mały	średni	średni	niska	mała	niski	1,41
37	mały	średni	średni	niska	mała	średni	1,19
38	mały	średni	średni	niska	mała	wysoki	0,11
39	mały	średni	średni	niska	średnia	średni	0,17

Numer reguły	Prognozowany popyt $p(t)$	Poziom zapasów $z_t$	Czas dostawy $L_t$	Jakość dostawy $r_t$	Akt. wielkość zamówienia $q_t^*$	Akt. poziom zamawiania $rop_t^*$	Waga reguły $w_i^R$
40	mały	średni	średni	niska	duża	wysoki	0,55
41	mały	średni	średni	średnia	mała	niski	0,92
42	mały	średni	średni	średnia	mała	wysoki	0,31
43	mały	średni	średni	średnia	średnia	niski	1,37
44	mały	średni	średni	średnia	średnia	średni	1,94
45	mały	średni	średni	średnia	duża	niski	0,90
46	mały	średni	średni	średnia	duża	wysoki	0,51
47	mały	średni	średni	wysoka	mała	niski	2,61
48	mały	średni	średni	wysoka	średnia	wysoki	0,20
49	mały	średni	średni	wysoka	duża	wysoki	0,42
50	mały	średni	długi	niska	mała	niski	0,71
51	mały	średni	długi	niska	mała	wysoki	0,03
52	mały	średni	długi	niska	duża	średni	1,77
53	mały	średni	długi	niska	duża	wysoki	0,95
54	mały	średni	długi	średnia	duża	średni	0,36
55	mały	średni	długi	średnia	duża	wysoki	0,95
56	mały	średni	długi	wysoka	mała	wysoki	0,47
57	mały	średni	długi	wysoka	duża	średni	1,15
58	mały	średni	długi	wysoka	duża	wysoki	0,23
59	mały	wysoki	krótki	niska	mała	niski	1,67
60	mały	wysoki	krótki	niska	mała	średni	1,57
61	mały	wysoki	krótki	niska	mała	wysoki	1,08
62	mały	wysoki	krótki	średnia	średnia	wysoki	0,68
63	mały	wysoki	krótki	średnia	duża	wysoki	0,91
64	mały	wysoki	krótki	wysoka	średnia	wysoki	0,43
65	mały	wysoki	krótki	wysoka	duża	średni	0,59
66	mały	wysoki	średni	niska	mała	niski	0,70
67	mały	wysoki	średni	niska	średnia	niski	2,42
68	mały	wysoki	średni	niska	duża	niski	0,07
69	mały	wysoki	średni	wysoka	średnia	niski	0,29
70	mały	wysoki	średni	wysoka	duża	wysoki	0,44
71	mały	wysoki	długi	niska	mała	niski	0,24
72	mały	wysoki	długi	niska	średnia	niski	1,11
73	mały	wysoki	długi	niska	średnia	wysoki	0,09
74	mały	wysoki	długi	niska	duża	niski	0,75
75	mały	wysoki	długi	niska	duża	wysoki	0,97
76	mały	wysoki	długi	średnia	średnia	wysoki	2,00
77	mały	wysoki	długi	średnia	duża	średni	1,26
78	mały	wysoki	długi	wysoka	mała	wysoki	0,15
79	mały	wysoki	długi	wysoka	średnia	niski	0,68
80	mały	wysoki	długi	wysoka	duża	wysoki	0,81

Numer reguły	Prognozowany popyt $p(t)$	Poziom zapasów $z_t$	Czas dostawy $L_t$	Jakość dostawy $r_t$	Akt. wielkość zamówienia $q_t^*$	Akt. poziom zamawiania $rop_t^*$	Waga reguły $w_i^R$
81	średni	mały	krótki	niska	mała	niski	0,98
82	średni	mały	krótki	niska	mała	średni	0,35
83	średni	mały	krótki	średnia	średnia	średni	0,77
84	średni	mały	krótki	średnia	duża	wysoki	0,42
85	średni	mały	krótki	wysoka	mała	niski	1,34
86	średni	mały	krótki	wysoka	mała	wysoki	0,25
87	średni	mały	krótki	wysoka	średnia	niski	0,25
88	średni	mały	krótki	wysoka	średnia	wysoki	0,18
89	średni	mały	krótki	wysoka	duża	niski	1,42
90	średni	mały	krótki	wysoka	duża	wysoki	0,67
91	średni	mały	średni	średnia	mała	średni	0,17
92	średni	mały	średni	średnia	mała	wysoki	1,05
93	średni	mały	średni	średnia	średnia	średni	0,35
94	średni	mały	średni	średnia	średnia	wysoki	2,07
95	średni	mały	średni	średnia	duża	średni	0,68
96	średni	mały	średni	wysoka	mała	niski	1,35
97	średni	mały	średni	wysoka	mała	średni	1,04
98	średni	mały	długi	niska	mała	średni	0,23
99	średni	mały	długi	niska	duża	średni	0,57
100	średni	mały	długi	średnia	mała	niski	0,91
101	średni	mały	długi	średnia	mała	średni	0,09
102	średni	mały	długi	średnia	mała	wysoki	0,40
103	średni	mały	długi	średnia	średnia	niski	0,31
104	średni	mały	długi	średnia	średnia	wysoki	0,04
105	średni	mały	długi	wysoka	mała	średni	1,64
106	średni	mały	długi	wysoka	mała	wysoki	0,28
107	średni	mały	długi	wysoka	średnia	niski	2,20
108	średni	mały	długi	wysoka	średnia	wysoki	1,95
109	średni	średni	krótki	niska	mała	wysoki	0,72
110	średni	średni	krótki	niska	średnia	wysoki	1,71
111	średni	średni	krótki	niska	duża	średni	0,73
112	średni	średni	krótki	niska	duża	wysoki	0,31
113	średni	średni	krótki	średnia	mała	wysoki	1,72
114	średni	średni	krótki	średnia	średnia	wysoki	0,57
115	średni	średni	krótki	średnia	duża	średni	1,01
116	średni	średni	krótki	średnia	duża	wysoki	0,29
117	średni	średni	krótki	wysoka	mała	niski	0,74
118	średni	średni	krótki	wysoka	średnia	niski	1,74
119	średni	średni	krótki	wysoka	duża	wysoki	0,68
120	średni	średni	średni	niska	mała	niski	2,15
121	średni	średni	średni	niska	mała	wysoki	0,62
122	średni	średni	średni	niska	średnia	niski	1,35

Numer reguły	Prognozowany popyt $p(t)$	Poziom zapasów $z_t$	Czas dostawy $L_t$	Jakość dostawy $r_t$	Akt. wielkość zamówienia $q_t^*$	Akt. poziom zamawiania $rop_t^*$	Waga reguły $w_i^R$
123	średni	średni	średni	niska	duża	średni	1,31
124	średni	średni	średni	niska	duża	wysoki	0,31
125	średni	średni	średni	średnia	średnia	niski	1,09
126	średni	średni	średni	wysoka	mała	wysoki	0,30
127	średni	średni	średni	wysoka	średnia	niski	1,95
128	średni	średni	średni	wysoka	średnia	średni	2,11
129	średni	średni	średni	wysoka	średnia	wysoki	0,66
130	średni	średni	długi	niska	mała	niski	0,33
131	średni	średni	długi	niska	średnia	niski	0,75
132	średni	średni	długi	niska	duża	wysoki	0,66
133	średni	średni	długi	średnia	mała	niski	0,56
134	średni	średni	długi	średnia	duża	średni	1,61
135	średni	średni	długi	średnia	duża	wysoki	1,00
136	średni	średni	długi	wysoka	średnia	niski	0,49
137	średni	średni	długi	wysoka	duża	średni	0,93
138	średni	wysoki	krótki	niska	duża	niski	1,94
139	średni	wysoki	krótki	niska	duża	wysoki	0,44
140	średni	wysoki	krótki	średnia	mała	wysoki	0,74
141	średni	wysoki	krótki	średnia	średnia	wysoki	0,54
142	średni	wysoki	krótki	średnia	duża	wysoki	0,31
143	średni	wysoki	krótki	wysoka	mała	średni	1,37
144	średni	wysoki	krótki	wysoka	średnia	wysoki	0,28
145	średni	wysoki	średni	niska	mała	średni	2,68
146	średni	wysoki	średni	niska	średnia	średni	0,58
147	średni	wysoki	średni	niska	duża	niski	0,54
148	średni	wysoki	średni	średnia	mała	średni	1,81
149	średni	wysoki	średni	średnia	mała	wysoki	0,63
150	średni	wysoki	średni	wysoka	mała	wysoki	0,09
151	średni	wysoki	średni	wysoka	średnia	niski	1,92
152	średni	wysoki	średni	wysoka	średnia	średni	1,61
153	średni	wysoki	średni	wysoka	duża	wysoki	1,29
154	średni	wysoki	długi	niska	mała	niski	2,54
155	średni	wysoki	długi	niska	mała	średni	3,39
156	średni	wysoki	długi	niska	mała	wysoki	0,40
157	średni	wysoki	długi	niska	średnia	średni	0,98
158	średni	wysoki	długi	średnia	mała	wysoki	1,22
159	średni	wysoki	długi	średnia	średnia	niski	1,96
160	średni	wysoki	długi	średnia	średnia	wysoki	1,32
161	średni	wysoki	długi	średnia	duża	niski	1,34
162	średni	wysoki	długi	średnia	duża	średni	0,77
163	średni	wysoki	długi	wysoka	mała	wysoki	0,44
164	średni	wysoki	długi	wysoka	duża	niski	0,69

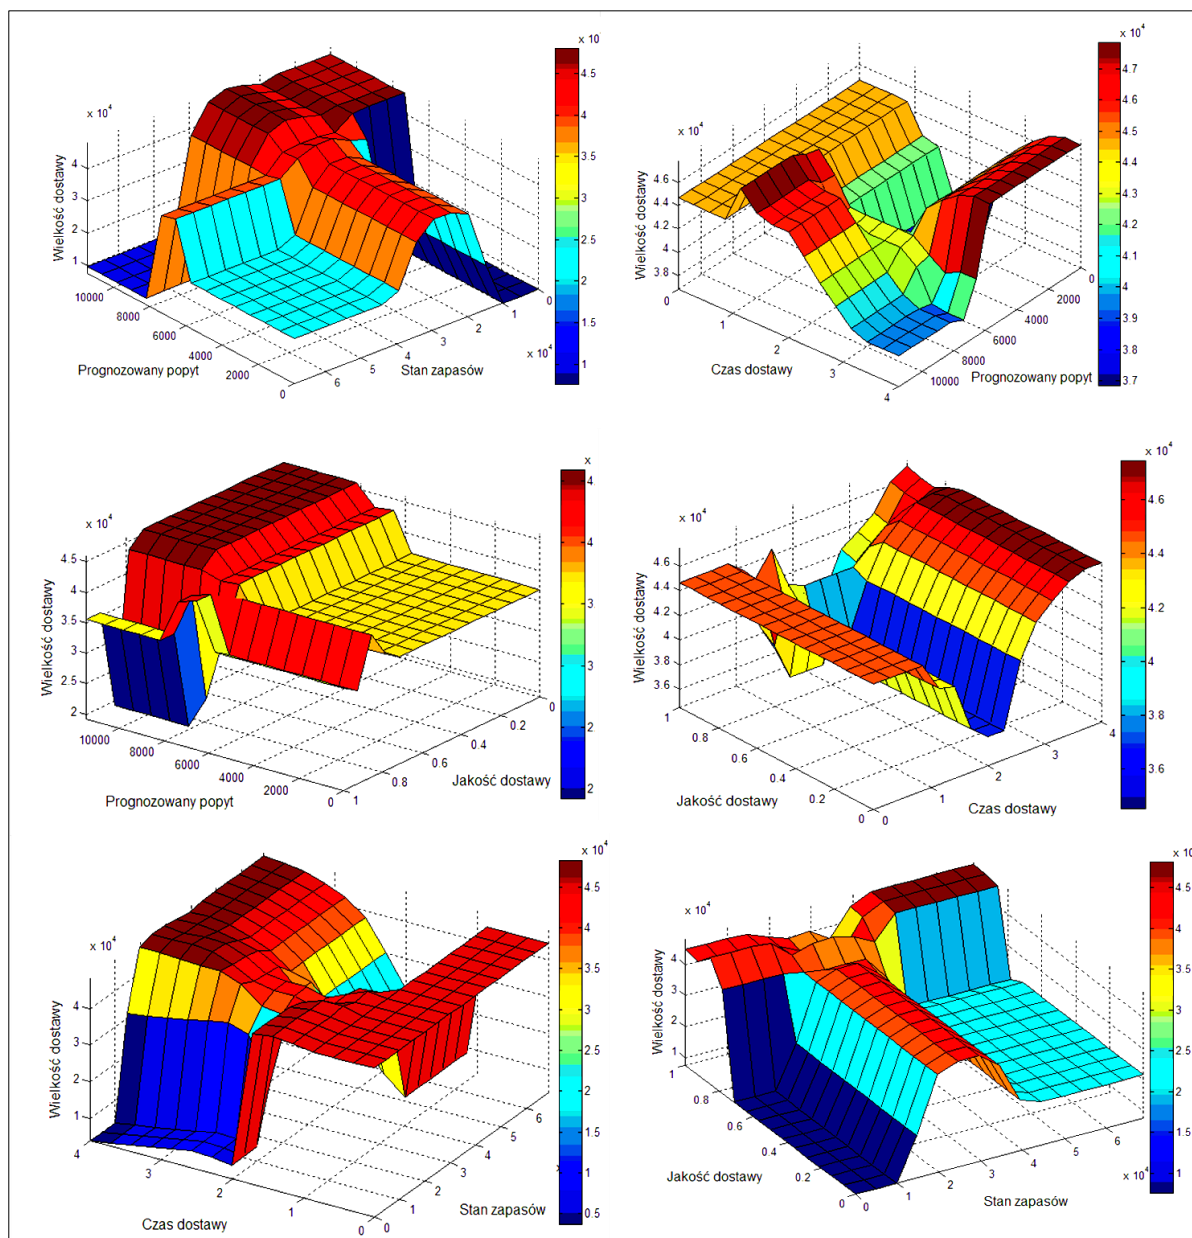
Numer reguły	Prognozowany popyt $p(t)$	Poziom zapasów $z_t$	Czas dostawy $L_t$	Jakość dostawy $r_t$	Akt. wielkość zamówienia $q_t^*$	Akt. poziom zamawiania $rop_t^*$	Waga reguły $w_i^R$
165	duży	mały	krótki	niska	średnia	wysoki	1,26
166	duży	mały	krótki	niska	duża	wysoki	0,41
167	duży	mały	krótki	średnia	mała	niski	1,07
168	duży	mały	krótki	średnia	mała	wysoki	3,38
169	duży	mały	krótki	średnia	średnia	wysoki	0,77
170	duży	mały	krótki	wysoka	mała	niski	0,96
171	duży	mały	krótki	wysoka	mała	wysoki	1,22
172	duży	mały	krótki	wysoka	średnia	niski	1,40
173	duży	mały	krótki	wysoka	średnia	wysoki	0,21
174	duży	mały	krótki	wysoka	duża	niski	0,95
175	duży	mały	średni	niska	mała	średni	0,93
176	duży	mały	średni	niska	średnia	wysoki	0,55
177	duży	mały	średni	niska	duża	niski	1,30
178	duży	mały	średni	średnia	średnia	niski	0,84
179	duży	mały	średni	wysoka	mała	średni	0,48
180	duży	mały	średni	wysoka	średnia	niski	1,84
181	duży	mały	średni	wysoka	średnia	wysoki	1,39
182	duży	mały	średni	wysoka	duża	niski	1,59
183	duży	mały	długi	niska	mała	średni	1,15
184	duży	mały	długi	niska	średnia	niski	1,52
185	duży	mały	długi	niska	duża	średni	2,09
186	duży	mały	długi	średnia	mała	średni	0,41
187	duży	mały	długi	średnia	średnia	niski	0,20
188	duży	mały	długi	średnia	duża	niski	0,14
189	duży	mały	długi	wysoka	mała	niski	0,61
190	duży	mały	długi	wysoka	średnia	średni	1,36
191	duży	średni	krótki	niska	mała	niski	0,01
192	duży	średni	krótki	niska	średnia	niski	0,82
193	duży	średni	krótki	niska	duża	niski	1,09
194	duży	średni	krótki	średnia	mała	średni	2,20
195	duży	średni	krótki	średnia	duża	niski	0,52
196	duży	średni	krótki	średnia	duża	wysoki	1,18
197	duży	średni	krótki	wysoka	mała	niski	0,43
198	duży	średni	krótki	wysoka	średnia	niski	1,34
199	duży	średni	krótki	wysoka	średnia	wysoki	0,37
200	duży	średni	średni	niska	średnia	niski	0,12
201	duży	średni	średni	niska	średnia	średni	1,94
202	duży	średni	średni	niska	duża	niski	1,06
203	duży	średni	średni	średnia	mała	niski	1,24
204	duży	średni	średni	średnia	mała	średni	0,09
205	duży	średni	średni	średnia	średnia	niski	0,82
206	duży	średni	średni	średnia	średnia	wysoki	0,25

Numer reguły	Prognozowany popyt $p(t)$	Poziom zapasów $z_t$	Czas dostawy $L_t$	Jakość dostawy $r_t$	Akt. wielkość zamówienia $q_t^*$	Akt. poziom zamawiania $rop_t^*$	Waga reguły $w_i^R$
207	duży	średni	średni	wysoka	mała	średni	2,83
208	duży	średni	długi	niska	mała	średni	0,58
209	duży	średni	długi	niska	średnia	średni	1,07
210	duży	średni	długi	niska	duża	niski	0,79
211	duży	średni	długi	niska	duża	wysoki	0,31
212	duży	średni	długi	średnia	mała	średni	0,31
213	duży	średni	długi	średnia	duża	wysoki	0,46
214	duży	wysoki	krótki	niska	średnia	niski	0,50
215	duży	wysoki	krótki	niska	średnia	wysoki	0,45
216	duży	wysoki	krótki	niska	duża	niski	1,13
217	duży	wysoki	krótki	średnia	średnia	niski	0,89
218	duży	wysoki	krótki	średnia	duża	niski	0,66
219	duży	wysoki	krótki	średnia	duża	średni	0,71
220	duży	wysoki	krótki	średnia	duża	wysoki	1,22
221	duży	wysoki	krótki	wysoka	mała	średni	0,10
222	duży	wysoki	krótki	wysoka	mała	wysoki	0,49
223	duży	wysoki	krótki	wysoka	średnia	wysoki	0,97
224	duży	wysoki	krótki	wysoka	duża	niski	1,16
225	duży	wysoki	krótki	wysoka	duża	średni	0,83
226	duży	wysoki	średni	niska	średnia	niski	0,82
227	duży	wysoki	średni	średnia	mała	wysoki	0,47
228	duży	wysoki	średni	wysoka	średnia	niski	1,88
229	duży	wysoki	średni	wysoka	duża	średni	0,57
230	duży	wysoki	długi	niska	mała	niski	2,20
231	duży	wysoki	długi	niska	średnia	niski	1,22
232	duży	wysoki	długi	niska	średnia	wysoki	0,70
233	duży	wysoki	długi	średnia	mała	niski	0,66
234	duży	wysoki	długi	średnia	średnia	średni	0,89
235	duży	wysoki	długi	wysoka	duża	średni	0,68

Aby graficznie określić wzajemną zależność pomiędzy poszczególnymi zmiennymi wejściowymi systemu a wyjściowymi zmiennymi sterowania dla tak wyznaczonej powyżej bazy reguł rozmytych, sporządzono w tym celu odpowiednie wykresy powierzchniowe dla pojedynczego zestawu danych. rys. 61. przedstawia w jaki sposób dowolnie dobrane pary wejść systemu wpływają na wielkość dostawy. Na podstawie wykresu można stwierdzić, iż dowolnie wybrane pary zmiennych wejściowych w znaczny sposób oddziałują na wielkość dostawy. W pewnych przypadkach niewielki wzrost lub spadek wartości jednego z parametrów wejściowych powoduje wręcz gwałtowną zmianę parametru wielkości dostawy. Jednakże można zaobserwować również obszary w których zmiana wartości wejściowych nawet w znaczącym zakresie powoduje znikomą tylko zmianę wartości parametru wyjściowego (przykładowo zależności:  $q_t^*(p(t), z(t))$ ;  $q_t^*(p(t), r_t)$ ;  $q_t^*(r_t, z(t))$ ). Sytuacje

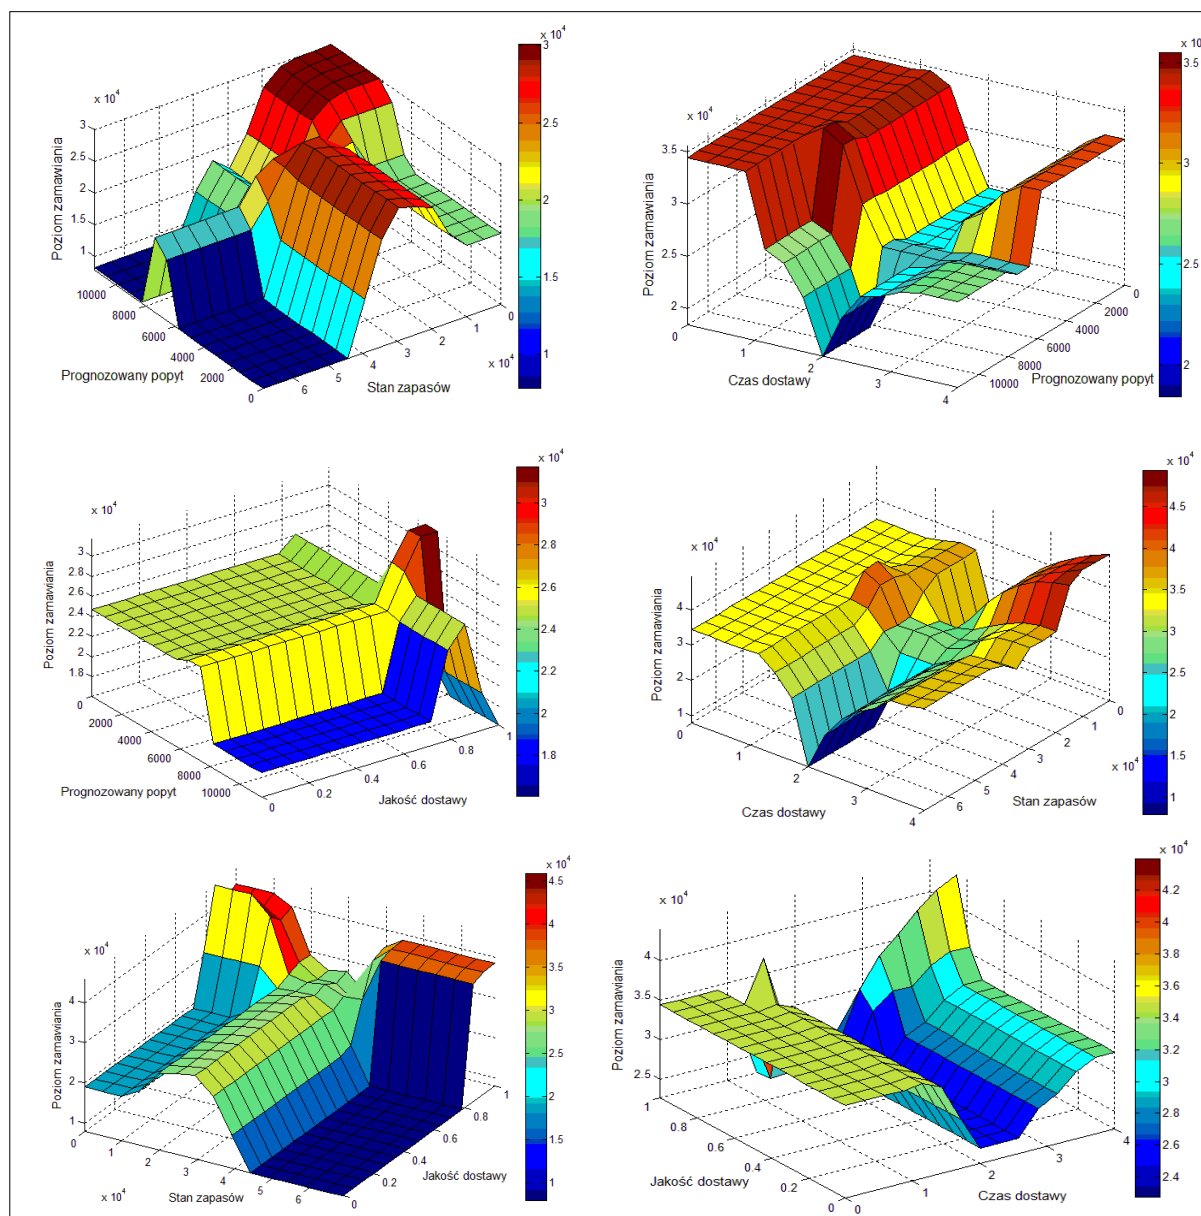
takie mogą być powodem tego, iż optymalizacja reguł rozmytej bazy wiedzy odbywała się w oparciu o minimalizację jednocześnie trzech kryteriów, które się wykluczają. Dzięki takiemu procesowi optymalizacji bazy reguł, system nabywa cechy odporności na wahające się parametry w pewnych zakresach zmienności. Podobna analiza została przeprowadzona dla drugiej zmiennej wyjściowej (poziom ponownego zamawiania  $rop_t^*$ ), przedstawia to rys.62. W tym wypadku również można dostrzec obszary na poszczególnych wykresach, gdzie zmiany wartości zmiennych wejściowych w pewnych zakresach w niewielkim stopniu wpływają na drugą zmienną wyjściową (poziom ponownego zamawiania  $rop_t^*$ ). Z analizy wykresów na rys. 62 można zaobserwować, że stabilność czasu dostawy (czas realizacji dostawy równy wartości średniej, w rozważanym przypadku  $\bar{L} = 2$ ) silnie wpływa na wielkość poziomu zamawiania. Kiedy czas dostawy jest równy  $\bar{L}$  poziom zamawiania jest najniższy. Dostrzec można także silną zależność poziomu zamawiania od wielkości prognozowanego popytu i aktualnego stanu zapasów. Niski stan zapasów, przy wysokim prognozowanym popycie skutkuje dynamicznym wzrostem poziomu zamawiania. Uwidacznia się także znacząca zależność poziomu zamawiania od stanu zapasu  $z_t$  i jakości dostawy  $r_t$ . Jeśli dostępność produktu u dostawcy jest wysoka i stan zapasu jest poniżej przeciętnego to poziom ponownego zamawiania szybko wzrasta. Wymusza to na systemie zapasów pewien rodzaj działań antycypacyjnych, mających na celu uniknięcie sytuacji braku towaru.





**Rys. 61.** Wpływ par zmiennych wejściowych systemu na wielkość dostawy


*Źródło: opracowanie własne*



**Rys. 62.** Wpływ par zmiennych wejściowych systemu na poziom ponownego zamawiania  
*Źródło: opracowanie własne*

Wyznaczone w ten sposób zależności zmiennych wyjściowych od zmiennych wejściowych systemu dostarczają cennych informacji o zachowaniu się norm sterowania w różnych warunkach. Dzięki temu możliwe jest określenie wartości parametrów wejściowych, które w największym stopniu mogą przyczynić się do generacji sytuacji niepożądanych dla systemu zapasów, które w konsekwencji mogą go destabilizować.

Przeprowadzenie procesu aktualizacji wag bazy reguł każdorazowo w każdym wariantcie symulacji pozwoliło określić, jak zakres zmienności parametrów  $L_t$  oraz  $r_t$  wpływa na optymalizowaną przez algorytm genetyczny bazę reguł rozmytych. Uśrednione wartości wag dla najistotniejszej grupy 235 reguł w zależności od analizowanego scenariusza przedstawia rys. 63.



**Rys. 63.** Zmienność wartości wag reguł w zależności od analizowanego wariantu  
*Źródło: opracowanie własne*

Na podstawie wykresu (rys.63.) można zauważyć, iż wartości wag dla tych samych reguł wyraźnie się zmieniają w zależności od rozważanego scenariusza. W jednym przypadku określona reguła może odgrywać niewielką rolę w wyznaczaniu wartości zmiennych wyjściowych systemu, natomiast już w innej sytuacji ta sama reguła może posiadać kilkakrotnie wyższą wagę (obecne na wykresie szczyty i wzniesienia). Widoczne na wykresie wyraźne zróżnicowanie wag w poszczególnych scenariuszach umożliwia systemowi elastyczną adaptację do określonych warunków, kształtowanych przez zmienność parametrów. Dodatkowo wykonywana aktualizacja bazy wiedzy indywidualnie dla każdego typu produktu uwzględnia jego swoistą charakterystykę. Liczbowe wartości uśrednionych wag reguł w poszczególnych wariantach, spośród wszystkich 25 produktów zostały przedstawione w Załączniku B w Tabelach. B. 1-5. Aby potwierdzić iż, nie tylko pojedyncze reguły posiadają zmienioną wagę, lecz większa część wag w zbiorze reguł ulega modyfikacji i aktualizacji w zależności od rodzaju produktu i scenariusza, wyznaczono ich odchylenia standardowe w kolejnych scenariuszach. Wartości kwartyli populacji odchyłeń standardowych dla wag ze zbioru reguł przedstawia Tabela. 11.

**Tabela 11.** Struktura wartości odchyłeń standardowych w populacji wag reguł rozmytych

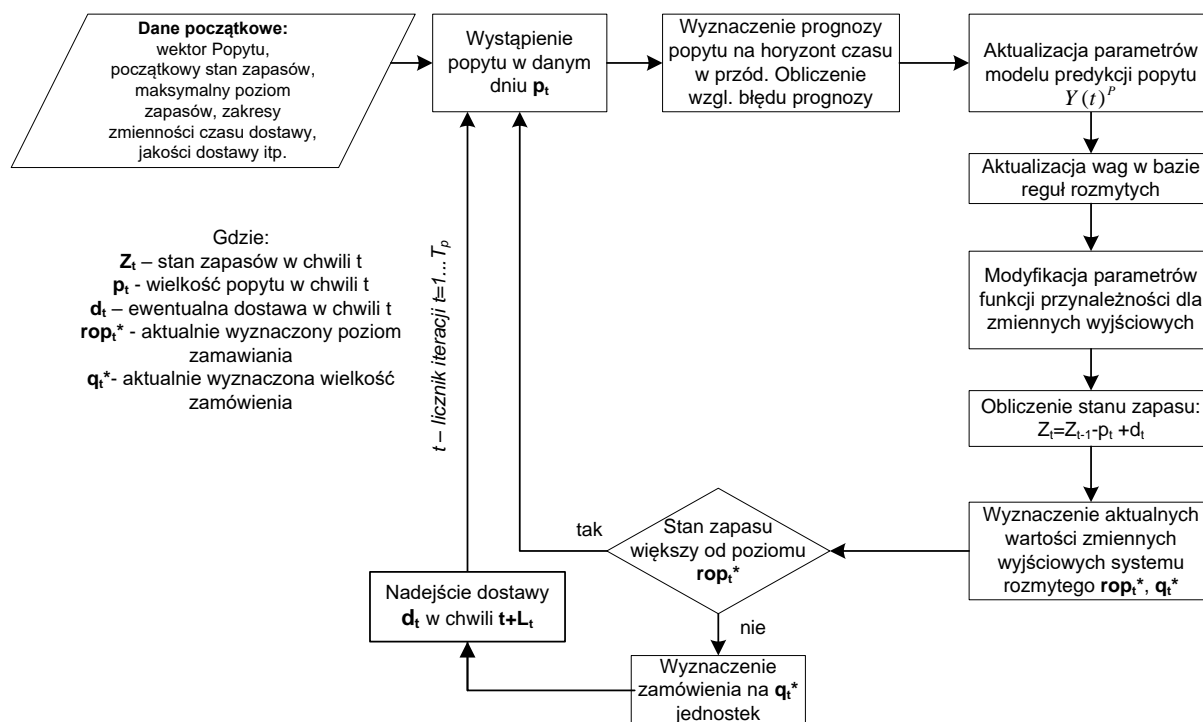
	min	kwartył Q <sub>0.25</sub>	kwartył Q <sub>0.5</sub>	kwartył Q <sub>0.75</sub>	max
Wartości odchyłeń standardowych w populacji wag reguł	0,21	0,69	0,91	1,11	2,10

## 5.2.2 Wyniki symulacji poziomu zapasów w proponowanej metodzie sterowania

Wykorzystując zoptymalizowaną bazę wiedzy, dedykowaną dla każdego produktu oraz wariantu zakresu zmienności wybranych czynników niepewnych, przeprowadzono symulację komputerową poziomu zapasów. Została ona wykonana dla wszystkich pozyskanych zestawów danych reprezentujących zapotrzebowanie na towar o różnym poziomie zmienności. Okres analizy obejmował jeden rok. Całość pliku symulacji wraz z wszystkimi założeniami metody została zaprogramowana w środowisku Matlab. Wstępne wyniki badań dla proponowanej metody zostały już opublikowane przez autora w pracy [148].


W związku z tym, że proponowana metoda sterowania należy do grupy metod o ciągłym przeglądzie poziomu zapasów, stan zapasu danego produktu był bieżąco monitorowany i aktualizowany w oparciu wartości zapotrzebowania oraz nadchodzące dostawy uzupełniające zapas. Każda iteracja w wykonywanej symulacji reprezentowała pojedynczy dzień z rozważanego okresu czasu. W każdym kroku symulacji wyznaczana była prognoza przyszłego zapotrzebowania na produkt na podstawie zbudowanego hybrydowego modelu predykcji  $Y(t)^P$ . Prognozy popytu budowane były na horyzont  $h$  kroków w przód, który był równy wartości dla środka przedziału zakresu zmienności czasu realizacji dostawy  $L_t$  w aktualnie rozważanym wariantcie symulacyjnym. Po realizacji prognozy w horyzoncie  $h$  parametry modelu predykcji ulegały ponownej aktualizacji. Ponadto w oparciu o wyznaczone na bieżąco błędy procentowe prognoz odbywała się aktualizacja parametrów funkcji przynależności w module rozmytym. Na podstawie tego wyznaczone były bieżące wartości norm sterowania systemu  $q_t^*$  oraz  $rop_t^*$ . Kolejne wartości czasów dostawy oraz parametru jakości dostawy generowane były odpowiednio z rozkładu równomiernego oraz normalnego. Dodatkowo przyjęto założenie, że w przypadku wystąpienia braku zapasu, nieobsłużone zapotrzebowanie jest tracone i ponoszony jest jednostkowy koszt braku zapasu równy  $k_b$ .

Otrzymane wyniki zostały ocenione pod względem czterech kryteriów: przeciętnego poziomu zapasów, liczby zaistniałych braków, procentowej wielkości nieobsłużonego popytu oraz przeciętnej liczby dostaw. Dla zapewnienia przejrzystości w analizie przeciętny poziom zapasów został wyrażony jako stosunek wielkości zapasu do jego maksymalnej dopuszczalnej wielkości. Uzyskane rezultaty zostały porównane z wynikami otrzymanymi przez klasyczną metodę poziomu zamawiania oraz połączony model cyklu i poziomu zamawiania, omówione w rozdziale drugim. Dokładny schemat poszczególnych etapów wykonywanej symulacji został przedstawiony na rys. 64.



**Rys. 64.** Schemat symulacji poziomu zapasów według proponowanego podejścia  
*Źródło: opracowanie własne*

Szczegółowe wyniki symulacji poziomu zapasów dla przykładowego zestawu danych nr 1 w przyjętym okresie analizy przedstawia rys. 65. W dalszej kolejności zostaną zaprezentowane zbiorcze wyniki dla pozostałych zestawów danych oraz zdefiniowanych wariantów symulacji. Dodatkowo aby zwiększyć wpływ losowości dla parametru czasu dostawy oraz jakości dostawy każda symulacja dla danego zestawu danych w każdym wariancie została przeprowadzona 25 razy a otrzymane rezultaty uśredniono.



**Rys. 65.** Symulacja poziomu zapasów w okresie 200 dni dla przykładowego zestawu danych  
*Źródło: opracowanie własne*

Na podstawie powyższego wykresu można dostrzec wyraźną zmienność i dynamikę wartości poziomu ponownego zamawiania. W sytuacji występowania prognoz zwiększonego zapotrzebowania produktu, dużego zużycia bieżącego zapasu oraz dłuższego czasu realizacji dostawy punkt ponownego zamawiania wzrasta. W trakcie analizowanego horyzontu czasowego w wielu przypadkach dostawy nadchodziły tuż przed całkowitym wyczerpaniem się zapasu. Dzięki temu w trakcie symulacji system dążył także do obniżenia zbędnych

zapasów w sposób, który w najmniejszym stopniu przekłada się na możliwość wystąpienia braku. Oczywiście należy pamiętać, iż otrzymane poszczególne wartości kryteriów mogą być dowolnie kreowane poprzez określony dobór priorytetów przez firmę, który jest odzwierciedlony w trakcie procesu optymalizacji bazy wiedzy w module rozmytym. Przedstawiony na wykresie przykład był rozważany dla wariantu 7. Otrzymane wyniki symulacji dla kolejnych zestawów danych popytowych w rozróżnieniu na poszczególne scenariusze przedstawiają Tabele. 12 – 14. Z analizy rezultatów zawartych w tabelach wynika, iż w pierwszych pięciu wariantach, które kolejno przedstawiają rosnący poziom zmienności czasu dostawy oraz parametru jakości dostawy, w wielu przypadkach spośród 25 rozważanych otrzymane wartości kryteriów są zdecydowanie niższe na korzyść proponowanej metody rozmytej w porównaniu do połączonego modelu poziomu i cyklu zamawiania. Przewaga na korzyść prezentowanego podejścia jest szczególnie zauważalna w zestawach danych od 11 – do 25, dla których współczynniki zmienności popytu wzrastają od wartości 0.6 do 0.97. W tym wypadku uwidacznia się wpływ wysokiej dokładności prognoz wygenerowanych przez moduł predykcji. W porównaniu do klasycznego modelu poziomu zamawiania prezentowana metoda uzyskała nieco gorsze rezultaty w odniesieniu do minimalizacji poziomu zapasów, jednakże osiągnęła zdecydowaną przewagę w przypadku kryterium liczby braków w zapasie, nieobsłużonego popytu czy też liczby dostaw pomimo wysokiego współczynnika bezpieczeństwa  $k=1,7$  jaki został przyjęty dla tej metody oraz połączonego modelu cyklu i poziomu zamawiania.



**Tabela 12.** Wyniki symulacji poziomu zapasów dla 25 zestawów danych oraz wariantów 1-3

Wariant	Metoda	Nr Zestawu danych	Z1	Z2	Z3	Z4	Z5	Z6	Z7	Z8	Z9	Z10	Z11	Z12	Z13	Z14	Z15	Z16	Z17	Z18	Z19	Z20	Z21	Z22	Z23	Z24	Z25	
Wariant 1	Proponowana metoda	Przeciętny poziom zapasów [%]	41,9	38,7	38,5	40,8	40,3	35,3	41,3	35,2	36,4	42,3	58,1	53,3	62,2	57,0	44,5	60,7	55,3	69,8	54,3	57,3	55,5	58,9	56,4	53,1	49,4	
		Średnia liczba braków	0,0	0,0	0,3	1,3	0,7	1,0	1,7	2,0	1,0	2,3	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	2,8	0,0
		Popyt nieobsłużony [%]	0,0	0,0	0,2	0,5	0,1	0,3	0,5	0,4	0,3	0,7	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,1	0,0
		Średnia liczba dostaw	37,3	42,7	42,3	46,7	48,0	47,3	45,7	48,0	45,7	43,7	15,0	20,0	7,3	17,3	5,3	4,0	19,0	4,3	23,3	19,7	20,3	10,7	9,7	49,3	34,0	
	Połączony model poziomu i cyklu zamawiania	Przeciętny poziom zapasów [%]	53,7	51,9	53,5	55,2	53,8	53,4	54,5	52,0	53,6	54,4	53,6	48,7	59,7	53,0	60,6	62,7	50,2	67,8	54,5	55,5	59,2	62,4	61,6	56,4	55,5	
		Średnia liczba braków	3,3	4,9	3,9	3,0	2,3	4,0	2,6	1,5	4,2	4,1	1,7	1,1	0,0	1,9	0,0	0,0	3,0	0,8	3,0	3,2	4,3	0,9	2,1	8,3	4,0	
		Popyt nieobsłużony [%]	1,0	1,8	1,5	1,1	0,7	1,3	0,8	0,4	1,2	1,8	0,5	0,5	0,0	1,0	0,0	0,0	1,7	0,8	1,1	1,7	3,3	0,4	1,7	3,9	1,7	
		Średnia liczba dostaw	55,5	56,5	58,0	61,3	95,2	61,1	66,3	126,1	58,5	72,1	19,2	19,0	11,5	21,3	8,3	8,5	20,6	10,2	27,1	26,0	21,9	14,2	14,2	43,4	25,9	
	Klasyfikacja modelu poziomu zamawiania	Przeciętny poziom zapasów [%]	43,2	43,9	42,3	40,1	28,8	40,7	36,8	29,6	41,8	32,6	30,4	27,9	27,2	31,2	38,2	39,6	30,4	40,1	35,7	37,1	34,8	32,3	34,1	57,7	36,1	
		Średnia liczba braków	0,9	0,6	2,8	4,3	55,7	1,4	7,2	43,5	1,4	17,1	0,6	0,5	0,3	1,7	0,3	0,8	1,5	1,1	0,8	2,6	3,2	1,8	1,3	5,3	2,7	
		Popyt nieobsłużony [%]	0,3	0,1	1,0	1,7	19,8	0,3	2,8	38,6	0,3	8,0	0,2	0,1	0,1	0,8	0,1	0,3	0,6	0,5	0,2	1,6	2,8	0,7	0,9	2,4	1,2	
		Średnia liczba dostaw	50,0	49,0	51,5	55,5	76,5	54,7	59,3	77,9	52,6	62,9	16,7	16,5	8,7	18,1	4,8	5,4	17,7	6,5	22,7	21,8	18,7	11,2	11,3	31,2	21,9	
Wariant 2	Proponowana metoda	Przeciętny poziom zapasów [%]	45,7	42,0	39,8	39,2	36,2	36,4	42,1	38,1	40,3	43,2	56,2	49,3	60,1	54,7	64,9	63,6	54,9	66,2	54,5	55,7	50,4	58,1	57,4	56,7	40,5	
		Średnia liczba braków	0,3	0,3	1,0	2,7	3,3	2,0	2,7	3,0	0,3	4,3	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	4,2	0,0	
		Popyt nieobsłużony [%]	0,0	0,0	0,4	0,9	1,0	0,4	0,6	0,5	0,0	1,6	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,3	0,0	
		Średnia liczba dostaw	39,7	43,7	45,0	49,0	49,0	50,0	48,0	49,7	47,7	48,0	14,7	20,0	6,7	18,3	4,3	4,3	16,0	3,7	22,0	19,0	21,3	9,7	12,0	51,0	35,3	
	Połączony model poziomu i cyklu zamawiania	Przeciętny poziom zapasów [%]	52,2	51,3	53,4	53,7	53,2	52,2	51,8	51,0	53,0	54,5	52,4	49,1	57,7	51,7	60,6	62,7	49,7	67,5	52,7	55,4	59,7	62,0	61,2	56,1	54,1	
		Średnia liczba braków	4,3	4,2	4,0	3,2	1,9	4,8	4,3	2,3	3,7	4,3	2,0	1,3	0,0	1,9	0,0	0,0	3,6	0,5	3,3	3,0	4,0	0,8	1,5	8,0	3,9	
		Popyt nieobsłużony [%]	1,3	1,3	1,3	1,1	0,6	1,7	1,4	0,5	1,0	1,7	0,6	0,5	0,0	0,8	0,0	0,0	2,1	0,5	1,3	1,8	3,2	0,3	1,0	4,4	2,0	
		Średnia liczba dostaw	56,5	57,3	58,8	62,3	96,2	63,0	67,1	126,7	59,5	72,8	19,5	19,0	11,7	21,5	8,3	8,5	20,8	10,2	27,6	26,3	22,2	14,2	14,2	43,7	26,4	
	Klasyfikacja modelu poziomu zamawiania	Przeciętny poziom zapasów [%]	41,4	41,5	41,0	38,3	28,3	37,9	35,5	20,4	39,2	32,0	29,8	27,6	27,2	31,3	38,0	39,7	30,3	40,1	35,6	36,0	34,6	32,4	34,3	55,5	35,4	
		Średnia liczba braków	2,5	2,1	4,3	6,5	63,5	4,0	9,5	48,1	4,5	19,8	0,4	0,5	0,4	1,5	0,4	0,3	1,5	1,3	1,0	3,2	3,3	2,2	2,0	6,8	3,5	
		Popyt nieobsłużony [%]	0,9	0,6	1,8	2,8	23,3	1,1	3,8	42,2	1,4	9,4	0,1	0,2	0,1	0,5	0,2	0,1	0,4	0,6	0,3	2,1	2,6	1,1	1,2	3,3	1,6	
		Średnia liczba dostaw	52,2	51,9	53,4	57,6	76,7	58,0	61,3	76,5	55,4	64,8	17,6	17,6	9,2	19,4	5,1	5,7	18,8	6,9	23,8	23,3	20,0	11,5	11,6	33,2	23,2	
Wariant 3	Proponowana metoda	Przeciętny poziom zapasów [%]	48,7	48,1	46,3	43,3	40,7	43,1	45,4	42,7	42,1	41,5	60,3	54,0	61,3	58,8	66,8	68,1	57,6	60,1	57,0	58,8	54,8	60,1	61,9	60,1	47,5	
		Średnia liczba braków	0,3	0,0	1,3	1,0	1,3	1,3	2,0	1,0	1,7	6,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	6,6	0,0	
		Popyt nieobsłużony [%]	0,0	0,0	0,1	0,4	0,4	0,5	0,7	0,2	0,2	3,1	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1,8	0,0	
		Średnia liczba dostaw	37,7	42,3	40,7	48,0	48,0	46,0	47,0	45,7	44,0	14,0	18,7	7,3	17,3	3,7	3,7	17,3	4,0	20,3	19,7	19,3	10,3	11,0	47,0	32,3		
	Połączony model poziomu i cyklu zamawiania	Przeciętny poziom zapasów [%]	58,8	55,7	58,2	58,2	56,6	57,3	56,7	54,3	58,0	58,4	55,1	50,6	59,5	54,1	60,3	62,5	51,6	67,7	56,5	56,5	59,5	62,6	61,3	57,5	54,3	
		Średnia liczba braków	1,8	2,4	2,5	2,2	1,3	2,6	2,1	0,7	2,3	3,0	1,1	0,8	0,1	1,1	0,0	0,0	1,8	0,9	1,9	2,6	3,4	0,3	1,4	9,0	3,8	
		Popyt nieobsłużony [%]	0,6	0,8	1,0	0,8	0,4	0,8	0,9	0,2	0,6	1,1	0,4	0,3	0,0	0,5	0,0	0,0	1,0	0,9	0,7	1,6	2,9	0,2	1,2	4,6	2,0	
		Średnia liczba dostaw	57,8	59,1	60,0	63,8	97,9	63,8	68,5	128,8	60,5	74,9	19,7	19,3	11,5	21,8	8,3	8,5	20,9	10,2	27,6	26,5	22,2	14,2	14,2	47,7	26,3	
	Klasyfikacja modelu poziomu zamawiania	Przeciętny poziom zapasów [%]	46,2	46,1	45,1	41,3	25,4	40,8	36,3	20,0	44,4	32,3	32,1	29,3	27,5	32,7	38,3	39,9	32,2	40,4	39,0	39,4	36,7	33,0	35,0	61,4	38,8	
		Średnia liczba braków	2,6	2,0	6,5	8,2	79,7	6,0	17,2	53,0	4,5	29,0	0,4	0,4	0,5	1,9	0,2	0,8	1,7	0,9	0,6	3,0	3,5	1,6	1,3	6,2	2,8	
		Popyt nieobsłużony [%]	0,9	0,6	3,2	3,6	31,4	2,1	7,5	47,4	1,5	14,1	0,1	0,1	0,1	0,8	0,1	0,2	0,9	0,4	0,1	2,3	2,7	0,6	0,8	2,8	1,1	
		Średnia liczba dostaw	49,3	48,6	50,8	54,8	64,8	53,7	56,0	65,5	51,3	58,0	17,0	16,8	8,8	18,6	5,0	5,2	17,8	6,5	22,6	21,7	19,2	11,3	11,1	32,3	22,0	



**Tabela 13.** Wyniki symulacji poziomu zapasów dla 25 zestawów danych oraz wariantów 4-6

Wariant	Metoda	Nr Zestawu danych	Z1	Z2	Z3	Z4	Z5	Z6	Z7	Z8	Z9	Z10	Z11	Z12	Z13	Z14	Z15	Z16	Z17	Z18	Z19	Z20	Z21	Z22	Z23	Z24	Z25	
Wariant 4	Proponowana metoda	Przeciętny poziom zapasów [%]	45,5	43,0	43,9	40,2	42,6	38,4	41,5	38,1	39,9	41,8	57,7	50,6	60,0	54,6	56,2	66,1	48,0	68,2	52,2	56,4	53,2	56,3	57,2	61,1	44,5	
		Średnia liczba braków	1,0	0,3	2,3	3,7	2,3	4,0	0,3	4,0	4,0	5,7	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	6,8	0,0
		Popyt nieobsłużony [%]	0,1	0,0	0,6	1,3	0,7	1,2	0,2	1,0	1,3	3,5	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1,9	0,0
		Średnia liczba dostaw	38,4	43,4	42,4	47,9	48,1	48,6	45,1	48,3	47,6	45,0	15,4	18,7	7,1	18,4	4,0	4,8	17,9	4,8	22,6	20,1	21,2	11,2	10,1	48,1	32,7	
	Połączony model poziomu i cyklu zamawiania	Przeciętny poziom zapasów [%]	57,2	55,1	56,6	58,5	57,2	56,1	56,1	54,2	57,1	58,2	55,2	49,6	54,6	54,0	60,3	62,5	51,2	67,3	54,3	55,9	58,5	62,4	61,6	57,4	54,3	
		Średnia liczba braków	2,4	3,1	3,1	2,0	1,3	3,2	2,8	0,7	2,7	3,3	1,3	0,6	0,3	1,4	0,0	0,0	1,8	1,0	2,5	3,2	4,0	0,7	1,3	9,7	4,2	
		Popyt nieobsłużony [%]	0,7	1,0	1,3	0,6	0,3	0,9	1,0	0,2	0,7	1,3	0,4	0,2	0,0	0,7	0,0	0,0	1,0	1,1	0,9	1,7	3,4	0,4	1,0	5,5	2,3	
		Średnia liczba dostaw	58,7	59,8	61,5	65,0	98,4	65,1	69,2	129,8	61,7	75,1	19,7	19,5	11,7	21,7	8,3	8,5	21,3	10,2	28,0	26,6	22,5	14,2	14,3	48,4	26,5	
	Klasyfikacja modelu poziomu i zamawiania	Przeciętny poziom zapasów [%]	42,8	43,6	40,8	38,4	23,8	35,8	31,5	21,0	40,1	29,6	31,7	28,9	27,7	33,2	38,1	39,8	32,3	40,3	38,2	38,9	36,9	32,7	34,7	59,2	39,0	
		Średnia liczba braków	5,2	4,7	10,7	12,8	89,3	12,8	22,6	55,3	9,5	35,3	0,8	0,8	0,5	1,7	0,4	0,5	2,1	1,5	1,0	2,7	4,1	2,3	2,5	9,2	3,5	
		Popyt nieobsłużony [%]	1,9	1,6	4,9	5,9	35,7	4,5	9,7	49,5	3,4	17,7	0,3	0,2	0,2	0,7	0,1	0,2	1,1	0,9	0,3	2,0	3,4	1,0	1,5	5,0	1,5	
		Średnia liczba dostaw	51,6	50,6	52,6	55,9	64,3	55,3	58,3	65,8	53,7	58,6	17,6	17,6	9,3	18,8	5,2	5,9	18,4	6,7	24,3	23,2	19,8	12,0	11,6	33,2	22,8	
Wariant 5	Proponowana metoda	Przeciętny poziom zapasów [%]	46,8	42,1	39,1	38,9	35,5	38,2	40,5	35,1	37,3	41,9	56,3	49,3	58,6	54,9	55,5	64,8	57,3	64,2	53,1	49,9	53,1	55,9	59,8	60,5	42,3	
		Średnia liczba braków	2,0	2,0	3,0	4,3	7,7	6,7	5,0	8,0	6,0	5,3	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	7,2	4,7	
		Popyt nieobsłużony [%]	2,1	1,2	1,9	2,6	2,8	2,2	2,2	3,0	2,2	3,1	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1,7	0,3	
		Średnia liczba dostaw	35,3	40,3	39,3	45,0	45,0	45,3	40,7	45,0	42,3	41,7	16,0	19,3	6,7	17,0	3,7	3,7	16,0	5,3	22,0	21,0	20,7	10,3	9,3	41,8	31,4	
	Połączony model poziomu i cyklu zamawiania	Przeciętny poziom zapasów [%]	57,3	54,7	56,6	57,7	53,6	55,7	55,8	53,1	55,6	57,1	54,4	50,1	59,0	53,8	60,3	62,2	50,8	67,1	54,8	56,4	59,5	62,3	60,9	56,5	54,9	
		Średnia liczba braków	2,5	4,0	4,0	3,5	1,7	3,5	4,1	1,1	4,3	4,2	1,8	2,0	0,3	1,8	0,0	0,0	3,1	1,4	3,9	3,2	4,7	0,6	2,4	11,8	4,4	
		Popyt nieobsłużony [%]	0,9	1,4	1,7	1,4	0,5	1,2	1,7	0,3	1,4	1,6	0,5	0,8	0,1	0,7	0,0	0,0	2,2	1,4	1,6	1,9	4,2	0,3	1,9	7,0	2,1	
		Średnia liczba dostaw	57,9	58,5	59,9	63,8	98,4	64,0	68,3	129,0	60,4	74,7	19,7	19,3	11,5	21,7	8,3	8,5	20,8	10,2	27,5	26,4	21,9	14,1	14,2	47,1	26,2	
	Klasyfikacja modelu poziomu i zamawiania	Przeciętny poziom zapasów [%]	37,6	37,2	36,2	32,1	21,9	32,3	28,3	20,6	34,7	24,9	30,8	28,0	27,1	31,6	38,1	39,6	30,9	39,8	36,5	37,7	35,6	32,3	33,9	57,1	36,8	
		Średnia liczba braków	10,9	10,8	15,2	21,5	97,8	19,2	30,5	60,8	15,5	43,0	1,9	1,7	1,2	3,0	0,8	1,5	3,7	3,3	3,1	4,0	5,0	2,9	3,3	10,4	6,3	
		Popyt nieobsłużony [%]	4,0	3,6	6,8	9,4	41,1	6,9	13,2	54,7	5,5	21,5	0,7	0,7	0,4	1,2	0,3	0,7	1,8	2,0	1,0	3,0	4,1	1,3	2,2	5,5	3,0	
		Średnia liczba dostaw	47,8	47,4	48,1	51,1	55,1	50,6	52,5	55,8	49,7	52,8	16,6	16,6	8,8	18,3	5,1	5,3	17,5	6,5	22,4	21,5	18,6	11,1	11,3	30,9	21,7	
Wariant 6	Proponowana metoda	Przeciętny poziom zapasów [%]	43,1	43,0	41,1	35,1	34,8	36,7	39,2	36,3	41,3	40,4	55,3	53,8	49,1	53,5	61,5	65,0	56,3	63,9	52,7	56,6	52,8	58,5	62,2	58,9	43,5	
		Średnia liczba braków	3,3	2,0	5,0	7,7	10,0	9,7	5,0	7,3	5,0	7,7	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	10,2	1,7	
		Popyt nieobsłużony [%]	1,3	0,7	2,2	3,2	5,2	3,9	2,8	2,8	2,0	5,1	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	2,1	0,9	
		Średnia liczba dostaw	38,7	40,0	41,0	44,3	45,3	45,7	44,7	46,0	44,0	41,7	16,3	18,0	8,0	20,0	3,7	4,7	17,3	4,0	22,7	20,3	20,3	11,0	10,0	43,7	30,9	
	Połączony model poziomu i cyklu zamawiania	Przeciętny poziom zapasów [%]	56,1	53,2	56,0	56,8	53,6	54,0	54,3	51,7	55,3	56,9	53,9	49,4	54,8	53,5	60,2	62,2	51,2	66,6	53,4	55,2	58,7	62,6	60,6	55,3	53,7	
		Średnia liczba braków	3,5	4,8	4,1	4,0	1,7	3,8	3,8	2,3	4,0	4,3	2,3	2,0	0,7	2,7	0,0	0,0	2,6	2,0	4,3	4,4	4,8	0,9	1,5	12,4	5,2	
		Popyt nieobsłużony [%]	1,1	1,6	2,0	1,7	0,4	1,2	1,4	0,6	1,3	1,7	0,8	0,8	0,2	1,1	0,0	0,0	1,6	2,0	1,9	3,1	3,6	0,3	1,1	7,3	2,6	
		Średnia liczba dostaw	58,6	59,7	60,9	64,3	98,8	65,1	69,4	129,3	61,4	75,7	19,7	19,4	11,7	21,8	8,3	8,5	21,1	10,2	27,8	26,7	22,3	14,1	14,3	47,5	26,6	
	Klasyfikacja modelu poziomu i zamawiania	Przeciętny poziom zapasów [%]	33,7	33,8	32,6	28,1	21,4	28,6	25,7	20,3	30,8	23,7	30,1	28,0	27,4	31,2	38,0	39,7	30,7	39,9	36,1	36,4	34,8	32,4	33,7	55,6	36,3	
		Średnia liczba braków	18,4	15,4	23,3	29,9	104,6	27,9	37,7	61,8	26,9	47,0	3,7	1,6	1,1	4,0	0,7	1,3	4,2	2,8	3,4	6,6	6,4	3,1	4,1	13,4	6,9	
		Popyt nieobsłużony [%]	7,1	5,5	10,0	13,6	44,0	10,5	16,7	57,1	10,5	23,3	1,4	0,5	0,4	2,0	0,3	0,7	1,9	1,6	1,4	4,6	5,0	1,5	2,6	7,8	3,4	
		Średnia liczba dostaw	48,8	49,6	48,9	51,5	54,9	51,8	52,8	55,4	49,5	54,2	17,5	17,2	9,0	19,0	5,3	5,4	18,4	7,0	24,2	22,6	19,3	11,9	12,1	32,3	22,5	

**Tabela 14.** Wyniki symulacji poziomu zapasów dla 25 zestawów danych oraz wariantów 7-8

Wariant	Metoda	Nr Zestawu danych	Z1	Z2	Z3	Z4	Z5	Z6	Z7	Z8	Z9	Z10	Z11	Z12	Z13	Z14	Z15	Z16	Z17	Z18	Z19	Z20	Z21	Z22	Z23	Z24	Z25	
Wariant 7	Proponowana metoda	Przeciętny poziom zapasów [%]	42,1	41,4	42,9	34,2	36,7	34,0	36,7	33,3	34,3	36,6	56,7	51,4	62,5	53,3	66,7	58,5	51,8	59,8	52,2	54,4	53,3	57,1	59,2	53,1	43,1	
		Średnia liczba braków	7,0	5,3	7,0	8,7	11,7	12,0	9,7	11,3	7,7	16,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,3	0,0	0,0	10,8	2,3
		Popyt nieobsłużony [%]	3,2	2,4	3,3	5,4	4,5	5,1	4,6	6,3	5,5	9,1	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,1	0,0	0,0	2,3	1,4
		Średnia liczba dostaw	35,3	38,3	39,3	42,7	44,3	42,0	40,3	44,0	41,7	40,0	15,7	18,0	6,3	18,0	3,0	4,7	14,7	3,7	20,7	19,7	19,0	11,0	10,7	38,8	29,7	
	Połączony model poziomu i cyklu zamawiania	Przeciętny poziom zapasów [%]	54,7	53,5	55,6	56,1	52,3	53,7	53,5	49,5	54,6	56,0	54,2	50,7	57,6	53,8	60,1	62,0	50,5	66,6	54,8	55,1	59,4	62,1	61,3	56,1	54,1	
		Średnia liczba braków	4,4	5,6	5,0	4,6	3,7	4,8	6,1	3,7	5,3	5,5	2,2	2,3	0,8	3,1	0,0	0,0	4,1	2,0	5,8	4,7	5,4	0,9	2,2	13,6	4,9	
		Popyt nieobsłużony [%]	1,6	2,1	2,4	1,9	1,2	1,7	2,9	1,3	1,8	2,9	0,7	1,0	0,3	1,6	0,0	0,0	2,9	1,9	2,4	2,9	4,3	0,2	1,5	8,5	2,4	
		Średnia liczba dostaw	57,5	58,3	59,6	63,4	98,1	63,4	68,4	129,1	60,2	74,1	19,7	19,2	11,6	21,3	8,3	8,5	20,7	10,2	27,3	26,4	22,1	14,1	14,2	45,9	26,2	
	Klasyczny model poziomu zamawiania	Przeciętny poziom zapasów [%]	29,3	30,5	28,6	24,2	19,9	24,9	21,3	21,2	27,5	20,1	29,7	26,6	26,8	30,0	37,8	39,3	30,0	39,7	34,1	35,3	34,6	32,0	33,5	53,7	35,0	
		Średnia liczba braków	26,5	23,2	31,8	42,0	108,6	39,3	47,3	67,8	32,2	56,4	3,4	3,5	2,3	4,5	1,7	3,3	5,9	4,5	5,7	8,8	7,8	5,7	5,6	16,8	8,7	
		Popyt nieobsłużony [%]	10,0	8,7	14,0	18,6	46,7	15,5	21,1	59,7	13,0	28,8	1,3	1,4	0,8	2,1	0,8	2,0	3,1	2,5	2,5	5,1	6,2	3,2	3,4	10,0	4,6	
		Średnia liczba dostaw	44,9	44,5	44,1	46,0	48,7	46,4	47,4	48,7	45,0	47,5	16,7	16,5	9,0	18,0	5,0	5,2	17,2	6,3	22,4	20,9	18,3	11,0	11,1	29,2	21,3	
Wariant 8	Proponowana metoda	Przeciętny poziom zapasów [%]	40,9	41,8	39,8	37,1	33,7	32,8	40,1	33,1	36,8	38,7	55,6	50,2	62,0	53,8	66,7	67,4	56,5	69,7	50,9	54,6	53,3	57,8	61,6	53,1	39,4	
		Średnia liczba braków	9,3	4,7	10,0	14,0	14,3	22,0	11,0	16,3	12,0	16,3	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	11,6	4,0	
		Popyt nieobsłużony [%]	3,3	1,7	5,0	6,0	8,6	8,4	4,5	6,5	5,7	8,5	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	2,7	2,8	
		Średnia liczba dostaw	36,7	39,3	37,7	43,0	43,0	43,3	42,0	44,0	41,3	39,7	16,0	20,0	7,7	18,3	4,3	4,7	14,7	3,7	21,0	20,7	21,0	11,3	10,3	38,8	30,4	
	Połączony model poziomu i cyklu zamawiania	Przeciętny poziom zapasów [%]	54,7	51,8	53,7	54,5	51,5	52,9	53,5	49,6	53,2	54,7	52,8	50,5	55,0	54,0	60,0	62,0	49,5	66,3	53,8	54,3	57,8	62,1	60,8	54,6	53,4	
		Średnia liczba braków	4,8	8,0	6,1	5,3	3,9	5,9	5,7	3,8	6,6	7,2	3,3	2,6	0,6	3,6	0,0	0,0	4,8	2,7	5,0	5,8	6,2	0,9	2,2	15,2	5,7	
		Popyt nieobsłużony [%]	1,7	3,0	2,6	1,9	1,3	2,1	2,5	1,3	2,4	3,7	1,1	1,3	0,2	1,6	0,0	0,0	3,0	2,6	2,2	4,1	4,9	0,2	1,3	9,5	2,9	
		Średnia liczba dostaw	58,1	58,7	60,4	64,5	99,1	64,1	69,2	129,7	60,6	75,0	19,8	19,4	11,7	21,7	8,3	8,5	21,1	10,2	27,7	26,2	22,3	14,0	14,2	46,7	26,5	
	Klasyczny model poziomu zamawiania	Przeciętny poziom zapasów [%]	27,5	28,5	27,4	21,6	20,4	22,5	18,9	19,1	25,9	17,5	29,0	26,3	26,9	30,0	37,9	39,5	29,5	39,8	34,1	35,2	34,0	31,8	33,3	51,9	34,9	
		Średnia liczba braków	34,1	31,0	35,3	51,6	116,6	47,8	59,1	73,7	41,4	64,5	6,3	4,6	2,0	6,4	2,0	2,2	7,2	4,8	7,8	8,9	8,9	7,9	6,5	19,0	10,2	
		Popyt nieobsłużony [%]	13,6	11,7	15,7	22,1	50,6	19,6	26,1	61,6	17,0	31,1	2,6	2,1	0,9	3,2	0,9	1,2	3,6	2,8	3,5	6,0	7,1	4,3	4,0	11,4	5,9	
		Średnia liczba dostaw	44,8	45,5	45,7	46,6	47,8	46,3	47,5	48,7	46,2	48,3	17,4	16,9	9,3	18,8	5,2	5,7	18,0	6,6	22,8	21,7	18,9	11,4	11,5	30,3	21,8	

Aby uzyskać bardziej ogólny, globalny obraz kształtujących się wyników symulacji rezultaty dla poszczególnych zestawów danych uśredniono. Otrzymane zbiorcze uśrednione wartości zostały zamieszczone w Tabeli.15. Ponadto aby zweryfikować czy i w jak dużym stopniu różnice wartości kryteriów otrzymane za pomocą rozważanych metod są istotne obliczono procentową przewagę/pogorszenie uzyskanych wyników dla metody rozmytej względem dwóch metod porównawczych Tabela. 16.

**Tabela 15.** Zbiorcze, uśrednione wyniki symulacji

Numer wariantu	Kryterium oceny	Proponowana metoda	Połączony model poziomu i cyklu zamawiania	Klasyczny model poziomu zamawiania
WARIANT 1	Przeciętny poziom zapasów [%]	49,5	55,9	36,5
	Średnia liczba braków	0,5	2,7	6,4
	Popyt nieobsłużony [%]	0,1	1,2	3,4
	Średnia liczba dostaw	28,3	40,1	32,9
WARIANT 2	Przeciętny poziom zapasów [%]	49,8	55,2	35,3
	Średnia liczba braków	1,0	2,8	7,7
	Popyt nieobsłużony [%]	0,2	1,2	4,1
	Średnia liczba dostaw	29,1	40,6	34,2
WARIANT 3	Przeciętny poziom zapasów [%]	53,2	57,7	37,3
	Średnia liczba braków	0,9	2,0	9,4
	Popyt nieobsłużony [%]	0,3	0,9	5,0
	Średnia liczba dostaw	27,7	41,4	31,5
WARIANT 4	Przeciętny poziom zapasów [%]	50,3	57,0	36,0
	Średnia liczba braków	1,4	2,3	11,7
	Popyt nieobsłużony [%]	0,5	1,1	6,1
	Średnia liczba dostaw	28,5	41,8	32,5
WARIANT 5	Przeciętny poziom zapasów [%]	49,2	56,8	33,7
	Średnia liczba braków	2,5	3,0	15,1
	Popyt nieobsłużony [%]	1,0	1,5	7,8
	Średnia liczba dostaw	26,6	41,3	29,7
WARIANT 6	Przeciętny poziom zapasów [%]	49,4	56,0	32,4
	Średnia liczba braków	3,0	3,3	18,2
	Popyt nieobsłużony [%]	1,3	1,6	9,3
	Średnia liczba dostaw	27,3	41,7	30,5
WARIANT 7	Przeciętny poziom zapasów [%]	48,2	55,9	30,6
	Średnia liczba braków	4,4	4,0	22,5
	Popyt nieobsłużony [%]	2,0	2,0	11,4
	Średnia liczba dostaw	25,7	41,1	27,6
WARIANT 8	Przeciętny poziom zapasów [%]	49,1	55,1	29,7
	Średnia liczba braków	5,8	4,6	26,4
	Popyt nieobsłużony [%]	2,4	2,3	13,1
	Średnia liczba dostaw	26,1	41,5	28,1

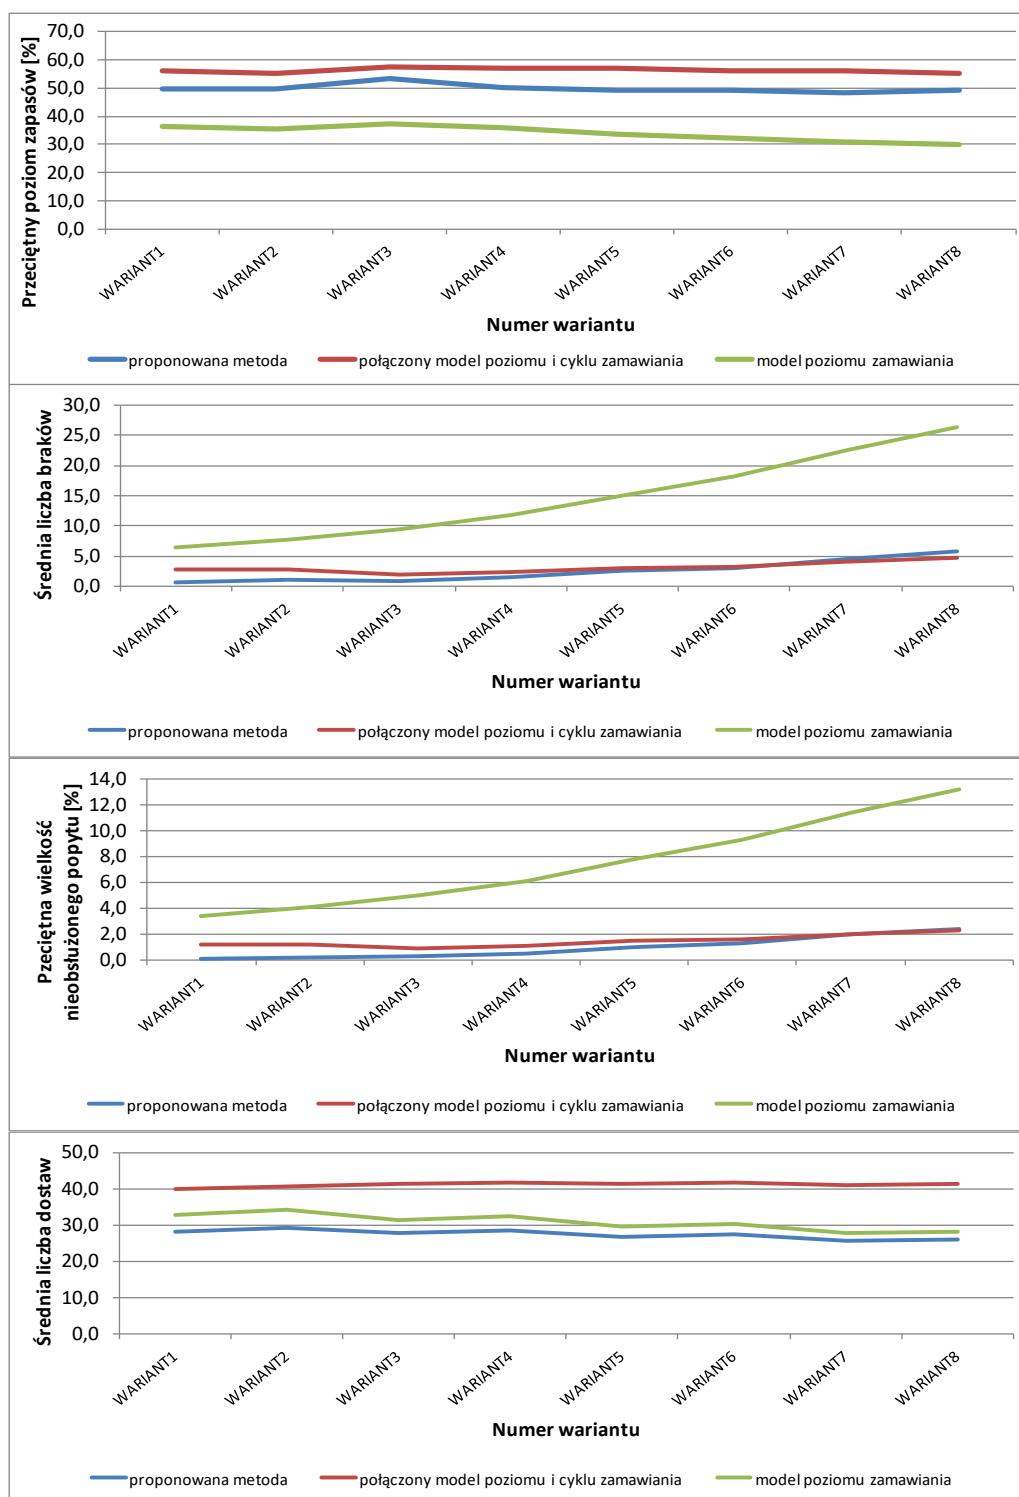
**Tabela 16.** Procentowa poprawa +/- pogorszenie otrzymanych wyników dla proponowanego podejścia względem metod porównawczych

Numer wariantu	Kryterium oceny	Połączony model poziomu i cyklu zamawiania	Klasyczny model poziomu zamawiania
WARIANT 1	Przeciętny poziom zapasów	12%	-35%
	Średnia liczba braków	81%	92%
	Popyt nieobsłużony	90%	96%
	Średnia liczba dostaw	29%	14%
WARIANT 2	Przeciętny poziom zapasów	10%	-41%
	Średnia liczba braków	66%	87%
	Popyt nieobsłużony	81%	94%
	Średnia liczba dostaw	28%	15%
WARIANT 3	Przeciętny poziom zapasów	8%	-42%
	Średnia liczba braków	54%	90%
	Popyt nieobsłużony	68%	94%
	Średnia liczba dostaw	33%	12%
WARIANT 4	Przeciętny poziom zapasów	12%	-40%
	Średnia liczba braków	39%	88%
	Popyt nieobsłużony	56%	92%
	Średnia liczba dostaw	32%	12%
WARIANT 5	Przeciętny poziom zapasów	13%	-46%
	Średnia liczba braków	17%	84%
	Popyt nieobsłużony	32%	87%
	Średnia liczba dostaw	36%	11%
WARIANT 6	Przeciętny poziom zapasów	12%	-53%
	Średnia liczba braków	9%	84%
	Popyt nieobsłużony	19%	86%
	Średnia liczba dostaw	35%	10%
WARIANT 7	Przeciętny poziom zapasów	14%	-57%
	Średnia liczba braków	-9%	81%
	Popyt nieobsłużony	2%	83%
	Średnia liczba dostaw	38%	7%
WARIANT 8	Przeciętny poziom zapasów	11%	-65%
	Średnia liczba braków	-26%	78%
	Popyt nieobsłużony	-3%	82%
	Średnia liczba dostaw	37%	7%

Na podstawie Tabeli 16. można stwierdzić, iż niezależnie od rozważanego wariantu przedstawiona w niniejszej pracy metoda dla kryterium przeciętnego poziomu zapasów daje rezultaty od 8% - 14% lepsze od połączonego modelu poziomu i cyklu zamawiania. Zasluguje to na uwagę, gdyż ta metoda porównawcza jest zazwyczaj stosowana dla produktów szczególnie ważnych dla przedsiębiorstwa celem jak najskuteczniejszego zabezpieczenia się przed ryzykiem wystąpienia braku w zapasie. Mimo to prezentowane rozwiązanie okazało się bardziej efektywne bez pogorszenia wartości innych kryteriów we wszystkich wariantach od 1 do 6. Jedynie dla wariantu 7 oraz 8 niższe wartości poziomu zapasów przełożyły się na nieco gorsze rezultaty w odniesieniu do liczby braków oraz wielkości nieobsłużonego popytu. Sytuacja ta jednak mogłaby ulec zmianie w wyniku zmiany wartości wag w procesie optymalizacji bazy wiedzy w module rozmytym. W odniesieniu do klasycznego modelu poziomu zamawiania oferowane podejście w zakresie kryterium poziomu zapasów uzyskało gorsze rezultaty o około 50% we wszystkich 8 wariantach. Należy jednak zwrócić uwagę, iż ta metoda porównawcza jest szczególnym przypadkiem podejścia wielokryterialnego tzn. metodą jednokryterialną a zatem otrzymane rozwiązanie reprezentuje punkt wierzchołkowy zbioru kompromisów, który dotyczy jedynie kryterium poziomu zapasów. Dla pozostałych kryteriów oceny przewaga proponowanej metody wielokryterialnego sterowania sięgała nawet 95%. Niższe wartości poziomu zapasów w modelu poziomu zamawiania były spowodowane bardzo wysoką liczbą występujących braków oraz nieobsłużonego popytu. W nawiązaniu do liczby niezbędnych dostaw rezultaty otrzymane za pomocą połączonego modelu poziomu i cyklu zamawiania oraz klasycznego modelu poziomu zamawiania okazały się gorsze o odpowiednio 30% i 10% w porównaniu do prezentowanej metody, co skutkowało może wyraźnie niższymi kosztami transportu ponoszonymi z tytułu wykonywania dostaw.

### 5.2.3 Ocena wrażliwości uzyskanych wyników symulacji poziomu zapasów

Kluczowym elementem, który może warunkować praktyczną użyteczność danej metody jest jej wrażliwość na wzrastający poziom zmienności i niepewności parametrów oddziałujących na system zapasów. Dlatego też aby z perspektywy kolejnych wariantów (które opisują rosnący stopień zmienności czasu dostawy oraz parametru jakości dostawy) spojrzeć na dynamikę zmian wartości poszczególnych kryteriów sporządzono wykres uśrednionej zależności wartości kryteriów oceny od kolejnych zdefiniowanych wariantów w rozważanych zestawach 25 produktów (rys. 66). Na podstawie wykresu wyraźnie można dostrzec, że przedstawione w pracy podejście cechuje dosyć dobry poziom odporności rozwiązania na rosnącą zmienność parametrów. Wraz z kolejnymi wariantami symulacji pogorszenie rezultatów postępuje powoli również dla połączonego modelu poziomu i cyklu zamawiania, w przeciwieństwie do klasycznej metody poziomu zamawiania, gdzie rosnący poziom zmienności powoduje gwałtowne pogorszenie rezultatów.



**Rys. 66.** Wrażliwość metod na rosnący poziom zmienności parametrów opisany kolejnymi wariantami

Źródło: opracowanie własne



Dokonując próby oceny zaproponowanego w pracy podejścia do sterowania zapasami towarów w warunkach oddziaływania czynników niepewnych można stwierdzić na podstawie otrzymanych rezultatów symulacji, że daje ono wyraźną możliwość złagodzenia poziomu nieokreśloności w podejmowaniu decyzji w zakresie uzupełniania i kontrolowania poziomu zapasów. Uzyskane w trakcie analiz prognozy popytu na produkty według zaproponowanych założeń i metodyki ukazują jej wyraźną przewagę nad innymi popularnie stosowanymi w praktyce metodami predykcji. Przewaga ta była szczególnie wyraźna rzędu 20% - do 25% dla zestawów danych o wyższym współczynniku zmienności tzn. powyżej 0,5. Dodatkowo dla kilku zestawów danych popytowych spośród 25 analizowanych wzrastający horyzont prognozowania tylko w minimalnym stopniu spowodował wzrost procentowego błędu prognozowania, co świadczy o dużej elastyczności podejścia i jego szerokiej możliwości zastosowania. Ponadto zintegrowane wykorzystanie algorytmów genetycznych oraz rozumowania rozmytego pozwoliło ograniczyć wpływ dwóch innych wziętych pod uwagę czynników niepewnych oddziałujących na system zapasów w postaci niepewności czasu dostawy oraz parametru jakości dostawy, rozumianej jako ograniczona dostępność produktu u dostawcy, możliwe uszkodzenia towaru itp. W tym przypadku całość zaproponowanej metody sterowania uzyskała rezultaty wyraźnie lepsze pod względem liczby braków w zapasach, wielkości nieobsłużonego popytu, liczby wykonanych dostaw a także poziomu zapasów w odniesieniu do metod porównawczych, pomimo zmian zakresu zmienności wspomnianych parametrów. Otrzymane rezultaty pokazują, że zaproponowana metoda rozwiązywania problemu sterowania zapasami towarów może stanowić atrakcyjne narzędzie pozwalające minimalizować wpływ niekorzystnych czynników losowych na proces uzupełniania i kontrolowania zapasów dla przedsiębiorstw i podmiotów w łańcuchach logistycznych. Dzięki takiemu rozwiązaniu możliwe jest zachowanie kompromisu pomiędzy wysokimi kosztami utrzymania zapasów (w sytuacji silnych zaburzeń systemu wskutek działania czynników niepewnych) a powszechnym dążeniem przedsiębiorstw do maksymalizacji poziomu obsługi klienta oraz utrzymaniem przewagi konkurencyjnej na rynku.

## 6. PODSUMOWANIE

### 6.1 WERYFIKACJA ZAŁOŻONYCH CELÓW ORAZ POSTAWIONYCH TEZ

Niniejsza rozprawa doktorska jest poświęcona tematyce kontrolowania i sterowania poziomem zapasów towarów z wykorzystaniem dedykowanych technik sztucznej inteligencji z uwzględnieniem oddziaływania na system zapasów czynników losowych w postaci niepewności popytu, czasu dostawy oraz dostępności towaru u dostawcy. Głównym celem pracy było zaproponowanie autorskiej metody opierającej się na zintegrowanym zastosowaniu narzędzi sztucznej inteligencji, wraz z niezbędnymi wytycznymi i założeniami do rozwiązania powyższego zagadnienia. Celem pobocznym było przedstawienie koncepcji umiejscowienia problematyki sterowania zapasami towarów w podejściu systemowym.

Obecnie jednym z najważniejszych celów przedsiębiorstw oprócz zapewnienia odpowiedniej jakości produktów oraz atrakcyjnej ceny jest dążenie do osiągnięcia właściwego poziomu obsługi klienta w postaci określonego czasu dostaw, powtarzalności, elastyczności, dostępności towarów przy jednoczesnej minimalizacji kosztów logistycznych. Aspekt ten w dużym stopniu rzutuje na pozycję firmy na rynku. W końcowym rozrachunku wysiłki wszystkich podmiotów skoncentrowane są na klienta (odbiorcę) znajdującego się na końcu łańcucha logistycznego.

Wobec powyższego, w kontekście rozważanej problematyki sterowania zapasami towarów jest wysoce pożądane aby stosować takie metody sterowania, które ograniczają poziom zapasów generujący wysokie koszty magazynowania, utrzymania zapasów, zamrożonego kapitału itp. a jednocześnie gwarantują wysoki poziom obsługi, czyli gotowość w dowolnym czasie do zaspokojenia zapotrzebowania na produkt dla klienta końcowego. Postulaty te są niezwykle trudne do całkowitej realizacji, gdyż stoją we wzajemnej opozycji do siebie.

Dodatkowo czynnikiem utrudniającym, wzmagającym poziom nieokreśloności w podejmowaniu decyzji w tym obszarze jest wpływ różnych, przywołanych w pracy determinant i warunków niepewnych działających na system zapasów. Ich typ oraz intensywność oddziaływania jest zmienna w zależności od specyfiki produktu, rodzaju i złożoności łańcucha dostaw itp. Stąd bardzo często u podmiotów w łańcuchach logistycznych dochodzi do przeszacowania przyszłego zapotrzebowania na towar dla klientów końcowych, które bardzo często jest powiększane o dodatkowy zapas zabezpieczający. W konsekwencji rezultatem tego jest spotęgowane zjawisko efektu Forrestera, bardzo niekorzystne dla całej sieci logistycznej.

Na tej podstawie, w oparciu o szeroki przegląd literatury rozpoznano trzy główne nurty metodyki sposobu modelowania niepewności w problemach decyzyjnych dotyczących optymalizacji poziomu zapasów: podejście stochastyczne, odpornościowe typu „robust” oraz heurystyczne wykorzystujące sztuczną inteligencję. Na bazie tego zidentyfikowano braki w dotychczasowych badaniach nad zagadnieniem sterowania poziomem zapasów w warunkach

niepewności. Ich podstawową cechą był brak jednoczesnego uwzględnienia kilku czynników, mogących istotnie wpłynąć na efektywność rozwiązania a także częsty brak dynamizmu, zdolności metod do adaptacji do zmieniających się warunków czy też różnej specyfiki wzorca i charakteru popytu. Dodatkowymi elementami był wysoki poziom skomplikowania i złożoności obliczeniowej metod.

Na podstawie spostrzeżeń z przeprowadzonych wywiadów z firmami logistycznymi trudniącymi się magazynowaniem określono specyfikę oraz najważniejsze założenia do rozważanego w pracy problemu. W dalszej kolejności została stworzona koncepcyjna architektura metody, struktura powiązań jej elementów oraz niezbędne założenia zaproponowanego w pracy podejścia do rozwiązania problemu sterowania poziomem zapasów towarów według trzech kryteriów. Istotnym elementem oferowanego rozwiązania był moduł predykcji odpowiedzialny za rozpoznawanie, identyfikację oraz predykcję przyszłego zapotrzebowania na produkty. Idea jego działania oparta jest o połączone wykorzystanie zalet płynących z analizy częstotliwościowej popytu, analizy zjawiska autoregresji za pomocą modeli ARIMA oraz rozpoznawania nieliniowych mechanizmów zachowań popytu za pomocą sztucznych sieci neuronowych. Kluczowym składnikiem w całej prezentowanej metodyce był moduł rozumowania rozmytego. W nim niepewność oddziałujących na system zapasów parametrów opisana została za pomocą odpowiednio dobranych zbiorów rozmytych, stanowiących zmienne wejściowe modułu. Natomiast zmienne wyjściowe odpowiadały zmiennym sterowania w rozważanym problemie. Zasadniczą cechą całej metody jest zdolność adaptacji wyznaczanego w sposób dynamiczny rozwiązania do aktualnie zmieniających się parametrów (popyt, czas dostawy, dostępność produktów u dostawcy). Realizacja tej cechy odbywa się poprzez dynamiczną modyfikację wartości parametrów funkcji przynależności dla zmiennych wyjściowych na podstawie bieżących wartości błędów predykcji zapotrzebowania na dany produkt. Dodatkowo przedstawiana metoda zapewnia duży stopień elastyczności, to znaczy że może być adekwatna dla szerokiego spektrum typów produktów o różnej charakterystyce popytu i współczynniku zmienności oraz w sytuacji oddziaływania wielu innych czynników losowych. Elastyczność tą gwarantuje wykorzystanie algorytmów genetycznych, które dokonują wielokryterialnej optymalizacji i adaptacji bazy wiedzy w formie reguł rozmytych dla danej specyfiki produktu, czasu potrzebnego na wykonanie dostawy, określonej sytuacji na rynku itp. Ponadto rozwiązanie umożliwia płynną zmianę priorytetów przedsiębiorstwa pod względem oceny jakości sterowania poprzez zmianę wag dla kryteriów oceny (poziom zapasów, liczba braków, wielkość nieobsłużonego popytu, liczba dostaw itp.) w procesie optymalizacji bazy wiedzy systemu. Dzięki takim zabiegom, pożądane działania sterujące podejmowane wedle zaproponowanego podejścia mają być antycypacyjne czyli uprzedzające negatywne konsekwencje błędnych decyzji w kontekście uzupełniania zapasów, wskutek możliwego działania dużego poziomu niepewności.

Dodatkowo w pracy przedstawiono koncepcję ujęcia rozważanej problematyki sterowania zapasami w ujęciu systemowym na podstawie idei hierarchicznej struktury Inteligentnych Systemów Logistycznych (ILS). Takie spojrzenie na rozważany problem umożliwia przypisanie określonych czynności w ramach planowania dostaw i kontrolowania poziomu

zapasów w odpowiednie warstwy systemowe. Ponadto spojrzenie systemowe na podejmowane zagadnienie umożliwia także identyfikację niezbędnych funkcjonalnych połączeń pomiędzy poszczególnymi podmiotami sieci dostaw, co ma zagwarantować wymaganą efektywność w zakresie optymalizacji zapasów w całości sieci logistycznej.

Wobec powyższego wszystkie cele pracy zdaniem autora zostały zrealizowane.

Potwierdzeniem realizacji wspomnianych powyżej cech przez proponowaną metodę są rezultaty wykonanych badań i symulacji komputerowych na podstawie rzeczywistych danych popytowych przedsiębiorstwa dla grupy 25 produktów. Na bazie przeprowadzonych analiz i symulacji dowiedziono, że zastosowanie hybrydowego modelu predykcyjnego, wspartego wykorzystaniem sztucznych sieci neuronowych daje zdecydowanie lepsze rezultaty w postaci mniejszych wartości błędów predykcji w porównaniu do wybranych metod porównawczych. Uśrednione dla wszystkich analizowanych zestawów procentowe wartości błędów prognozowania są niższe dla modelu hybrydowego o około 10 punktów procentowych w porównaniu do modelu Holta, o około 30 punktów procentowych w odniesieniu do modelu Wintersa oraz przeszło 100 punktów procentowych w porównaniu do modelu średniej ruchomej. Przewaga podejścia hybrydowego jest wyraźna pomimo przyjmowanej w analizie zmiennej długości horyzontu prognozowania. Rezultaty te dowodzą zatem postawionej tezy pomocniczej, że zastosowanie hybrydowych modeli prognostycznych umożliwia zmniejszenie niepewności w odniesieniu do predykcji popytu na dostawy towarów.

W odniesieniu do pozostałej części przeprowadzonych analiz, procesu optymalizacji i sterowania poziomem zapasów według całej zaproponowanej metody dowiedziono, że wykorzystanie techniki rozumowania rozmytego jest właściwe dla opisu niepewności czynników mogących oddziaływać na proces decyzyjny w ramach sterowania zapasami. Natomiast zastosowanie algorytmów genetycznych w procesie optymalizacji bazy reguł rozmytych może skutecznie podnieść efektywność radzenia sobie z tą niepewnością. Świadczą o tym wyniki wykonanych eksperymentów obliczeniowych poziomu zapasów wedle przedstawionej metody w przyjętym okresie czasu. Dla zaproponowanego podejścia otrzymano wartości kryterium przeciętnego poziomu zapasów lepsze o 8% - 14% od jednej z metod porównawczych jakim był połączony model poziomu i cyklu zamawiania. Przy tym należy mieć na uwadze, iż osiągnięcie tego wyniku odbyło się bez pogorszenia wartości innych kryteriów we wszystkich analizowanych scenariuszach od 1 do 6. Wyłącznie dla wariantu 7 oraz 8 niższe wartości poziomu zapasów przełożyły się na nieco gorsze rezultaty w odniesieniu do liczby braków oraz wielkości nieobsłużonego popytu. Sytuacja ta jednak mogłaby ulec zmianie podczas zmiany wartości wag w procesie optymalizacji bazy wiedzy w module rozmytym. W odniesieniu do drugiej metody porównawczej jaką był klasyczny model poziomu zamawiania oferowane podejście w zakresie kryterium poziomu zapasów uzyskało gorsze rezultaty o około 50% we wszystkich 8 wariantach. Należy jednak zwrócić uwagę, iż ta metoda porównawcza jest metodą jednokryterialną a zatem otrzymane rozwiązanie reprezentuje punkt wierzchołkowy zbioru kompromisów, który dotyczy jedynie kryterium poziomu zapasów. Dla pozostałych kryteriów oceny przewaga proponowanej w pracy metody sterowania sięgała nawet 95%. Niższe wartości poziomu zapasów w modelu poziomu

zamawiania były spowodowane bardzo wysoką liczbą występujących braków oraz nieobsłużonego popytu. W przypadku liczby niezbędnych dostaw rezultaty otrzymane za pomocą połączonego modelu poziomu i cyklu zamawiania oraz klasycznego modelu poziomu zamawiania okazały się gorsze o odpowiednio 30% i 10% w porównaniu do prezentowanej metody, co w efekcie skutkować może wyraźnie niższymi kosztami transportu ponoszonymi z tytułu wykonywania dostaw.

Otrzymane w wyniku eksperymentów obliczeniowych rezultaty symulacji poziomów zapasów dowodzą zatem, że pomimo rozpatrywanych różnych poziomów zmienności parametrów uzyskiwane wartości poszczególnych kryteriów oceny, nie ulegają gwałtownemu, skokowemu pogorszeniu, co jest istotne ze względu na praktyczne zastosowanie metody.

Ponadto zweryfikowano, że pomimo przyjęcia wysokiego współczynnika bezpieczeństwa dla zapasu zabezpieczającego, efekty otrzymywane przez metody porównawcze są w wielu przypadkach gorsze od zaproponowanego w pracy podejścia. Dzięki temu przedstawiona propozycja rozwiązania podejmowanego problemu zapasów może stanowić atrakcyjne narzędzie umożliwiając zachowanie kompromisu pomiędzy całkowitymi ponoszonymi kosztami systemu zapasów a ryzykiem wystąpienia braku w zapasie towaru w sytuacji oddziaływania czynników niepewnych. Ponadto zweryfikowano, iż proponowane podejście posiada cechę uniwersalności, dzięki czemu może być użyteczne w różnych przedsiębiorstwach dla różnej charakterystyki produktów oraz różnych wzorcach zapotrzebowania. Jest to możliwe również dzięki podejściu systemowemu, które jest reprezentowane przez oferowaną w niniejszej pracy metodę.

Wobec wszystkich powyższych spostrzeżeń postawione w niniejszej pracy tezy zostały potwierdzone.

## **6.2 PRAKTYCZNE ASPEKTY PROPONOWANEGO ROZWIĄZANIA**

Podsumowując proponowane podejście, narzędzia i wyniki uzyskane w pracy należy zwrócić uwagę na kluczowe praktyczne kwestie:

- Proponowane w pracy sformułowanie i rozwiązanie problemu sterowania zapasami w magazynach zostało zrealizowane w środowisku nowoczesnych zintegrowanych inteligentnych systemów logistycznych ILS.
- Zaproponowana w pracy predykcyjna metoda sterowania, ujęta w ramy systemowe oferuje i warunkuje wiele istotnych nowych specyfikacji rozwiązywanego problemu tzn. uniwersalność, elastyczność, eksploracja nowoczesnych inteligentnych narzędzi systemowych. W efekcie tego możliwa jest eliminacja większości występujących ograniczeń (uproszczeń) w istniejących już rozwiązaniach rozważanej problematyki. Istniejące rozwiązania w tym zakresie przeważnie wykorzystują podejścia deterministyczne, pseudo-stochastyczne z wieloma uproszczeniami, formułując często problemy NP.-trudne o bardzo mocno ograniczonej użyteczności.



- W proponowanym podejściu eksploracja inteligentnych narzędzi systemowych ILS w postaci wybranych technik sztucznej inteligencji o aktualizowanych parametrach w czasie rzeczywistym, pozwoliła na sformułowanie wielokryterialnego problemu prognozowania popytu i predykcyjnego sterowania poziomem zapasów w otoczeniu oddziaływania wybranych czynników niepewnych. Umożliwiło to eliminację pewnego rodzaju praktycznych uproszczeń/ ograniczeń obecnych w istniejących metodach.
- Z praktycznego punktu widzenia należy zwrócić uwagę iż rozważane w pracy zagadnienie jest jednym z wielu problemów rozwiązywanych w ramach Inteligentnych Systemów Logistycznych ILS. Obecnie wiele projektów realizowanych na świecie dotyczy wdrażania funkcjonalności oraz metod dolnej warstwy ILS, czyli bezpośredniego inteligentnego sterowania w czasie rzeczywistym różnymi procesami logistycznymi i transportowymi. Z tej perspektywy w niedługim czasie oczekiwac można wzrastającego zainteresowania i zapotrzebowania przedsiębiorstw na rozszerzoną wersję metody predykcyjnego sterowania w czasie rzeczywistym poziomem zapasów towarów w magazynach, zapewniającą integrację ze środowiskiem operacyjnym wewnętrznym i zewnętrznym ILS systemów oraz uwzględniającą dodatkowe wymagania ( np. zmienność w czasie jednostkowych kosztów uzupełniania i utrzymania zapasów z wieloma systemowo zorientowanymi optymalizowanymi w czasie rzeczywistym funkcjonalnymi kryterialnymi).

### 6.3 DALSZE KIERUNKI BADAŃ

W pracy podjęto próbę opisu wybranych czynników niepewnych oddziałujących na system zapasów za pomocą teorii zbiorów rozmytych oraz wykorzystując przy tym technikę rozumowania rozmytego wspartą algorytmem genetycznym do rozwiązania postawionego problemu kontroli poziomu zapasów. Pomimo przeprowadzonych analiz oraz aktualnego stanu wiedzy z tego zakresu, zaproponowana metoda predykcyjnego sterowania poziomem zapasów może być w dalszym ciągu rozwijana między innymi w następujących kierunkach:

- Uwzględnienie w metodzie w zależności od potrzeb dodatkowych aspektów praktycznych w postaci ograniczonego czasu składowania towarów, zmienności cen zakupu, rabatów u dostawców itp.
- Uwzględnienie w metodzie możliwości grupowego zamawiania produktów,
- Rozszerzenie proponowanej metody na zagadnienie wieloszczeblowe obejmujące większą liczbę podmiotów w sieci dostaw, gdzie optymalizacja rozwiązania wykonywana byłaby z punktu widzenia całej sieci dostaw,

- Zastosowanie w metodzie możliwości bieżącej aktualizacji wag dla bazy wiedzy reguł rozmytych w trakcie wykonywania symulacji, na podstawie aktualnie wyznaczonych zdefiniowanych wartości sygnałów śledzących, które opisują bieżącą jakość sterowania wedle przyjętych kryteriów,
- Weryfikacja proponowanej metody w rzeczywistym procesie zaopatrzenia w wybranym przedsiębiorstwie, w którym oddziaływanie czynników niepewnych istotnie wpływa na jakość decyzji podejmowanych w ramach sterowania zapasami,



## BIBLIOGRAFIA

- [1] Abginehchi, S., Farahani, R. *Modeling and analysis for determining optimal suppliers under stochastic lead times*. Applied Mathematical Modelling, Vol. 34, No.5, pp. 1311–1328, 2010
- [2] Aburto, L., Weber, R.. *Improved supply chain management based on hybrid demand forecasts*. Applied Soft Computing, Vol.7, pp. 136–144, 2007
- [3] Adamski A., *Advanced system platform HILS for development of ILS systems*, Czasopismo Logistyka nr 6, str. 1331 -1339, 2014
- [4] Adamski A., *Hierarchical Integrated Intelligent Logistics System Platform*, Procedia Social and Behavioral Science, Vol.20, pp. 1004 – 1016, 2011
- [5] Adamski A., *Routing problems based on HILS system platform*, LogForum, Vol. 11, No.1, pp. 87-98, 2015
- [6] Adida E., Perakis G., *A Robust Optimization Approach to Dynamic Pricing and Inventory Control with no Backorders*, Math. Program., Ser. B Vol.107, pp. 97–129, 2006
- [7] Adida E., Perakis G., *Dynamic pricing and inventory control: robust vs. stochastic uncertainty models—a computational study*, Oper Res, Vol.,181, pp.125–157, 2010
- [8] Aengchuan, P., Phruksaphanrat, B., *Inventory system design by fuzzy logic control: A case study*. Advanced Materials Research, Vol. 8, pp. 619–624, 2013
- [9] Alfares H. K., Ghaithan A. M., *Inventory and pricing model with price-dependent demand, time-varying holding cost, and quantity discounts*, Computers & Industrial Engineering, Vol.,94, pp. 170–177, 2016
- [10] Alfares H., Elmorra H.,, *The distribution - free newsboy problem: extensions to the shortage penalty case*, Int.J.Prod.Econ, Vol. 93, pp. 465–477, 2005
- [11] Aouam, T., Brahim, N. *Integrated production planning and order acceptance under uncertainty: A robust optimization approach*. European Journal of Operational Research, Vol. 228, No.3, pp.501–515, 2013
- [12] Bai L., Alexopoulos Ch., Ferguson M. E., Tsui K. L., *A simple and robust batch-ordering inventory policy under incomplete demand knowledge*, Computers & Industrial Engineering, Vol.,63, pp. 343–353, 2012
- [13] Bandyopadhyay,S., Bhattacharya, R. *Solving a tri objectives supply chain problem with modified NSGA-II algorithm*, Journal of Manufacturing Systems, Vol. 33, pp. 41–50, 2014
- [14] Ben Tal A., Ghaoui L, Nemirovski A., *Robust Optimization*, Princeton University Press, 2009
- [15] Ben Tal A., Golany B., Sthern S., *Robust multi-echelon multi-period inventory control*, European Journal of Operational Research, Vol. 199, pp. 922–935, 2009
- [16] Ben-Tal, A., Golany, B., Nemirovski, A., Vial, J. *Retailer-supplier flexible commitments contracts:A robust optimization approach*. Manufacturing and Service Operations Management, Vol. 7, No. 3, pp. 248–271, 2005

- [17] Bertsimas D., Thiele A., *A robust optimization to inventory theory*, Operations Research, Vol. 54, No. 1, pp. 150 – 168, 2006
- [18] Bhattacharya R., Bandyopadhyay S., *A review of the causes of bullwhip effect in a supply chain*, International Journal of Advanced Manufacturing Technology, Vol. 54, No 9., pp. 1245 – 1261, 2011
- [19] Bohle, C., Maturana, S., Vera, J. (), *A robust optimization approach to wine grape harvesting scheduling*. European Journal of Operational Research, Vol. 200, No.1, pp. 245–252, 2010
- [20] Bozarth C.B., Handfield R.B., *Wprowadzenie do zarządzania operacjami i łańcuchem dostaw*, Helion, Gliwice 2007
- [21] Brockwell P., Davis R., *Intorduction to Time Series and Forecasting*, Springer, 2002
- [22] Burbidge J. L., *Period batch control (PBC) w GT – the way forward from MRP*, BPCIS, Birmingham 1991
- [23] Bylka S., *Turnpike policies for periodic review inventory model with emergency orders*, International Journal of Production Economics, Vol. 93–94, pp. 357–373, 2005
- [24] Chang C.-T., Ouyang L.-Y., Teng J.-T., *An EOQ model for deteriorating items under supplier credits linked to ordering quantity*, Applied Mathematical Modelling, Vol. 27, No.12, pp. 983–996, 2003
- [25] Chang C.-T., Ouyang L.-Y., Teng J.-T., Cheng M.-C., *Optimal ordering policies for deteriorating items using a discounted cash-flow analysis when a trade credit is linked to order quantity*, Computers & Industrial Engineering, Vol. 59, No. 4, pp. 770-777, 2010
- [26] Chang H.-J., Teng J.-T., Ouyang L.-Y., Dye C.-Y., *Retailer's optimal pricing and lot-sizing policies for deteriorating items with partial backlogging*, European Journal of Operational Research, Vol. 168, No. 1, pp. 51–64, 2006
- [27] Chang H.C., J.S.H. Yao, L.Y. Ouyang, *Fuzzy mixture inventory model with variable lead time based on probabilistic fuzzy set and triangular fuzzy number*, Mathematical and Computer Modeling, Vol. 39, pp. 287–304, 2004
- [28] Chede, B., Jain, C. K., Jain, S. K., Chede, A. *Fuzzy logic analysis based on inventory considering demand and stock quantity on hand*. Industrial Engineering Letters, 2(1), pp. 13–21, 2012
- [29] Chen J.-M., Lin C.-S., *An optimal replenishment model for inventory items with normally distributed deterioration*, Production Planning & Control, Vol. 13, No. 5, pp. 470–480, 2002
- [30] Chen L.-H., Ouyang L.-Y., Teng J.-T., *On an EOQ model with ramp type demand rate and time dependent deterioration rate*, International Journal of Information and Management Sciences, Vol. 17, No. 4, pp. 51–66, 2006
- [31] Chiang C., *Optimal ordering policies for periodic-review systems with replenishment cycles*, European Journal of Operational Research, Vol. 170, pp. 44 – 56, 2005

- [32] Chiang C., *Optimal replenishment for a periodic review inventory system with two supply modes*, European Journal of Operational Research, Vol. 149, pp. 229–244, 2003
- [33] Choi B., *ARMA Model Identification*, Springer, 1992
- [34] Choi K.-S., Dai J., Song J.-S., *On measuring supplier performance under vendor-managed-inventory programs in capacitated supply chains*. Manufacturing and Service Operations Management, Vol. 6, No.1, pp. 53–72, 2004
- [35] Chopra S., Reinhardt G., Mohan U., *The importance of decoupling recurrent and disruption risks in a supply chain*. Naval Research Logistics, Vol. 54, No. 5, pp. 544–555, 2007
- [36] Ciesielski M., Długosz J., *Strategie łańcuchów dostaw*, Polskie Wydawnictwo Ekonomiczne, Warszawa 2010
- [37] Cieślak M., *Prognozowanie Gospodarcze. Metody i zastosowanie*, PWN, 2005
- [38] Cyplik P, Krzyżaniak S., *Zapasy i magazynowanie*, Instytut Logistyki i Magazynowania, 2008
- [39] Dada M., Petruzzi N., Schwarz, L., *A newsvendor's procurement problem when suppliers are unreliable*. Manufacturing and Service Operations Management, Vol. 9, No. 1, pp. 9–32, 2007
- [40] Dittmann P., Dittmann I., Szabela-Pasierbińska E., Szpulak A., *Prognozowanie w zarządzaniu sprzedażą i finansami przedsiębiorstwa*. Wolters Kluwer Business, Warszawa 2011.
- [41] Du W., Leung S., Kwong C., *A multi objective optimization-based neural network model for short-term replenishment forecasting in fashion industry*, Neuro computing, Vol. 151, pp. 342–353, 2015
- [42] Dudziński Z., *Opakowania w gospodarce magazynowej*, ODiDK, Gdańsk 2007
- [43] Dye C.-Y., *A note on an EOQ model for items with weibull distributed deterioration, shortages and power demand pattern*, International Journal of Information and Management Sciences, Vol. 15, No. 2, pp. 81–84, 2004
- [44] Dye C.-Y., Chang H.-J., Wu C.-H., *Purchase-inventory decision models for deteriorating items with a temporary sale price*, International Journal of Information and Management Sciences, Vol. 18, No. 1, pp. 17–35, 2007
- [45] Dye C.-Y., Hsieh T.-P., Ouyang L.-Y., *Determining optimal selling price and lot size with a varying rate of deterioration and exponential partial backlogging*, European Journal of Operational Research, Vol. 181, No. 2, pp. 668–678, 2007
- [46] Dye C.-Y., *Joint pricing and ordering policy for a deteriorating inventory with partial backlogging*, Omega, Vol. 35, No. 2, pp. 184–189, 2007
- [47] Dye C.-Y., Ouyang L.-Y., Hsieh T.-P., *Deterministic inventory model for deteriorating items with capacity constraint and time-proportional backlogging rate*, European Journal of Operational Research, Vol. 178, No. 3, pp. 789–807, 2007
- [48] Efendigil T., Önüt S., Kahraman C., *A decision support system for demand forecasting with artificial neural networks and neuro-fuzzy models: A comparative analysis*, Expert Systems with Applications, Vol. 36, pp. 6697–6707, 2009

- [49] Fechner I., *Centra logistyczne. Cel – realizacja – przyszłość*, Instytut Logistyki i Magazynowania, Poznań 2004
- [50] Ferguson M., Jayaraman V., Souza G. C. *An application of the EOQ model with nonlinear holding cost to inventory management of perishables*, European Journal of Operational Research, Vol. 180, No.1, pp. 485–490, 2007
- [51] Frank K.C., Ahn H.-S., Zhang R.Q., *Inventory policies for a make-to-order system with a perishable component and fixed ordering cost*, Naval Research Logistics, Vol. 56, No.2, pp. 127–141, 2009
- [52] Gallego G.,a, Katircioglu K., Ramachandran B., *Inventory management under highly uncertain demand*, Operations Research Letters, Vol. 35, No. 3, pp. 281 – 289, 2007
- [53] Ghasemi, N., Afshar Nadjafi, B., *EOQ models with varying holding cost*, Journal of Industrial Mathematics, 2013
- [54] Ghiani G., Laporte G., Musmanno R., *Introduction to Logistics System Planning and Control*, Wiley 2004
- [55] Goldberg D., *Genetic Algorithms in Search, Optimization, and Machine Learning*, Addison – Wesley Publishing Company, Inc, 1989
- [56] Gołemska E., *Kompendium wiedzy o logistyce*, PWN, Warszawa 2010
- [57] Gorissen Bram L., Yanıkoğlu Ihsan., Hertog D., *A practical guide to robust optimization*, Omega, Vol. 53, pp. 124–137, 2015
- [58] Gou Q., Liang L., Xu C., Zha Y., *A modified joint inventory policy for VMI systems*, International Journal of Information Technology and Decision Making, Vol. 7, No.2, pp. 225–240, 2008
- [59] Govindan K., *The optimal replenishment policy for time - varying stochastic demand under vendor managed inventory*, European Journal of Operational Research, Vol. 242, pp. 402–423, 2015
- [60] Goyal S.K., Giri B.C., *Recent trends in modelling of deteriorating inventory*, European Journal of Operational Research, Vol.134, No.1, pp. 1–16., 2001
- [61] Guan Y. *Stochastic lot-sizing with backlogging: Computational complexity analysis*. Journal of Global Optimization's, Vol. 49, pp. 651– 678, 2011
- [62] Güller M., Uygun Y., Noche B., *Simulation – based optimization for a capacitated multi-echelon production inventory system*, Journal of Simulation, Vol. 9, No. 4, pp. 325–336, 2015
- [63] Hamzacebi C., *Improving artificial neural networks' performance in seasonal time series forecasting*, Information Sciences, Vol. 178, pp. 4550–4559, 2008
- [64] Ho, W.T., Hsiao Y.C., *Single supplier single retailer inventory model controlled by the reorder and shipping points with sharing information*, International Journal of Systems Science, Vol. 43, No.4, pp. 673–681, 2012
- [65] Hodrick R.J., E.C. Prescott: *Postwar U.S. Business Cycles: An Empirical Investigation*, Journal of Money, Credit and Banking, Vol. 29, No. 1, pp. 1–6, Ohio State University Press, 1997
- [66] Hsieh C.H., *Optimization of fuzzy production inventory models*, Information Sciences, Vol. 146, pp. 29–40, 2002

- [67] Hsieh T.-P., Dye C.-Y., Ouyang L.-Y., *Determining optimal lot size for a two warehouse system with deterioration and shortages using net present value*, European Journal of Operational Research, Vol. 191, No.1, pp. 182–192, 2008
- [68] Kamal, L., Sculfort, J.-L., *Fuzzy modelling of inventory control system in uncertain environment*, International Symposium on Logistics and Industrial Informatics, pp. 53–57, 2007
- [69] Kanchanasuntorn K., Techanitisawad A., *An approximate periodic model for fixed-life perishable products in a two-echelon inventory–distribution system*, International Journal of Production Economics, Vol. 100, No.1, pp. 101– 115, 2006
- [70] Kang S., C., Brisimi T., S., I., Ch., Paschalidis, *Distribution-dependent robust linear optimization with applications to inventory control*, Ann Oper Res, Vol. 231, pp. 229–263, 2015
- [71] Kang H.-Y., Lee A. H. I., *A stochastic lot-sizing model with multi-supplier and quantity discounts*. International Journal of Production Research, Vol. 51, No.1, pp. 245–263, 2013
- [72] Kochański T., *Logistyka jako koncepcja zintegrowanego zarządzania*, Akademia Obrony Narodowej, Warszawa, s.14-16, 2003
- [73] Korzeń Z., *Logistyczne systemy transportu bliskiego*, Biblioteka Logistyka, 1999
- [74] Kwak C., Choi J., Kim C., Kwon I.-H., *Situation reactive approach to Vendor Managed Inventory problem*, Expert Systems with Applications, Vol. 36, No.5, pp. 9039–9045, 2009
- [75] Lee C.C., *Two-warehouse inventory model with deterioration under FIFO dispatching policy*, European Journal of Operational Research, Vol.174, No.2,pp.861–873, 2006
- [76] Li J., Edwin Cheng T.C., Wang S.-Y., *Analysis of postponement strategy for perishable items by EOQ-based models*, International Journal of Production Economics, Vol.107, No.1, pp. 31–38, 2007
- [77] Li H., Thorstenson, A., *A multi-phase algorithm for a joint lot sizing and pricing problem with stochastic demands*, International Journal of Production Research, Vol. 52, No. 8, pp. 2345–2362, 2014
- [78] Lin C., Lin Y., *A cooperative inventory policy with deteriorating items for a two-echelon model*, European Journal of Operational Research, Vol. 178, No.1, pp. 92–111, 2007
- [79] Liu B., *Uncertainty Theory*, Springer-Verlag Berlin, 2015
- [80] M.K. Maiti, M. Maiti, *Fuzzy inventory model with two warehouses under possibility constraint*, Fuzzy Sets and Systems, Vol. 157, pp. 52–73, 2006
- [81] Maiti M.K., Maiti M., *Fuzzy inventory model with two warehouses under possibility constraint*, Fuzzy Sets and Systems, Vol. 157, pp. 52–73, 2006
- [82] Maity A., Maity K., Mondal S., Maiti M., Chebyshev, *An approximation for solving the optimal production inventory problem of deteriorating multi item*, Mathematical and Computer Modelling, Vol. 45, No.1–2, pp.149–161, 2007



- [83] Maity K., Maiti M., *Optimal inventory policies for deteriorating complementary and substitute items*, International Journal of Systems Science, Vol. 40, No.3, pp. 267–276, 2009
- [84] Makridakis S., Wheelwright S.C., *Forecasting Methods and Applications*. John Wiley & Son, New York 1989
- [85] Mandal N.K., Roy T.K., *A displayed inventory model with L–R Fuzzy number*, Fuzzy Optimization and Decision Making, Vol. 5, pp. 227–243, 2006
- [86] Mańkowski C., *Implikacje logistyczne teorii chaosu*, LogForum Vol. 5, Issue 4, No 4, 2009
- [87] Mathworks, *Matlab Econometric toolbox User's Guide*, MathWorks Inc, 2015
- [88] Milewski R., Kwiatkowski E., *Podstawy ekonomii*, PWN, Warszawa 2008
- [89] Mohebbi E., *A replenishment model for the supply-uncertainty problem*, International Journal of Production Economics, Vol. 87, pp. 25–37, 2004
- [90] Mohebbi E., Posner M.J.M., *Multiple replenishment orders in continuous-review inventory system with lost sales*, Operation Research Letters, Vol. 30, pp. 117–129, 2002
- [91] Mohebbi E., Posner M.J.M., *Multiple replenishment orders in continuous-review inventory system with lost sales*, Operation Research Letters, Vol. 30, pp. 117–129, 2002
- [92] Mousavi, S. M., Sadegh J., Niaki S. T. A., Tavana M., *A bi-objective inventory optimization model under inflation and discount using tuned Pareto-based algorithms: NSGA-II, NPGA, and MOPSO*, Applied Soft Computing, Vol. 43, pp. 57–72, 2016
- [93] Movahed, K. K., Zhang, Z. H. *Robust design of (s, S) inventory policy parameters in supply chains with demand and lead time uncertainties*, International Journal of Systems Science, Vol.46, No.12, pp. 2258–2268, 2015
- [94] Muckstadt J. A., Sapra A., *Principles of Inventory Management*, Springer 2010
- [95] Nia A.R., Far M.H, Niaki S.T.A., *A hybrid genetic and imperialist competitive algorithm for green vendor managed inventory of multi - item multi - constraint EOQ model under shortage*. Applied Soft Computing, Vol. 30, pp. 353–364, 2015
- [96] Niemczyk A., *Zapasy i magazynowanie Tom 2 Magazynowanie*, Wyd. Biblioteka Logistyka, Poznań 2007
- [97] Niu B., Xie J., *A note on two-warehouse inventory model with deterioration under FIFO dispatch policy*, European Journal of Operational Research, Vol. 190, No.2, pp. 571–577, 2008
- [98] Osińska M., *Ekonometria Finansowa*, PWE, Warszawa, 2006
- [99] Osowski S., *Sieci neuronowe w ujęciu algorytmicznym*, Wydawnictwo Naukowo Techniczne, Warszawa 1996
- [100] Ouyang L.Y., Chuang B.R., *A periodic review inventory model involving variable lead-time with a service level constraint*, International Journal of System Science, Vol. 31, pp. 1209–1215, 2000
- [101] Özler A., Tan B. Karaesmen F., *Multi - product newsvendor problem with value-at-risk considerations*. Int.J.Prod.Econ, Vol.117, pp. 244–255, 2009



- [102] Pan J. Ch., Hsiao Y. C., Lee C. J., *Inventory models with fixed and variable lead time crash costs considerations*, Journal of the Operational Research Society Vol. 53, pp. 1048–1053, 2002
- [103] Pando, V., García-Laguna, J., San-José, L. A., Sicilia, J., *Maximizing profits in an inventory model with both demand rate and holding cost per unit time dependent on the stock level*. Computers & Industrial Engineering, Vol. 62, No.2, pp. 599–608, 2012
- [104] Pando, V., San-José, L. A., García-Laguna, J., Sicilia, J. *An economic lot-size model with non-linear holding cost hinging on time and quantity*. International Journal of Production Economics, Vol. 145, No.1, pp. 294–303, 2013
- [105] Park, K.J., Kyung, G., *Optimization of total inventory cost and order fill rate in a supply chain using PSO*, International Journal of Advanced Manufacturing Technology, Vol. 70, pp. 1533–1541, 2014
- [106] Pasandideh S.H.R., Niaki S.T.A., Asadi K., *Bi-objective optimization of a multi-product multi-period three-echelon supply chain problem under uncertain environments: NSGA-II and NREGA*, Information Sciences, Vol. 292, pp. 57–74, 2015
- [107] Piegat A., *Modelowanie i sterowanie rozmyte*, Akademicka Oficyna Wydawnicza EXIT, Warszawa 1999
- [108] Prasad S., *Classification of inventory models and systems*, International Journal of Production Economics, Vol. 34, No., pp. 209 – 222, 1994
- [109] Qi, L., Shen, Z.J.M., Snyder, L.V., *A continuous-review inventory model with disruptions at both supplier and retailer*, Production and Operations Management, Vol. 18, No.5, pp. 516–532, 2009
- [110] Qiu R., Shang J., Huang X., *Robust inventory decision under distribution uncertainty: A CVaR-based optimization approach*, Int. J. Production Economics, Vol. 153, pp. 13–23, 2014
- [111] Qu W.W., Bookbinder J.H., Iyogun P., *An integrated inventory-transportation system with modified periodic policy for multiple products*, European Journal of Operational Research, Vol. 115, pp. 254–269, 1999
- [112] Rasmussen S., *Risk and uncertainty, in: Production Economics, The Basic Theory of Production Optimisation*. Springer, pp. 161–171, 2011
- [113] Rau H., Wu M.Y., Wee H.-M., *Integrated inventory model for deteriorating items under a multi-echelon supply chain environment*, International Journal of Production Economics, Vol. 86, No.2, pp. 155–168, 2003
- [114] Roy A., Maiti M.K., Kar S., Maiti M., *Two storage inventory model with fuzzy deterioration over a random planning horizon*, Mathematical Computer Modeling, Vol. 46, pp. 1419–1433, 2007
- [115] Roy A., Pal S., Maiti M.K., *A production inventory model with stock dependent demand incorporating learning and inflationary effect in a random planning horizon: a fuzzy genetic algorithm with varying population size approach*, Computers & Industrial Engineering, Vol. 57, pp. 1324–1335, 2009
- [116] Rutkowska D., Pilinski M., Rutkowski L., *Sieci Neuronowe, algorytmy genetyczne i systemy rozmyte*, PWN 1997

- [117] Rutkowski K., *Logistyka Dystrybucji*, Szkoła Główna Handlowa Oficyna Wydawnicza, Warszawa 2005
- [118] Rutkowski L., *Metody i techniki sztucznej inteligencji*, PWN, Warszawa 2005
- [119] S.T. Liu, *Fuzzy profit measures for a fuzzy economic order quantity model*, Journal of Applied Mathematical Modeling, Vol.32, pp. 2076–2086, 2008
- [120] San-José, L. A., Sicilia, J., García-Laguna, J., *Analysis of an EOQ inventory model with partial backordering and non-linear unit holding cost*, Omega, Vol. 54, pp. 147–157, 2015
- [121] Sari K., *On the benefits of CPFR and VMI: A comparative simulation study*, International Journal of Production Economics, Vol. 113, No.2, pp.575–586, 2008
- [122] Schmitt A.J., Singh M., *A quantitative analysis of disruption risk in a multi-echelon supply chain*. Working paper, MIT Center for Transportation and Logistics, Cambridge, MA, 2009
- [123] Schwartz G., *Estimating the Dimension of a Model*, The annals of statistics, Vol. 6, No. 2, pp. 461-464, 1978
- [124] See, C. T., Sim, M. *Robust approximation to multi-period inventory management*, Operations Research, Vol.58, pp. 583–594, 2010
- [125] Shabudeen P., Sivakumar, G.D. *Algorithm for the design of single-stage adaptive Kanban system*, Computers & Industrial Engineering, Vol.54, pp. 800– 820, 2008
- [126] Silver E., *Inventory Management: An overview*, Canadian publications practical applications and suggestions for future research, Infor Vol.46, No.1, pp 15- 28, 2008
- [127] Simangunsong E., HendryL., Stevenson M., *Supply – chain uncertainty: a review and theoretical foundation for future research*, Int.J.Prod.Res. Vol.50, pp.4493–4523, 2012
- [128] Skowronek C, Wolski Z, *Logistyka w przedsiębiorstwie*, Polskie Wydawnictwo Ekonomiczne, 2012
- [129] Słownik ekonomiczny (online), <http://www.ekonom.info/1326-sterowanie/>
- [130] Snyder, L.V., Shen, Z.J.M., *Supply and demand uncertainty in multi-echelon supply chains*, Working paper, P.C. Rossin College of Engineering and Applied Sciences, Lehigh University, Bethlehem, PA, 2006
- [131] Snyder, L.V., Tomlin, B., *Inventory management with advanced warning of disruptions*, Working paper, P.C. Rossin College of Engineering and Applied Sciences, Lehigh University, Bethlehem, PA, 2008
- [132] Soni H. N., Joshi M., *A periodic review inventory model with controllable lead time and back order rate in fuzzy stochastic environment*, Fuzzy Inf. Eng., Vol. 7, pp.101 – 114, 2015
- [133] Srivastav A., Agraval S., *Multi-objective optimization of hybrid backorder inventory model*, Expert Systems With Applications, Vol.51, pp.76–84, 2016
- [134] Suer, G.A. F. Badurdeen, Dissanayake N., *Capacitated lot sizing by using multi-chromosome crossover strategy*, Journal of Intelligent Manufacturing, Vol.19, pp. 273–282, 2008
- [135] Tadeusiewicz R., *Sieci Neuronowe*, Akademicka Oficyna Wydawnicza, Warszawa 1993

- [136] Taleizadeh A.A., Aryanezhad M.B., Niaki S.T.A., *Optimizing multi-product multi-constraint inventory control systems with stochastic replenishment*, Journal of Applied Sciences, Vol.8, pp. 1228–1234, 2008
- [137] Taleizadeh A.A., Niaki S.T.A., Aryanezhad M.B., *Multi-product multi-constraint inventory control systems with stochastic replenishment and discount under fuzzy purchasing price and holding costs*, American Journal of Applied Sciences, Vol. 6, pp.1–12, 2009
- [138] Taleizadeh A.A., Niaki S.T.A., Hosseini V., *Optimizing multi-product multi-constraint bi-objective newsboy problem with discount by a hybrid method of goal programming and genetic algorithm*, Engineering Optimization, Vol. 41, pp. 437–457, 2009
- [139] Tamjidzad S., Mirmohammadi S H., *An optimal  $(r, Q)$  policy in a stochastic inventory system with all - units quantity discount and limited sharable resource*, European Journal of Operational Research, Vol. 247, pp.93–100, 2015
- [140] Tanthatemee, T., & Phruksaphanrat, B., *Fuzzy inventory control for uncertain demand and supply*, Proceedings of the International MultiConference of Engineers and Scientists, Vol. 2, pp.1224–1229, 2012
- [141] Thorsen A., Yao T., *Robust inventory control under demand and lead time uncertainty*, Springer Science+Business, Media New York, 2015
- [142] Tomlin, B., *On the value of mitigation and contingency strategies for managing supply chain disruption risks*, Management Science, Vol.52, No.5, pp.639–657, 2006
- [143] Twaróg J., *Mierniki i wskaźniki logistyczne*, Biblioteka Logistyka, Poznań 2003
- [144] Tyrrell Rockafellar R., Uryasev S., *Conditional value-at-risk for general loss distributions*, Journal of Banking & Finance, Vol.26, pp.1443–1471, 2002
- [145] Wacker J.G., Lummus R.R., *Sales forecasting for strategic resource planning*, International Journal of Operations & Production Management, , Vol. 22, No. 9. pp. 1017-1018, 2002
- [146] Wei, C., Li, Y., & Cai, X. (). *Robust optimal policies of production and inventory with uncertain return and demand*, International Journal of Production Economics, Vol. 134, No.2, pp.357–367, 2011
- [147] Wensig T., *Periodic Review Inventory Systems*, Springer 2011
- [148] Więcek P., *Intelligent approach to inventory control in logistics under uncertainty conditions*, Transportation Research Procedia, Vol. 18., pp. 164 – 171, 2016
- [149] Wolski S. Z., *Sterowanie Zapasami w przedsiębiorstwie*, PWE S.A., Warszawa 2000
- [150] Yager Ronald R., *Podstawy modelowania i sterowania rozmytego*, Warszawa, Wydawnictwo Naukowo-Techniczne 1995
- [151] Yin, S., & Nishi T., *A solution procedure for mixed - integer nonlinear programming formulation of supply chain planning with quantity discounts under demand uncertainty*, International Journal of Systems Science, Vol. 42, No. 11, 2014
- [152] Zanoni S., Zavanella L., *Single-vendor single-buyer with integrated transport inventory system: models and heuristics in the case of perishable goods*, Computers & Industrial Engineering, Vol.52, No.1, pp.107–123, 2007

- [153] Zeliaś A., Pawełek B., Wanat S., *Prognozowanie Ekonomiczne*, PWN Warszawa 2008
- [154] Zeliaś A., *Teoria Prognozy*, Polskie Wydawnictwo Ekonomiczne, 1997
- [155] Ziukov S., *A literature review on models of inventory management under uncertainty*, Business systems and economics, Vol. 5 No.1, pp. 26 – 35, 2015

## SPIS RYSUNKÓW

<b>RYS. 1. PODZIAŁ MAGAZYNÓW</b> .....	17
<b>RYS. 2. PUNKTY ROZDZIAŁU W ŁAŃCUCHU DOSTAW</b> .....	18
<b>RYS. 3. KONSOLIDACYJNA FUNKCJA MAGAZYNU</b> .....	18
<b>RYS. 4. DEKONSOLIDACYJNA FUNKCJA MAGAZYNU</b> .....	19
<b>RYS. 5. FUNKCJA PRZEŁADUNKU KOMPLETACYJNEGO W MAGAZYNIE</b> .....	19
<b>RYS. 6. STRUKTURA KOSZTÓW OBSŁUGI ZAPASÓW</b> .....	23
<b>RYS. 7. KLASYFIKACJA MODELI ZAPASÓW</b> .....	25
<b>RYS. 8. SCHEMAT MODELU POZIOMU ZAMAWIANIA</b> .....	26
<b>RYS. 9. SCHEMAT MODELU CYKLU ZAMAWIANIA</b> .....	26
<b>RYS. 10. POZIOM ZAPASÓW W CZASIE DLA MODELU EOQ</b> .....	27
<b>RYS. 11. ZUŻYCIE ZAPASU W CZASIE W SYTUACJI ZAŁOŻENIA PLANOWEGO NIEDOBORU</b> .....	29
<b>RYS. 12. CECHY PARAMETRÓW STEROWANIA W ZALEŻNOŚCI OD PRZYJĘTEGO MODELU ZAPASÓW</b> .....	32
<b>RYS. 13. GRAFICZNA INTERPRETACJA POZIOMU OBSŁUGI KLIENTA POK<sub>1</sub></b> .....	35
<b>RYS. 14. IDEA INTERPRETACJI POZIOMU OBSŁUGI KLIENTA W SENSIE ILOŚCIOWYM</b> .....	36
<b>RYS. 15. REKOMENDACJE DOTYCZĄCE WYBORU PODEJŚĆ DO STEROWANIA ZAPASAMI W ZALEŻNOŚCI OD KLAS PRODUKTÓW</b> .....	41
<b>RYS. 16. LOSOWE CZYNNIKI ODDZIAŁUJĄCE NA NIEOKREŚLONOŚĆ POPYTU W POJEDYNCZYCH OGNIWACH SIECI DOSTAW</b> .....	50
<b>RYS. 17. ZNIEKSZTAŁCENIE INFORMACJI O RZECZYWISTEJ WIELKOŚCI POPYTU PROPAGUJĄCE WZDŁUŻ ŁAŃCUCHA DOSTAW</b> .....	51
<b>RYS. 18. ARCHITEKTURA PROPONOWANEGO PODEJŚCIA DO ROZWIĄZANIA PROBLEMU STEROWANIA ZAPASAMI W WARUNKACH NIEPEWNOŚCI</b> .....	62
<b>RYS. 19. MODEL POJEDYNCZEGO NIELINIOWEGO NEURONU</b> .....	68
<b>RYS. 20. STRUKTURA WYKORZYSTYWANEJ SIECI NEURONOWEJ</b> .....	71
<b>RYS. 21. PROCEDURA DOBORU STRUKTURY SIECI NEURONOWEJ</b> .....	72
<b>RYS. 22. NAJWAŻNIEJSZE ETAPY BUDOWY PROGNOZY POPYTU</b> .....	73
<b>RYS. 23. STRUKTURA MODUŁU ROZUMOWANIA ROZMYTEGO DLA ROZWAŻANEGO PROBLEMU ZAPASÓW</b> ..	78
<b>RYS. 24. PRZYJĘTY SCHEMAT WNIOSKOWANIA W MODELU ROZMYTEGO</b> .....	79
<b>RYS. 25. PARAMETRY WEJŚCIOWE SYSTEMU OPISANE PRZY POMOCY ZBIORÓW ROZMYTYCH</b> .....	80
<b>RYS. 26. PARAMETRY WYJŚCIOWE SYSTEMU OPISANE PRZY POMOCY ZBIORÓW ROZMYTYCH</b> .....	81
<b>RYS. 27. SPOSÓB AKTUALIZACJI PARAMETRÓW FUNKCJI PRZYNALEŻNOŚCI DLA ZMIENNYCH WYJŚCIOWYCH SYSTEMU</b> .....	82
<b>RYS. 28. PODSTAWOWY SCHEMAT DZIAŁANIA ALGORYTMU GENETYCZNEGO</b> .....	84
<b>RYS. 29. PRZYKŁAD STRUKTURY CHROMOSOMU</b> .....	85
<b>RYS. 30. DZIAŁANIE DWUPUNKTOWEGO OPERATORA KRZYŻOWANIA</b> .....	85



<b>RYS. 31.</b> ILUSTRACJA ZBIORU KOMPROMISÓW W PRZESTRZENI KRYTERIÓW.....	86
<b>RYS. 32.</b> PRZYKŁADOWE ODDZIAŁYWANIA NA SYSTEM ZAPASÓW W OGNIWIE LOGISTYCZNYM.....	90
<b>RYS. 33.</b> PROBLEM STEROWANIA ZAPASAMI W STRUKTURZE ILS .....	92
<b>RYS. 34.</b> SPOSÓB TESTOWANIA PROGNOZ .....	94
<b>RYS. 35.</b> PRZYKŁADOWE ZESTAWY DANYCH WYKORZYSTANE W ANALIZIE.....	95
<b>RYS. 36.</b> WYKAZ NAJISTOTNIEJSZYCH HARMONIK SZEREGU DLA ZESTAWU DANYCH NR 1 .....	96
<b>RYS. 37.</b> DOPASOWANIE SKŁADOWEJ SPEKTRALNEJ DO WARTOŚCI RZECZYWISTYCH SZEREGU .....	97
<b>RYS. 38.</b> WYKRESY FUNKCJI AUTOKORELACJI ACF ORAZ AUTOKORELACJI CZĄSTKOWEJ PACF DLA ROZWAŻANEGO PRZYKŁADU.....	98
<b>RYS. 39.</b> EFEKTYWNOŚĆ PROCESU UCZENIA SIECI.....	99
<b>RYS. 40.</b> HISTOGRAM BŁĘDÓW ODPOWIEDZI SZTUCZNEJ SIECI NEURONOWEJ.....	100
<b>RYS. 41.</b> DOPASOWANIE WARTOŚCI PROGNOZ DWUDNIOWYCH SZEREGU NR 1 DO DANYCH RZECZYWISTYCH.....	102
<b>RYS. 42.</b> WARTOŚCI $Q_{0.25}$ BŁĘDÓW MAPE WYZNACZONYCH PROGNOZ DWUDNIOWYCH.....	103
<b>RYS. 43.</b> WARTOŚCI $Q_{0.5}$ BŁĘDÓW MAPE WYZNACZONYCH PROGNOZ DWUDNIOWYCH .....	103
<b>RYS. 44.</b> WARTOŚCI $Q_{0.75}$ BŁĘDÓW MAPE WYZNACZONYCH PROGNOZ DWUDNIOWYCH.....	104
<b>RYS. 45.</b> ŚREDNIE WARTOŚCI BŁĘDU MAPE DLA PROGNOZ DWUDNIOWYCH.....	104
<b>RYS. 46.</b> WARTOŚCI $Q_{0.25}$ BŁĘDÓW MAPE WYZNACZONYCH PROGNOZ TRZYDNIOWYCH.....	105
<b>RYS. 47.</b> WARTOŚCI $Q_{0.5}$ BŁĘDÓW MAPE WYZNACZONYCH PROGNOZ TRZYDNIOWYCH .....	105
<b>RYS. 48.</b> WARTOŚCI $Q_{0.75}$ BŁĘDÓW MAPE WYZNACZONYCH PROGNOZ TRZYDNIOWYCH .....	105
<b>RYS. 49.</b> ŚREDNIE WARTOŚCI BŁĘDU MAPE DLA PROGNOZ TRZYDNIOWYCH.....	106
<b>RYS. 50.</b> WARTOŚCI $Q_{0.25}$ BŁĘDÓW MAPE WYZNACZONYCH PROGNOZ CZTERODNIOWYCH.....	106
<b>RYS. 51.</b> WARTOŚCI $Q_{0.5}$ BŁĘDÓW MAPE WYZNACZONYCH PROGNOZ CZTERODNIOWYCH .....	107
<b>RYS. 52.</b> WARTOŚCI $Q_{0.75}$ BŁĘDÓW MAPE WYZNACZONYCH PROGNOZ CZTERODNIOWYCH.....	107
<b>RYS. 53.</b> ŚREDNIE WARTOŚCI BŁĘDU MAPE DLA PROGNOZ CZTERODNIOWYCH .....	107
<b>RYS. 54.</b> WARTOŚCI $Q_{0.25}$ BŁĘDÓW MAPE WYZNACZONYCH PROGNOZ PIĘCIODNIOWYCH .....	108
<b>RYS. 55.</b> WARTOŚCI $Q_{0.5}$ BŁĘDÓW MAPE WYZNACZONYCH PROGNOZ PIĘCIODNIOWYCH.....	108
<b>RYS. 56.</b> WARTOŚCI $Q_{0.75}$ BŁĘDÓW MAPE WYZNACZONYCH PROGNOZ PIĘCIODNIOWYCH .....	109
<b>RYS. 57.</b> ŚREDNIE WARTOŚCI BŁĘDU MAPE DLA PROGNOZ PIĘCIODNIOWYCH .....	109
<b>RYS. 58.</b> ZALEŻNOŚĆ WZGLĘDNEGO PROCENTOWEGO BŁĘDU PROGNOZY OD WSPÓŁCZYNNIKA ZMIENNOŚCI ORAZ HORYZONTU PROGNOZY $h$ DLA ROZPATRYWANEGO ZESTAWU DANYCH.....	111
<b>RYS. 59.</b> PROCEDURA OPTIMALIZACYJNA BAZY REGUŁ ROZMYTYCH.....	113
<b>RYS. 60.</b> ZBIEŻNOŚĆ ZASTOSOWANEGO ALGORYTMU GENETYCZNEGO DLA RÓŻNYCH KONFIGURACJI ROZMIARU POPULACJI I LICZBY ITERACJI .....	115
<b>RYS. 61.</b> WPLYW PAR ZMIENNYCH WEJŚCIOWYCH SYSTEMU NA WIELKOŚĆ DOSTAWY.....	124
<b>RYS. 62.</b> WPLYW PAR ZMIENNYCH WEJŚCIOWYCH SYSTEMU NA POZIOM PONOWNEGO ZAMAWIANIA .....	125
<b>RYS. 63.</b> ZMIENNOŚĆ WARTOŚCI WAG REGUŁ W ZALEŻNOŚCI OD ANALIZOWANEGO WARIANTU .....	126



<b>RYS. 64.</b> SCHEMAT SYMULACJI POZIOMU ZAPASÓW WEDŁUG PROPONOWANEGO PODEJŚCIA .....	128
<b>RYS. 65.</b> SYMULACJA POZIOMU ZAPASÓW W OKRESIE 200 DNI DLA PRZYKŁADOWEGO ZESTAWU DANYCH .....	128
<b>RYS. 66.</b> WRAŻLIWOŚĆ METOD NA ROSNĄCY POZIOM ZMIENNOŚCI PARAMETRÓW OPISANY KOLEJNYMI WARIANTAMI.....	136

## SPIS TABEL

<b>TABELA 1. NAJWAŻNIEJSZE ZALETY I WADY MODELI OKRESOWEGO I CIĄGŁEGO</b>	
<b>MONITOROWANIA ZAPASÓW</b> .....	34
<b>TABELA 2. WYKORZYSTANIE PODEJŚCIA STOCHASTYCZNEGO W MODELOWANIU PARAMETRÓW</b>	
<b>NIEPEWNYCH PROBLEMU ZAPASÓW NA PODSTAWIE STRATEGII ZAMAWIANIA (R,T) I (R,Q)</b> .....	57
<b>TABELA 3. WYKORZYSTANIE ŚRODOWISKA ROZMYTEGO W MODELOWANIU WYBRANYCH PARAMETRÓW</b>	
<b>NIEPEWNYCH W STEROWANIU ZAPASAMI</b> .....	59
<b>TABELA 4. WARTOŚCI KRYTERIUM INFORMACYJNEGO SCHWARTZ'A DLA WARIANTÓW MODELU</b> .....	98
<b>TABELA 5. WYZNACZONE STRUKTURY SIECI NEURONOWYCH DLA WSZYSTKICH ZESTAWÓW DANYCH</b> .....	101
<b>TABELA 6. ZBIORCZE ZESTAWIENIE WZGLĘDNYCH PROCENTOWYCH BŁĘDÓW PROGNOZ</b> .....	110
<b>TABELA 7. ZBIORCZE ZESTAWIENIE PIERWIASTKA ŚREDNIOKWADRATOWEGO BŁĘDU PROGNOZ</b> .....	110
<b>TABELA 8. ANALIZOWANE WARIANTY SYMULACJI</b> .....	112
<b>TABELA 9. GÓRNE I DOLNE OSZACOWANIE WARTOŚCI KRYTERIÓW DLA WARIANTU 1</b> .....	114
<b>TABELA 10. ZBIÓR NAJWAŻNIEJSZYCH REGUŁ Z UŚREDNIONYMI WAGAMI DLA WARIANTU 1</b> .....	117
<b>TABELA 11. STRUKTURA WARTOŚCI ODCHYLEŃ STANDARDOWYCH W POPULACJI</b>	
<b>WAG REGUŁ ROZMYTYCH</b> .....	126
<b>TABELA 12. WYNIKI SYMULACJI POZIOMU ZAPASÓW DLA 25 ZESTAWÓW DANYCH ORAZ</b>	
<b>WARIANTÓW 1-3</b> .....	130
<b>TABELA 13. WYNIKI SYMULACJI POZIOMU ZAPASÓW DLA 25 ZESTAWÓW DANYCH</b>	
<b>ORAZ WARIANTÓW 4-6</b> .....	131
<b>TABELA 14. WYNIKI SYMULACJI POZIOMU ZAPASÓW DLA 25 ZESTAWÓW DANYCH</b>	
<b>ORAZ WARIANTÓW 7-8</b> .....	132
<b>TABELA 15. ZBIORCZE, UŚREDNIONE WYNIKI SYMULACJI</b> .....	133
<b>TABELA 16. PROCENTOWA POPRAWA +/- POGORSZENIE OTRZYMANYCH WYNIKÓW</b>	
<b>DLA PROPONOWANEGO PODEJŚCIA WZGLĘDEM METOD PORÓWNAWCZYCH</b> .....	134

## ZAŁĄCZNIK A.

Zaprezentowane w załączniku A Tabele. A.1. – A.4. przedstawiają strukturę procentowych błędów prognozowania dla zaproponowanego w pracy modelu hybrydowego oraz trzech metod porównawczych. Analizie zostało poddanych 25 zestawów danych. Prognozy były budowane dla horyzontów  $h=2, 3, 4$  oraz 5 dni. Okres analizy obejmował jeden rok.

**Tabela. A.1.** Wartości kwartyli procentowego błędu prognozy dla kolejnych zestawów danych i horyzontu prognozowania  $h=2$  dni.

Horyzont prognozowania $h=2$ dni								
Kwartył Q0.25					Kwartył Q0.5			
Zestaw Danych	Model Hybrydowy	Model Holta	Srednia Ruchoma	Model Wintersa	Model Hybrydowy	Model Holta	Srednia Ruchoma	Model Wintersa
Z1	9,1	10,9	14,6	30,6	14,0	16,4	22,3	41,4
Z2	9,0	10,8	13,7	14,2	16,8	17,4	22,9	22,2
Z3	8,0	11,1	14,0	19,4	13,2	16,0	23,0	31,5
Z4	9,1	11,8	15,9	35,0	15,6	18,6	23,3	45,4
Z5	13,7	20,3	25,7	56,3	23,4	31,3	55,9	71,4
Z6	13,3	19,5	24,5	49,4	22,7	32,9	54,0	62,5
Z7	6,7	10,1	14,2	11,3	11,8	19,1	23,9	20,7
Z8	9,8	25,7	25,5	94,1	21,3	39,7	70,1	96,4
Z9	8,1	10,7	15,1	31,6	14,1	16,0	22,4	40,5
Z10	7,9	13,5	16,7	25,3	13,7	22,0	25,9	45,2
Z11	8,9	16,4	20,9	15,8	17,8	24,0	35,6	25,9
Z12	9,7	13,5	19,8	23,0	16,6	20,3	30,1	41,6
Z13	18,0	20,4	28,0	29,6	26,7	32,6	45,3	44,5
Z14	17,6	18,1	30,3	43,3	26,5	28,8	44,4	56,6
Z15	15,0	16,0	26,6	21,0	24,5	25,8	37,7	38,5
Z16	13,4	16,6	25,2	40,6	23,6	26,8	38,9	54,7
Z17	10,2	15,0	22,2	26,6	17,9	26,7	33,2	41,3
Z18	14,8	18,4	28,2	23,8	25,6	30,3	46,0	45,3
Z19	10,9	11,4	15,2	17,0	17,6	18,4	25,1	35,8
Z20	10,3	16,1	18,2	14,9	15,8	24,6	30,4	33,2
Z21	11,1	20,2	25,1	24,4	18,6	33,1	46,6	37,4
Z22	18,1	23,3	27,7	37,8	30,6	37,0	43,6	86,2
Z23	14,7	19,7	24,4	41,5	23,3	30,6	37,7	59,5
Z24	17,1	22,1	25,1	30,2	32,3	32,9	39,7	50,1
Z25	12,1	23,0	23,3	26,2	23,7	34,8	35,3	46,8
Kwartył Q0.75					Wartość średnia błędu MAPE			
Zestaw Danych	Model Hybrydowy	Model Holta	Srednia Ruchoma	Model Wintersa	Model Hybrydowy	Model Holta	Srednia Ruchoma	Model Wintersa
Z1	22,3	23,2	36,3	49,6	17,5	18,9	30,2	40,4
Z2	25,6	27,2	42,2	30,6	20,2	21,4	74,9	24,0
Z3	18,5	25,9	34,0	39,7	14,6	20,7	30,5	31,0
Z4	21,6	27,7	44,0	55,9	16,6	23,0	221,5	45,1
Z5	38,9	58,6	192,6	77,5	31,6	51,6	219,8	67,6
Z6	34,1	55,4	106,7	71,6	28,4	49,8	95,0	59,2
Z7	20,1	27,1	42,5	37,5	15,6	25,9	121,0	26,3
Z8	41,2	80,6	249,9	97,3	32,8	60,9	283,8	95,5
Z9	22,9	27,5	39,4	50,5	18,5	22,6	146,3	41,8
Z10	22,8	32,4	38,9	78,0	18,9	38,0	269,7	62,0
Z11	31,8	37,8	52,9	49,0	24,5	31,8	65,4	36,5
Z12	28,2	33,0	46,0	71,4	20,7	26,9	74,4	51,3
Z13	42,4	48,5	76,4	61,3	34,3	41,4	85,4	44,6
Z14	36,4	51,5	73,6	69,7	30,0	40,5	133,4	55,2
Z15	37,8	40,0	55,0	63,8	29,4	36,5	57,3	56,7
Z16	36,8	43,5	63,5	69,0	27,8	35,4	60,2	53,5
Z17	30,7	40,5	53,1	57,0	24,2	35,0	72,9	43,4
Z18	38,2	46,5	71,6	88,4	33,3	42,8	79,4	69,6
Z19	28,3	28,7	42,1	61,7	22,0	24,6	67,9	41,5
Z20	24,7	39,3	44,9	51,8	21,2	31,7	57,5	36,4
Z21	33,0	50,8	69,7	64,0	26,0	42,4	79,0	44,6
Z22	51,5	60,5	86,5	204,5	38,1	52,2	112,7	151,7
Z23	36,7	50,0	62,5	73,0	27,4	38,8	76,9	56,0
Z24	50,7	53,2	69,9	75,9	38,5	43,6	131,8	60,9
Z25	37,1	54,2	64,1	82,4	27,3	47,6	79,6	68,6

**Tabela. A.2.** Wartości kwartyli procentowego błędu prognozy dla kolejnych zestawów danych i horyzontu prognozowania  $h=3$  dni.

Horyzont prognozowania $h=3$ dni								
Kwartyl Q0.25					Kwartyl Q0.5			
Zestaw Danych	Model Hybrydowy	Model Holta	Srednia Ruchoma	Model Wintersa	Model Hybrydowy	Model Holta	Srednia Ruchoma	Model Wintersa
Z1	10,7	11,8	17,3	33,6	15,8	17,3	27,1	40,9
Z2	11,9	11,4	16,7	14,0	17,7	17,9	27,2	22,1
Z3	7,8	11,6	16,5	20,7	14,1	17,3	23,8	30,1
Z4	8,8	13,9	18,4	33,6	15,4	19,9	30,3	44,6
Z5	20,4	23,5	39,4	66,9	29,2	33,5	75,3	75,7
Z6	15,5	24,6	29,3	51,3	23,1	34,3	62,6	59,4
Z7	10,6	12,2	16,4	12,6	16,6	19,3	25,3	19,3
Z8	17,5	29,6	39,7	95,7	27,3	52,1	93,6	97,0
Z9	9,2	11,5	15,4	26,9	15,8	17,0	24,6	38,5
Z10	10,3	15,4	19,3	34,9	16,8	22,3	27,6	66,9
Z11	12,2	17,3	26,0	18,0	20,8	24,9	40,4	29,3
Z12	12,4	14,5	22,9	26,6	18,4	22,0	30,0	49,4
Z13	20,8	21,6	29,8	29,7	27,8	32,2	49,3	42,2
Z14	17,3	21,6	27,6	38,8	25,8	32,7	48,6	56,9
Z15	18,4	17,0	26,2	25,1	30,0	26,9	41,0	48,7
Z16	17,3	19,9	30,2	50,6	26,3	29,5	48,4	62,6
Z17	12,5	18,8	23,5	25,3	20,6	26,8	35,3	41,3
Z18	21,9	21,2	34,3	26,3	30,3	32,3	55,9	56,1
Z19	11,5	13,3	19,5	23,3	17,0	19,0	26,0	38,2
Z20	13,1	18,8	25,3	18,1	19,4	26,7	37,1	31,3
Z21	14,1	25,4	29,9	25,2	24,6	34,6	49,1	40,4
Z22	18,8	28,2	33,8	53,0	33,3	41,4	47,3	123,1
Z23	19,4	21,5	29,2	50,3	27,9	35,5	41,2	65,7
Z24	18,2	24,8	33,4	32,8	27,8	32,0	44,3	46,5
Z25	15,4	23,5	27,9	31,1	26,6	35,0	40,8	51,9
Kwartyl Q0.75					Wartość średnia błędu MAPE			
Zestaw Danych	Model Hybrydowy	Model Holta	Srednia Ruchoma	Model Wintersa	Model Hybrydowy	Model Holta	Srednia Ruchoma	Model Wintersa
Z1	21,6	23,0	41,3	48,8	17,3	19,3	31,5	41,5
Z2	28,1	28,3	45,0	28,8	22,1	21,6	75,5	23,6
Z3	19,0	26,0	39,9	37,8	15,9	21,2	33,9	30,4
Z4	22,3	27,6	50,5	53,9	16,5	23,0	224,7	43,2
Z5	44,9	57,3	164,6	81,3	44,0	51,6	427,3	73,6
Z6	38,8	52,6	119,2	69,1	31,3	50,8	102,0	58,4
Z7	29,3	32,8	39,7	38,6	23,7	26,4	129,3	26,4
Z8	39,0	83,9	247,8	97,8	35,7	66,0	742,9	96,5
Z9	26,1	27,6	40,3	47,7	20,4	23,2	581,6	39,5
Z10	29,0	34,3	38,1	108,0	26,6	39,2	217,7	76,3
Z11	33,9	39,6	64,4	54,9	25,6	33,1	82,9	38,2
Z12	29,4	33,5	51,2	78,4	22,4	27,2	68,7	59,8
Z13	43,3	53,3	84,1	58,2	34,9	41,8	88,7	43,4
Z14	40,2	47,6	67,5	67,0	35,6	41,3	101,4	53,6
Z15	46,6	41,0	60,4	74,8	43,8	37,0	58,3	64,4
Z16	39,9	44,6	81,2	73,3	31,3	36,5	65,6	62,3
Z17	31,2	41,0	51,8	54,8	25,4	35,6	71,8	42,7
Z18	43,2	46,2	97,7	125,7	35,6	44,0	87,3	87,5
Z19	27,4	31,2	42,6	63,9	21,4	25,3	67,6	43,9
Z20	28,1	37,2	53,7	51,0	24,7	33,1	59,8	36,8
Z21	40,2	55,6	73,4	61,7	29,9	43,8	84,7	45,8
Z22	47,7	57,3	87,9	250,0	38,8	53,9	105,0	171,2
Z23	41,4	47,0	66,7	77,6	35,5	40,4	86,5	63,9
Z24	42,1	50,5	68,7	72,7	32,6	45,3	121,1	56,3
Z25	41,1	54,1	70,8	112,7	32,1	48,8	84,2	74,6

**Tabela. A.3.** Wartości kwartyli procentowego błędu prognozy dla kolejnych zestawów danych i horyzontu prognozowania  $h=4$  dni

Horyzont prognozowania $h=4$ dni								
Kwartyl Q0.25					Kwartyl Q0.5			
Zestaw Danych	Model Hybrydowy	Model Holta	Srednia Ruchoma	Model Wintersa	Model Hybrydowy	Model Holta	Srednia Ruchoma	Model Wintersa
Z1	11,7	11,4	19,3	36,6	14,7	17,3	26,7	43,7
Z2	11,6	12,4	21,1	13,5	17,7	19,9	31,1	21,3
Z3	10,4	11,4	18,0	21,5	13,9	17,8	26,9	27,7
Z4	10,1	14,5	19,8	33,6	15,7	19,5	32,3	42,9
Z5	17,5	28,0	58,9	74,9	22,6	36,0	99,6	82,0
Z6	19,0	26,3	44,8	51,4	25,2	37,9	72,8	56,7
Z7	11,8	13,7	18,7	13,3	16,1	19,0	28,7	19,3
Z8	23,8	34,9	69,4	97,1	29,6	49,2	142,2	98,1
Z9	10,5	11,6	16,0	28,7	16,2	18,6	24,1	38,2
Z10	11,1	17,1	20,6	39,1	17,4	21,6	27,4	75,5
Z11	18,1	20,0	31,8	20,3	25,5	24,2	39,7	29,1
Z12	18,2	16,0	23,5	27,4	23,9	21,8	32,8	47,1
Z13	30,2	22,9	36,7	31,9	37,8	35,9	51,5	44,4
Z14	20,1	21,1	31,5	44,0	28,6	31,1	48,0	55,2
Z15	33,6	19,2	30,8	30,0	45,7	26,1	38,6	54,3
Z16	31,8	18,0	29,9	66,0	43,2	27,5	49,4	72,8
Z17	17,2	20,5	27,3	26,8	22,8	27,6	38,1	42,8
Z18	31,0	22,1	38,5	32,7	36,6	30,8	55,2	71,3
Z19	13,6	13,8	18,9	22,8	19,5	20,1	28,4	38,7
Z20	16,6	18,9	25,7	22,2	21,6	27,5	35,3	31,9
Z21	17,2	25,4	36,9	29,5	27,2	39,1	51,5	39,7
Z22	25,7	28,4	37,9	51,8	36,7	40,6	57,7	121,5
Z23	25,3	24,1	30,4	65,2	31,5	33,0	47,6	75,2
Z24	20,4	23,6	32,7	37,9	27,8	33,9	48,3	54,1
Z25	18,4	24,8	32,1	32,9	27,4	36,6	45,7	54,0
Kwartyl Q0.75					Wartość średnia błędu MAPE			
Zestaw Danych	Model Hybrydowy	Model Holta	Srednia Ruchoma	Model Wintersa	Model Hybrydowy	Model Holta	Srednia Ruchoma	Model Wintersa
Z1	19,7	23,8	41,5	51,0	16,8	19,4	31,7	44,1
Z2	24,6	24,9	44,7	31,6	20,6	21,4	72,9	24,3
Z3	23,7	26,3	36,8	38,9	18,1	20,5	32,4	30,6
Z4	22,1	28,0	49,2	53,3	17,2	22,7	225,0	43,4
Z5	32,3	53,2	164,8	86,2	39,2	52,4	425,9	80,4
Z6	39,3	50,1	121,4	65,8	31,1	47,2	117,5	57,6
Z7	26,4	30,5	54,4	37,2	22,3	26,1	128,9	26,2
Z8	47,9	72,6	254,2	98,7	37,7	67,9	608,5	97,7
Z9	25,9	29,4	40,5	46,2	20,1	23,3	551,9	38,9
Z10	27,8	33,3	45,4	118,5	26,6	39,4	221,0	85,8
Z11	33,7	35,9	62,6	52,2	28,5	33,4	79,5	38,1
Z12	30,8	35,6	46,5	78,3	26,4	28,1	65,8	59,1
Z13	48,3	52,5	81,8	53,3	44,0	41,9	89,2	44,4
Z14	44,7	51,8	81,8	67,5	35,4	40,8	95,4	54,9
Z15	62,7	37,6	62,6	81,4	50,9	37,7	59,3	69,7
Z16	59,4	45,9	77,2	80,1	48,3	36,5	62,2	72,3
Z17	33,6	39,3	58,7	52,6	29,5	35,0	82,0	43,0
Z18	60,3	50,4	79,8	135,0	48,7	43,9	85,1	101,4
Z19	27,9	28,6	38,7	64,5	22,4	24,9	71,0	44,2
Z20	31,8	39,4	57,6	47,2	26,6	32,3	60,9	36,5
Z21	39,4	52,0	73,6	60,7	32,1	43,7	83,5	45,8
Z22	67,8	63,6	104,2	273,3	49,3	52,8	110,9	177,2
Z23	44,5	52,2	76,0	84,7	38,3	40,6	78,6	74,0
Z24	46,8	49,7	71,6	70,1	36,7	43,1	128,8	55,6
Z25	42,0	53,2	85,4	106,4	35,1	48,8	87,9	74,2

**Tabela. A.4.** Wartości kwartyli procentowego błędu prognozy dla kolejnych zestawów danych i horyzontu prognozowania  $h=5$  dni

Horyzont prognozowania $h=5$ dni								
Kwartyl Q0.25					Kwartyl Q0.5			
Zestaw Danych	Model Hybrydowy	Model Holta	Srednia Ruchoma	Model Wintersa	Model Hybrydowy	Model Holta	Srednia Ruchoma	Model Wintersa
Z1	10,9	14,0	20,1	39,2	14,0	16,1	25,3	45,8
Z2	12,0	12,9	17,2	15,0	16,9	18,0	31,8	23,1
Z3	10,8	13,5	20,6	22,0	16,5	18,1	25,5	27,0
Z4	11,2	15,2	23,3	32,1	16,4	19,3	32,0	42,8
Z5	17,5	27,2	66,2	84,5	23,7	36,6	83,0	87,7
Z6	20,5	29,0	52,6	50,6	27,8	35,5	71,4	56,1
Z7	12,6	13,4	19,9	14,2	17,9	19,4	28,8	22,5
Z8	22,8	36,1	83,0	98,1	35,6	48,5	151,3	99,1
Z9	12,0	12,4	18,4	26,1	15,7	17,4	26,9	35,8
Z10	12,5	15,6	21,2	41,7	19,1	21,5	28,2	82,6
Z11	18,2	18,9	29,6	20,1	25,6	24,4	38,7	30,5
Z12	17,0	15,2	22,6	30,2	22,4	22,4	30,7	47,3
Z13	33,3	25,7	36,7	33,4	46,9	35,0	50,8	42,1
Z14	25,5	21,9	35,5	43,8	33,3	31,9	45,6	57,3
Z15	40,0	19,1	32,7	32,3	54,2	29,3	40,6	55,8
Z16	38,7	19,9	32,0	76,1	51,9	29,9	44,7	82,8
Z17	19,3	20,3	27,2	30,6	26,5	28,5	38,9	43,2
Z18	31,0	23,3	41,1	36,3	45,9	34,8	60,4	92,3
Z19	14,9	13,6	19,8	21,4	21,3	20,8	27,3	44,2
Z20	17,1	17,7	26,4	20,0	22,9	25,4	37,0	30,8
Z21	19,0	25,5	39,0	28,2	27,3	37,5	49,9	40,6
Z22	27,4	26,3	40,8	56,1	46,0	42,1	59,0	137,4
Z23	27,1	26,0	31,6	79,2	38,3	35,4	46,3	84,9
Z24	19,1	24,5	33,8	41,3	31,0	34,4	45,2	57,7
Z25	23,7	24,4	30,9	33,3	31,8	33,1	48,0	53,2
Kwartyl Q0.75					Wartość średnia błędu MAPE			
Zestaw Danych	Model Hybrydowy	Model Holta	Srednia Ruchoma	Model Wintersa	Model Hybrydowy	Model Holta	Srednia Ruchoma	Model Wintersa
Z1	21,1	22,2	39,7	52,3	13,9	19,2	31,1	46,6
Z2	25,0	24,6	40,9	32,3	17,3	21,2	73,2	25,4
Z3	24,1	26,0	38,1	36,7	16,3	21,1	31,3	30,6
Z4	23,4	25,6	44,7	52,2	25,2	22,0	147,1	43,3
Z5	41,0	49,9	153,8	92,3	37,0	52,2	447,0	88,1
Z6	36,7	49,2	108,6	62,8	27,7	45,8	104,8	56,1
Z7	30,2	27,2	43,9	33,1	20,8	25,5	134,2	26,0
Z8	46,8	67,8	223,0	99,7	33,2	64,1	765,8	98,9
Z9	28,3	27,9	40,8	45,3	18,9	23,2	656,1	38,2
Z10	27,8	30,2	42,9	142,1	31,9	38,8	256,0	97,9
Z11	36,9	37,3	61,5	55,6	26,7	32,4	72,4	38,1
Z12	31,7	35,5	45,0	72,9	22,9	27,5	69,6	58,3
Z13	63,1	51,3	83,3	60,1	42,2	41,3	92,0	45,3
Z14	45,5	50,4	66,9	67,3	32,5	39,6	133,7	56,1
Z15	70,2	44,1	66,7	91,4	52,2	38,4	61,7	75,2
Z16	65,5	41,5	69,0	91,3	47,6	34,8	58,4	82,7
Z17	37,1	36,8	52,9	54,8	27,2	34,6	80,5	44,2
Z18	75,9	47,6	89,8	163,3	53,9	43,6	89,1	112,9
Z19	31,0	29,6	39,0	61,7	19,9	24,6	57,8	44,4
Z20	40,5	35,8	47,6	47,9	25,0	31,6	58,0	36,5
Z21	44,5	46,7	78,4	62,9	29,7	43,1	79,8	45,8
Z22	72,9	71,3	101,8	281,7	45,8	52,7	116,6	182,9
Z23	50,8	45,2	79,7	91,1	36,7	39,9	73,9	84,8
Z24	42,7	51,8	79,4	74,0	30,2	41,9	123,5	58,4
Z25	53,2	54,9	82,9	111,7	36,5	46,0	85,9	74,2



**ZALĄCZNIK B.**

Przedstawione w załączniku B Tabele. B.1.-B.5 zawierają zoptymalizowane uśrednione wartości wag dla grupy 235 najistotniejszych reguł rozmytych kolejno dla 8 wariantów.

**Tabela. B.1.** Wartości wag zbioru reguł rozmytych dla kolejnych rozważanych wariantów

Numer reguły	WEJŚCIA SYSTEMU				WYJŚCIA SYSTEMU		WAGI REGUŁ DLA WARIANTÓW							
	Prognozowany popyt	Aktualny poziom zapasów	Czas dostawy	Jakość dostawy	Aktualna wielkość zamówienia	Poziom zamawiania	W1	W2	W3	W4	W5	W6	W7	W8
1	mały	mały	krótki	niska	mała	niski	1,48	1,7	1,45	0,79	1,79	1,97	2,94	0,79
2	mały	mały	krótki	niska	mała	średni	1,20	1,38	1,56	2,02	1,13	3,27	1,08	1,35
3	mały	mały	krótki	niska	mała	wysoki	0,19	0,22	1,54	0,80	0,30	1,25	1,62	3,03
4	mały	mały	krótki	niska	średnia	niski	1,02	1,17	4,35	0,98	1,34	4,59	1,87	0,93
5	mały	mały	krótki	niska	średnia	wysoki	1,47	1,69	3,52	0,98	2,00	2,05	2,68	0,95
6	mały	mały	krótki	niska	duża	średni	0,39	0,44	2,56	1,39	1,12	2,30	2,01	1,94
7	mały	mały	krótki	niska	duża	wysoki	1,78	2,05	1,36	0,82	0,81	1,40	1,10	0,58
8	mały	mały	krótki	średnia	mała	niski	0,54	0,62	3,27	4,26	1,92	2,09	1,92	0,93
9	mały	mały	krótki	średnia	mała	średni	0,92	1,06	0,90	2,24	0,52	2,24	2,90	2,67
10	mały	mały	krótki	średnia	mała	wysoki	0,93	1,07	1,15	1,33	0,74	1,16	1,39	1,93
11	mały	mały	krótki	średnia	średnia	niski	2,04	2,34	2,80	1,05	0,88	1,56	1,92	2,45
12	mały	mały	krótki	średnia	duża	średni	0,49	0,56	3,09	0,84	1,17	1,54	2,42	0,56
13	mały	mały	krótki	średnia	duża	wysoki	1,51	1,73	2,02	1,08	0,32	3,90	1,77	1,16
14	mały	mały	krótki	wysoka	mała	średni	0,63	0,73	2,03	0,63	1,86	2,33	2,31	2,24
15	mały	mały	krótki	wysoka	mała	wysoki	0,28	0,33	2,29	1,65	1,40	0,88	3,84	2,41
16	mały	mały	krótki	wysoka	średnia	wysoki	0,32	0,37	3,95	0,59	1,10	2,93	0,81	2,96
17	mały	mały	średni	niska	mała	niski	0,39	0,45	3,73	0,75	1,21	1,57	2,34	1,51
18	mały	mały	średni	niska	średnia	średni	0,52	0,59	2,35	0,76	1,66	0,86	1,08	0,69
19	mały	mały	średni	średnia	średnia	wysoki	0,20	0,22	2,01	2,09	1,09	3,22	0,47	2,06
20	mały	mały	średni	średnia	duża	wysoki	0,52	0,59	2,76	1,13	1,08	3,57	2,71	1,53
21	mały	mały	średni	wysoka	mała	średni	1,20	1,38	1,95	0,54	1,13	1,63	2,22	3,80
22	mały	mały	średni	wysoka	średnia	średni	0,57	0,66	2,39	1,77	1,26	4,18	3,31	2,73
23	mały	mały	średni	wysoka	duża	wysoki	0,84	0,96	2,09	1,03	0,64	0,53	2,83	1,41
24	mały	mały	długi	niska	mała	wysoki	0,97	1,12	4,83	0,97	0,30	2,20	0,98	0,47
25	mały	mały	długi	średnia	mała	średni	0,80	0,92	1,56	0,87	0,85	2,20	1,32	0,75
26	mały	mały	długi	wysoka	mała	średni	0,38	0,43	3,74	0,77	0,25	2,28	3,60	1,09
27	mały	mały	długi	wysoka	średnia	średni	0,84	0,97	2,50	0,88	0,92	3,44	1,54	2,73
28	mały	mały	długi	wysoka	duża	wysoki	0,34	0,39	4,09	1,57	1,71	0,90	1,83	1,29
29	mały	średni	krótki	niska	mała	wysoki	1,60	1,84	1,24	0,89	0,63	1,80	0,43	2,47
30	mały	średni	krótki	niska	średnia	wysoki	1,42	1,63	1,01	0,90	0,83	2,22	2,90	2,36
31	mały	średni	krótki	niska	duża	średni	1,08	1,25	3,09	2,61	2,29	3,57	3,81	3,05
32	mały	średni	krótki	średnia	średnia	średni	0,20	0,23	2,68	2,18	1,37	1,71	0,51	0,79
33	mały	średni	krótki	średnia	średnia	wysoki	0,61	0,7	2,59	0,41	2,28	2,12	0,81	0,65
34	mały	średni	krótki	średnia	duża	średni	0,35	0,41	3,33	0,46	1,84	2,14	1,27	2,03
35	mały	średni	krótki	średnia	duża	wysoki	0,17	0,19	4,04	0,58	0,36	2,54	1,48	0,47
36	mały	średni	średni	niska	mała	niski	1,41	1,62	2,12	2,85	1,74	3,97	1,61	0,78
37	mały	średni	średni	niska	mała	średni	1,19	1,37	4,28	1,38	0,09	1,26	2,04	2,04
38	mały	średni	średni	niska	mała	wysoki	0,11	0,13	3,08	1,01	0,95	1,42	0,78	0,86
39	mały	średni	średni	niska	średnia	średni	0,17	0,19	3,08	0,37	1,03	2,45	2,35	1,13
40	mały	średni	średni	niska	duża	wysoki	0,55	0,63	1,06	1,11	0,68	1,19	2,95	2,06
41	mały	średni	średni	średnia	mała	niski	0,92	1,06	3,32	2,20	0,87	1,58	0,75	2,38
42	mały	średni	średni	średnia	mała	wysoki	0,31	0,36	2,06	0,73	0,85	0,78	1,07	1,83
43	mały	średni	średni	średnia	średnia	niski	1,37	1,57	2,41	1,85	0,52	4,27	1,89	2,56
44	mały	średni	średni	średnia	średnia	średni	1,94	2,23	1,25	0,68	0,64	0,57	2,18	1,10
45	mały	średni	średni	średnia	duża	niski	0,90	1,04	2,10	2,86	1,51	1,86	0,31	1,77
46	mały	średni	średni	średnia	duża	wysoki	0,51	0,58	3,27	0,35	1,11	2,51	1,29	1,76
47	mały	średni	średni	wysoka	mała	niski	2,61	3,01	4,06	2,96	1,07	1,53	1,04	0,73
48	mały	średni	średni	wysoka	średnia	wysoki	0,20	0,23	1,42	1,89	0,32	2,42	2,07	1,31
49	mały	średni	średni	wysoka	duża	wysoki	0,42	0,48	1,54	1,24	0,92	1,71	1,23	5,52
50	mały	średni	długi	niska	mała	niski	0,71	0,81	0,54	0,45	0,69	1,88	2,15	1,61

**Tabela. B.2.** Wartości wag zbioru reguł rozmytych dla kolejnych rozważanych wariantów

Numer reguły	WEJŚCIA SYSTEMU				WYJŚCIA SYSTEMU		WAGI REGUŁ DLA WARIANTÓW							
	Prognozowany popyt	Aktualny poziom zapasów	Czas dostawy	Jakość dostawy	Aktualna wielkość zamówienia	Poziom zamawiania	W1	W2	W3	W4	W5	W6	W7	W8
51	mały	średni	długi	niska	mała	wysoki	0,03	0,04	1,89	1,13	1,19	3,23	1,91	1,03
52	mały	średni	długi	niska	duża	średni	1,77	2,04	2,72	1,92	0,44	2,50	0,53	1,23
53	mały	średni	długi	niska	duża	wysoki	0,95	1,09	1,08	2,72	2,71	1,08	1,90	0,51
54	mały	średni	długi	średnia	duża	średni	0,36	0,41	1,71	2,36	1,19	0,68	1,52	1,10
55	mały	średni	długi	średnia	duża	wysoki	0,95	1,09	1,07	2,07	1,65	2,11	3,14	1,55
56	mały	średni	długi	wysoka	mała	wysoki	0,47	0,54	1,03	1,21	1,03	1,03	1,12	1,14
57	mały	średni	długi	wysoka	duża	średni	1,15	1,32	3,55	0,20	0,55	2,26	1,73	1,40
58	mały	średni	długi	wysoka	duża	wysoki	0,23	0,27	2,68	0,90	1,09	6,53	2,83	3,25
59	mały	wysoki	krótki	niska	mała	niski	1,67	1,92	1,60	2,27	2,00	2,33	2,20	2,79
60	mały	wysoki	krótki	niska	mała	średni	1,57	1,81	1,19	1,44	2,10	2,50	0,72	2,06
61	mały	wysoki	krótki	niska	mała	wysoki	1,08	1,24	2,05	0,83	1,40	2,34	2,26	1,63
62	mały	wysoki	krótki	średnia	średnia	wysoki	0,68	0,78	0,77	1,20	1,07	0,49	0,77	1,58
63	mały	wysoki	krótki	średnia	duża	wysoki	0,91	1,04	0,68	1,50	1,61	1,87	1,47	1,23
64	mały	wysoki	krótki	wysoka	średnia	wysoki	0,43	0,49	1,93	0,40	1,11	1,16	1,18	0,87
65	mały	wysoki	krótki	wysoka	duża	średni	0,59	0,67	2,00	1,48	1,64	2,77	2,39	1,98
66	mały	wysoki	średni	niska	mała	niski	0,70	0,8	0,87	1,84	0,80	2,21	1,72	1,79
67	mały	wysoki	średni	niska	średnia	niski	2,42	2,78	1,92	2,80	0,57	2,77	0,77	2,36
68	mały	wysoki	średni	niska	duża	niski	0,07	0,08	1,56	1,40	0,98	2,74	1,01	2,58
69	mały	wysoki	średni	wysoka	średnia	niski	0,29	0,33	2,26	2,04	2,16	2,11	1,81	2,20
70	mały	wysoki	średni	wysoka	duża	wysoki	0,44	0,5	0,31	0,79	1,61	3,67	2,40	1,43
71	mały	wysoki	długi	niska	mała	niski	0,24	0,27	2,42	1,24	0,97	1,14	1,07	2,14
72	mały	wysoki	długi	niska	średnia	niski	1,11	1,28	1,68	0,31	1,50	1,64	3,24	0,68
73	mały	wysoki	długi	niska	średnia	wysoki	0,09	0,1	1,99	0,79	0,49	1,89	1,36	1,60
74	mały	wysoki	długi	niska	duża	niski	0,75	0,86	3,02	0,41	1,05	1,68	1,58	2,53
75	mały	wysoki	długi	niska	duża	wysoki	0,97	1,11	3,10	0,41	1,11	2,68	0,59	1,21
76	mały	wysoki	długi	średnia	średnia	wysoki	2,00	2,3	1,84	0,76	1,29	3,63	2,95	1,03
77	mały	wysoki	długi	średnia	duża	średni	1,26	1,45	3,37	0,69	0,69	1,21	0,56	0,90
78	mały	wysoki	długi	wysoka	mała	wysoki	0,15	0,17	1,66	1,27	0,44	2,75	0,91	2,01
79	mały	wysoki	długi	wysoka	średnia	niski	0,68	0,79	2,32	0,09	0,16	0,90	0,82	2,03
80	mały	wysoki	długi	wysoka	duża	wysoki	0,81	0,93	2,19	1,95	1,41	0,11	0,27	2,71
81	średni	mały	krótki	niska	mała	niski	0,98	1,13	3,11	1,71	0,67	1,62	2,75	1,12
82	średni	mały	krótki	niska	mała	średni	0,35	0,4	2,21	1,27	1,56	3,71	2,18	0,69
83	średni	mały	krótki	średnia	średnia	średni	0,77	0,88	0,42	1,35	0,48	2,77	0,84	0,86
84	średni	mały	krótki	średnia	duża	wysoki	0,42	0,49	1,45	1,39	1,61	1,55	2,20	1,77
85	średni	mały	krótki	wysoka	mała	niski	1,34	1,54	2,97	1,06	0,42	0,88	1,10	0,75
86	średni	mały	krótki	wysoka	mała	wysoki	0,25	0,29	1,27	1,01	0,81	3,12	3,50	0,92
87	średni	mały	krótki	wysoka	średnia	niski	0,25	0,29	1,68	0,67	2,20	4,19	4,01	1,06
88	średni	mały	krótki	wysoka	średnia	wysoki	0,18	0,21	1,66	0,83	1,41	3,29	2,10	1,16
89	średni	mały	krótki	wysoka	duża	niski	1,42	1,64	1,88	1,85	1,24	2,89	1,28	2,21
90	średni	mały	krótki	wysoka	duża	wysoki	0,67	0,77	1,70	0,89	1,78	1,55	1,80	1,94
91	średni	mały	średni	średnia	mała	średni	0,17	0,2	1,29	0,13	1,09	1,86	1,26	0,38
92	średni	mały	średni	średnia	mała	wysoki	1,05	1,2	1,78	2,33	1,91	0,53	0,74	2,00
93	średni	mały	średni	średnia	średnia	średni	0,35	0,4	2,70	1,96	0,55	2,33	0,69	0,73
94	średni	mały	średni	średnia	średnia	wysoki	2,07	2,38	1,09	1,67	0,86	0,79	3,25	0,67
95	średni	mały	średni	średnia	duża	średni	0,68	0,78	2,72	1,78	2,47	1,39	1,04	3,26
96	średni	mały	średni	wysoka	mała	niski	1,35	1,55	4,26	0,62	2,12	2,38	0,58	1,42
97	średni	mały	średni	wysoka	mała	średni	1,04	1,2	1,82	1,38	0,60	2,15	0,98	1,30
98	średni	mały	długi	niska	mała	średni	0,23	0,27	2,70	0,97	0,98	2,04	0,40	1,03
99	średni	mały	długi	niska	duża	średni	0,57	0,66	2,30	1,93	1,94	2,53	2,43	3,26
100	średni	mały	długi	średnia	mała	niski	0,91	1,05	2,74	0,95	2,03	3,53	1,11	1,90

**Tabela. B.3.** Wartości wag zbioru reguł rozmytych dla kolejnych rozważanych wariantów

Numer reguły	WEJŚCIA SYSTEMU				WYJŚCIA SYSTEMU		WAGI REGUŁ DLA WARIANTÓW							
	Prognozowany popyt	Aktualny poziom zapasów	Czas dostawy	Jakość dostawy	Aktualna wielkość zamówienia	Poziom zamawiania	W1	W2	W3	W4	W5	W6	W7	W8
101	średni	mały	długi	średnia	mała	średni	0,09	0,11	2,11	0,92	0,93	0,52	0,68	1,74
102	średni	mały	długi	średnia	mała	wysoki	0,40	0,46	1,34	2,22	0,64	1,84	3,15	1,54
103	średni	mały	długi	średnia	średnia	niski	0,31	0,35	1,09	2,10	0,40	1,06	0,42	1,59
104	średni	mały	długi	średnia	średnia	wysoki	0,04	0,05	2,72	2,57	1,02	0,38	1,04	2,08
105	średni	mały	długi	wysoka	mała	średni	1,64	1,88	5,89	2,18	1,07	3,58	2,70	2,43
106	średni	mały	długi	wysoka	mała	wysoki	0,28	0,32	0,97	1,00	4,17	1,96	3,01	2,87
107	średni	mały	długi	wysoka	średnia	niski	2,20	2,53	2,50	0,32	0,19	0,71	1,82	1,79
108	średni	mały	długi	wysoka	średnia	wysoki	1,95	2,24	1,74	1,62	1,67	2,50	1,51	1,31
109	średni	średni	krótki	niska	mała	wysoki	0,72	0,83	1,61	0,59	1,65	1,27	2,49	0,92
110	średni	średni	krótki	niska	średnia	wysoki	1,71	1,97	2,17	1,31	0,28	1,89	1,36	1,04
111	średni	średni	krótki	niska	duża	średni	0,73	0,84	3,04	1,19	2,28	1,74	3,67	1,20
112	średni	średni	krótki	niska	duża	wysoki	0,31	0,36	1,79	0,98	0,64	2,08	3,34	0,28
113	średni	średni	krótki	średnia	mała	wysoki	1,72	1,98	2,03	0,74	1,54	1,83	0,91	1,11
114	średni	średni	krótki	średnia	średnia	wysoki	0,57	0,66	2,95	0,80	1,29	2,36	0,31	1,41
115	średni	średni	krótki	średnia	duża	średni	1,01	1,16	3,34	1,04	1,68	2,23	2,33	2,04
116	średni	średni	krótki	średnia	duża	wysoki	0,29	0,33	1,27	0,42	1,91	0,49	4,66	2,94
117	średni	średni	krótki	wysoka	mała	niski	0,74	0,85	4,25	2,33	2,44	0,66	1,84	1,80
118	średni	średni	krótki	wysoka	średnia	niski	1,74	2	2,66	2,18	0,51	1,54	2,34	2,59
119	średni	średni	krótki	wysoka	duża	wysoki	0,68	0,78	1,61	1,42	0,62	2,31	1,02	1,98
120	średni	średni	średni	niska	mała	niski	2,15	2,47	2,61	0,34	1,10	0,96	2,76	1,29
121	średni	średni	średni	niska	mała	wysoki	0,62	0,72	3,43	1,11	1,33	2,11	4,51	0,73
122	średni	średni	średni	niska	średnia	niski	1,35	1,55	1,79	2,20	1,14	2,38	1,67	0,94
123	średni	średni	średni	niska	duża	średni	1,31	1,51	0,97	1,41	1,90	3,16	1,50	0,80
124	średni	średni	średni	niska	duża	wysoki	0,31	0,36	1,21	0,47	1,11	1,78	1,38	3,76
125	średni	średni	średni	średnia	średnia	niski	1,09	1,26	2,48	0,58	0,29	1,95	1,50	0,34
126	średni	średni	średni	wysoka	mała	wysoki	0,30	0,35	1,95	0,50	0,95	2,70	2,05	1,62
127	średni	średni	średni	wysoka	średnia	niski	1,95	2,24	1,54	1,27	0,88	0,98	0,95	0,81
128	średni	średni	średni	wysoka	średnia	średni	2,11	2,42	1,85	1,41	1,33	1,34	2,64	2,74
129	średni	średni	średni	wysoka	średnia	wysoki	0,66	0,76	2,46	1,26	1,43	1,10	0,68	1,61
130	średni	średni	długi	niska	mała	niski	0,33	0,38	2,26	1,85	0,46	1,28	1,51	1,31
131	średni	średni	długi	niska	średnia	niski	0,75	0,87	1,64	1,48	1,95	2,06	2,39	1,23
132	średni	średni	długi	niska	duża	wysoki	0,66	0,76	1,71	1,67	3,12	3,53	0,88	1,18
133	średni	średni	długi	średnia	mała	niski	0,56	0,64	0,98	1,51	1,72	0,80	1,11	0,62
134	średni	średni	długi	średnia	duża	średni	1,61	1,85	1,89	1,60	1,61	1,26	0,45	0,80
135	średni	średni	długi	średnia	duża	wysoki	1,00	1,15	1,24	0,89	1,32	3,82	1,38	1,75
136	średni	średni	długi	wysoka	średnia	niski	0,49	0,56	1,12	0,67	1,77	0,84	0,58	1,19
137	średni	średni	długi	wysoka	duża	średni	0,93	1,07	4,12	2,32	0,74	1,61	1,95	3,06
138	średni	wysoki	krótki	niska	duża	niski	1,94	2,23	2,69	0,37	0,17	2,10	2,37	1,80
139	średni	wysoki	krótki	niska	duża	wysoki	0,44	0,51	1,18	1,84	2,22	2,55	1,57	4,63
140	średni	wysoki	krótki	średnia	mała	wysoki	0,74	0,85	3,46	0,03	2,60	3,17	2,51	1,33
141	średni	wysoki	krótki	średnia	średnia	wysoki	0,54	0,62	1,66	0,89	0,85	0,58	2,34	1,21
142	średni	wysoki	krótki	średnia	duża	wysoki	0,31	0,36	4,18	1,33	1,01	1,65	2,92	0,70
143	średni	wysoki	krótki	wysoka	mała	średni	1,37	1,57	2,26	1,25	1,52	3,30	1,41	1,44
144	średni	wysoki	krótki	wysoka	średnia	wysoki	0,28	0,32	2,76	0,41	1,18	4,17	1,48	0,86
145	średni	wysoki	średni	niska	mała	średni	2,68	3,08	0,88	1,11	0,78	2,07	2,07	1,53
146	średni	wysoki	średni	niska	średnia	średni	0,58	0,67	1,15	1,69	3,47	2,37	1,02	3,36
147	średni	wysoki	średni	niska	duża	niski	0,54	0,62	1,48	0,93	0,36	1,24	1,10	0,72
148	średni	wysoki	średni	średnia	mała	średni	1,81	2,08	2,48	1,18	0,60	1,74	1,70	1,72
149	średni	wysoki	średni	średnia	mała	wysoki	0,63	0,73	1,14	0,35	1,33	3,68	4,18	2,38
150	średni	wysoki	średni	wysoka	mała	wysoki	0,09	0,1	1,07	1,22	1,91	1,50	2,21	0,65

**Tabela. B.4.** Wartości wag zbioru reguł rozmytych dla kolejnych rozważanych wariantów

Numer reguły	WEJŚCIA SYSTEMU				WYJŚCIA SYSTEMU		WAGI REGUŁ DLA WARIANTÓW							
	Prognozowany popyt	Aktualny poziom zapasów	Czas dostawy	Jakość dostawy	Aktualna wielkość zamówienia	Poziom zamawiania	W1	W2	W3	W4	W5	W6	W7	W8
151	średni	wysoki	średni	wysoka	średnia	niski	1,92	2,21	2,09	1,83	0,51	2,28	2,60	1,72
152	średni	wysoki	średni	wysoka	średnia	średni	1,61	1,85	4,30	1,63	2,56	2,12	1,91	2,94
153	średni	wysoki	średni	wysoka	duża	wysoki	1,29	1,49	0,97	1,65	0,48	1,28	1,64	2,10
154	średni	wysoki	długi	niska	mała	niski	2,54	2,92	2,76	1,58	1,01	2,02	1,79	3,31
155	średni	wysoki	długi	niska	mała	średni	3,39	3,9	3,38	1,26	2,48	1,68	1,65	2,01
156	średni	wysoki	długi	niska	mała	wysoki	0,40	0,46	2,37	0,70	1,99	2,27	2,34	2,05
157	średni	wysoki	długi	niska	średnia	średni	0,98	1,13	1,28	0,91	0,95	1,76	2,05	0,87
158	średni	wysoki	długi	średnia	mała	wysoki	1,22	1,4	3,89	0,41	0,97	0,56	1,63	1,60
159	średni	wysoki	długi	średnia	średnia	niski	1,96	2,26	2,40	1,76	1,95	1,63	0,61	2,66
160	średni	wysoki	długi	średnia	średnia	wysoki	1,32	1,52	1,27	0,61	0,97	2,41	2,46	1,42
161	średni	wysoki	długi	średnia	duża	niski	1,34	1,54	1,90	1,75	1,59	2,82	2,65	3,92
162	średni	wysoki	długi	średnia	duża	średni	0,77	0,89	2,09	1,41	0,70	1,61	0,58	1,28
163	średni	wysoki	długi	wysoka	mała	wysoki	0,44	0,5	1,85	1,31	1,13	1,57	2,35	1,95
164	średni	wysoki	długi	wysoka	duża	niski	0,69	0,79	0,80	0,66	1,32	1,88	1,37	3,28
165	duży	mały	krótki	niska	średnia	wysoki	1,26	1,45	2,83	0,85	0,51	2,25	0,98	0,52
166	duży	mały	krótki	niska	duża	wysoki	0,41	0,47	1,27	1,16	0,36	2,71	0,59	0,41
167	duży	mały	krótki	średnia	mała	niski	1,07	1,23	2,39	1,35	2,11	2,84	1,32	1,93
168	duży	mały	krótki	średnia	mała	wysoki	3,38	3,89	3,11	0,21	0,67	2,16	1,32	3,16
169	duży	mały	krótki	średnia	średnia	wysoki	0,77	0,89	0,24	0,44	1,50	2,58	3,13	1,46
170	duży	mały	krótki	wysoka	mała	niski	0,96	1,1	1,88	1,46	0,90	3,64	1,40	0,60
171	duży	mały	krótki	wysoka	mała	wysoki	1,22	1,4	1,98	1,05	0,62	3,50	1,38	2,31
172	duży	mały	krótki	wysoka	średnia	niski	1,40	1,62	0,34	0,77	0,48	2,83	2,40	0,74
173	duży	mały	krótki	wysoka	średnia	wysoki	0,21	0,24	1,03	0,69	1,48	3,46	3,09	1,90
174	duży	mały	krótki	wysoka	duża	niski	0,95	1,1	0,10	1,85	1,25	2,61	1,46	2,76
175	duży	mały	średni	niska	mała	średni	0,93	1,07	3,53	0,39	0,12	2,19	0,60	1,75
176	duży	mały	średni	niska	średnia	wysoki	0,55	0,63	1,77	2,00	0,35	2,64	2,56	1,32
177	duży	mały	średni	niska	duża	niski	1,30	1,49	2,73	1,02	2,29	2,10	2,46	3,94
178	duży	mały	średni	średnia	średnia	niski	0,84	0,96	3,74	0,23	1,07	1,77	0,64	1,85
179	duży	mały	średni	wysoka	mała	średni	0,48	0,55	0,81	1,48	0,51	1,94	2,18	1,65
180	duży	mały	średni	wysoka	średnia	niski	1,84	2,12	0,89	0,97	1,34	1,67	0,88	1,30
181	duży	mały	średni	wysoka	średnia	wysoki	1,39	1,6	1,47	2,05	2,70	5,19	1,82	4,60
182	duży	mały	średni	wysoka	duża	niski	1,59	1,83	1,61	0,91	3,16	4,32	2,37	2,78
183	duży	mały	długi	niska	mała	średni	1,15	1,32	1,20	1,62	1,63	0,91	0,50	0,76
184	duży	mały	długi	niska	średnia	niski	1,52	1,75	1,36	0,50	1,77	1,44	0,36	3,80
185	duży	mały	długi	niska	duża	średni	2,09	2,4	3,31	1,22	0,54	3,11	1,58	0,57
186	duży	mały	długi	średnia	mała	średni	0,41	0,47	1,89	0,77	0,73	1,52	1,81	2,11
187	duży	mały	długi	średnia	średnia	niski	0,20	0,24	1,97	2,64	0,49	1,28	1,48	1,78
188	duży	mały	długi	średnia	duża	niski	0,14	0,17	2,29	1,62	1,87	2,10	1,51	1,40
189	duży	mały	długi	wysoka	mała	niski	0,61	0,71	2,12	1,47	1,16	2,54	1,38	1,66
190	duży	mały	długi	wysoka	średnia	średni	1,36	1,56	4,22	2,09	0,72	2,68	1,55	2,06
191	duży	średni	krótki	niska	mała	niski	0,01	0,02	2,82	1,14	2,72	1,51	3,27	4,73
192	duży	średni	krótki	niska	średnia	niski	0,82	0,94	2,22	0,81	0,41	2,79	2,12	2,39
193	duży	średni	krótki	niska	duża	niski	1,09	1,25	4,84	2,32	0,72	2,48	2,45	1,43
194	duży	średni	krótki	średnia	mała	średni	2,20	2,53	0,68	0,38	1,43	1,20	1,12	3,14
195	duży	średni	krótki	średnia	duża	niski	0,52	0,6	2,06	3,01	3,38	1,05	2,16	2,46
196	duży	średni	krótki	średnia	duża	wysoki	1,18	1,35	1,75	1,30	1,31	4,44	3,12	2,03
197	duży	średni	krótki	wysoka	mała	niski	0,43	0,49	0,71	1,60	0,15	2,13	3,96	3,80
198	duży	średni	krótki	wysoka	średnia	niski	1,34	1,54	2,50	2,80	0,21	1,64	1,12	0,86
199	duży	średni	krótki	wysoka	średnia	wysoki	0,37	0,42	4,34	1,65	0,49	2,51	1,96	0,40
200	duży	średni	średni	niska	średnia	niski	0,12	0,14	2,54	0,97	0,66	1,46	1,28	3,73

**Tabela. B.5.** Wartości wag zbioru reguł rozmytych dla kolejnych rozważanych wariantów

Numer reguły	WEJŚCIA SYSTEMU				WYJŚCIA SYSTEMU		WAGI REGUŁ DLA WARIANTÓW							
	Prognozowany popyt	Aktualny poziom zapasów	Czas dostawy	Jakość dostawy	Aktualna wielkość zamówienia	Poziom zamawiania	W1	W2	W3	W4	W5	W6	W7	W8
201	duży	średni	średni	niska	średnia	średni	1,94	2,23	2,13	0,57	2,93	1,22	1,62	0,57
202	duży	średni	średni	niska	duża	niski	1,06	1,22	1,99	2,23	0,97	0,27	0,50	0,40
203	duży	średni	średni	średnia	mała	niski	1,24	1,42	1,30	1,15	1,23	0,43	0,99	1,47
204	duży	średni	średni	średnia	mała	średni	0,09	0,1	1,25	0,47	0,77	2,19	1,70	1,09
205	duży	średni	średni	średnia	średnia	niski	0,82	0,94	1,91	1,84	0,80	2,00	2,40	1,01
206	duży	średni	średni	średnia	średnia	wysoki	0,25	0,29	1,12	0,46	0,63	1,02	1,38	4,49
207	duży	średni	średni	wysoka	mała	średni	2,83	3,26	2,35	2,43	2,21	2,10	0,81	0,66
208	duży	średni	długi	niska	mała	średni	0,58	0,67	4,56	1,50	0,90	3,40	1,43	0,80
209	duży	średni	długi	niska	średnia	średni	1,07	1,23	2,10	1,91	2,19	2,21	3,07	1,12
210	duży	średni	długi	niska	duża	niski	0,79	0,91	0,86	2,63	0,99	1,84	1,61	1,70
211	duży	średni	długi	niska	duża	wysoki	0,31	0,36	2,45	0,83	0,20	0,95	0,79	0,55
212	duży	średni	długi	średnia	mała	średni	0,31	0,36	3,28	1,51	0,90	0,49	1,17	2,44
213	duży	średni	długi	średnia	duża	wysoki	0,46	0,53	1,91	1,68	0,57	4,37	2,59	1,10
214	duży	wysoki	krótki	niska	średnia	niski	0,50	0,58	0,23	1,21	1,15	1,52	3,09	1,87
215	duży	wysoki	krótki	niska	średnia	wysoki	0,45	0,52	1,10	0,69	1,35	0,42	1,51	2,57
216	duży	wysoki	krótki	niska	duża	niski	1,13	1,3	3,98	0,22	1,44	2,58	0,89	0,73
217	duży	wysoki	krótki	średnia	średnia	niski	0,89	1,02	1,01	0,90	0,31	2,44	1,08	2,44
218	duży	wysoki	krótki	średnia	duża	niski	0,66	0,76	3,93	0,95	1,46	1,21	1,89	0,81
219	duży	wysoki	krótki	średnia	duża	średni	0,71	0,82	1,65	1,58	1,63	4,96	1,43	0,79
220	duży	wysoki	krótki	średnia	duża	wysoki	1,22	1,4	1,89	2,57	2,02	1,70	2,44	0,99
221	duży	wysoki	krótki	wysoka	mała	średni	0,10	0,11	1,57	0,07	0,59	0,73	0,99	2,18
222	duży	wysoki	krótki	wysoka	mała	wysoki	0,49	0,56	2,21	0,32	0,66	2,38	3,13	3,43
223	duży	wysoki	krótki	wysoka	średnia	wysoki	0,97	1,11	4,77	1,53	1,77	2,28	3,09	0,69
224	duży	wysoki	krótki	wysoka	duża	niski	1,16	1,33	3,29	1,04	2,19	2,03	1,89	1,92
225	duży	wysoki	krótki	wysoka	duża	średni	0,83	0,96	2,65	0,97	1,09	1,04	3,48	1,46
226	duży	wysoki	średni	niska	średnia	niski	0,82	0,95	1,65	1,57	0,94	3,23	1,55	2,23
227	duży	wysoki	średni	średnia	mała	wysoki	0,47	0,54	1,18	1,85	0,55	0,91	1,24	2,35
228	duży	wysoki	średni	wysoka	średnia	niski	1,88	2,17	2,11	0,28	0,93	3,14	4,87	1,37
229	duży	wysoki	średni	wysoka	duża	średni	0,57	0,65	1,23	0,29	0,83	3,08	2,01	1,35
230	duży	wysoki	długi	niska	mała	niski	2,20	2,53	1,89	0,54	2,35	2,18	3,14	2,07
231	duży	wysoki	długi	niska	średnia	niski	1,22	1,41	2,70	0,77	1,54	0,90	1,07	3,73
232	duży	wysoki	długi	niska	średnia	wysoki	0,70	0,8	1,54	2,33	1,69	1,82	0,75	1,54
233	duży	wysoki	długi	średnia	mała	niski	0,66	0,76	2,87	0,93	0,39	1,79	1,35	1,79
234	duży	wysoki	długi	średnia	średnia	średni	0,89	1,02	2,32	0,32	1,33	1,58	2,26	3,22
235	duży	wysoki	długi	wysoka	duża	średni	0,68	0,78	2,11	0,57	1,09	0,84	0,13	2,57

