

Marianna Jacyna¹

Warsaw University of Technology Faculty of Transport
75 Koszykowa str. Warsaw, Poland
email: marianna.jacyna@pw.edu.pl

Iouri Semenov²

West Pomeranian University of Technology, Faculty of Maritime Technology and Transport
al. Piastów 41, 71-899 Szczecin, Poland
email: iouri.semenov@zut.edu.pl

Modele procesu zaopatrzenia systemu obsługi pojazdów samochodowych w warunkach niepewności informacyjnej

Keywords: stacje obsługi pojazdów, części zamienne, pewność informacyjna, łańcuch dostaw, model decyzyjny

Abstract: W artykule przedstawiono problematykę podejmowania decyzji w trakcie planowania i realizacji zaopatrzenia systemu obsługi pojazdów w części zamienne w warunkach niepełnej dostępności do informacji. Brak skutecznych modeli planowania zaopatrzenia opartych na zasadach sztucznej inteligencji przyczynia się do pogłębienia luki wiedzy w tej problematyce. Wykonane analizy potwierdzają fakt, iż niepewność informacyjna jest jednym z głównych czynników załamania procesu zaopatrzenia skutkujących stratami finansowymi tak stacji obsługi pojazdów jak i firm zaopatrzeniowych. Autorzy dokonali strukturyzacji krajowego systemu obsługi pojazdów samochodowych wyodrębniając trzy odmiennych segmenty tego systemu. Dokonana strukturyzacja pozwoliła na identyfikację ryzyka podejmowania błędnych decyzji logistycznych w każdym z wyodrębnionych segmentów. Pokazano, iż proces planowania zaopatrzenia w każdym z nich jest realizowany wg różnych zasad. Przedstawiono autorskie modele decyzyjne dla każdego z segmentów. Modele mogą służyć jako narzędzie wspomagające usprawnienie procesu zaopatrzenia stacji obsługi pojazdów samochodowych w warunkach niepewności informacyjnej. W części aplikacyjnej została opracowana propozycja autorskiego algorytmu umożliwiającego rozwiązanie zaproponowanych modeli.

1. Wprowadzenie

W 2010 r. liczba używanych na świecie samochodów przekroczyła miliard sztuk. Ponad 50% wszystkich pojazdów eksploatowano w USA i UE. Co roku do użytku na drogach USA trafia 20 mln nowych samochodów, a w UE ta liczba wynosi 14 mln sztuk, przy czym na każdy tysiąc mieszkańców przypada 531 samochodów [5]. Wiąże się to więc ze znacznym wzrostem popytu, na usługi w segmencie obsługi logistycznej produkcji i dystrybucji nowych pojazdów FL (ang. Forward Logistics) oraz rynku zaopatrzenia w części zamienne i akcesoria RL (ang. Reverse Logistics) [9]. Według podejścia tradycyjnego, łańcuch dostaw dla nowo wyprodukowanych samochodów zaczyna się w miejscu ich produkcji, obejmuje

¹ Marianna Jacyna, [0000-0002-7582-4536], Warsaw University of Technology Faculty of Transport, 75 Koszykowa str. Warsaw, Poland, email: marianna.jacyna@pw.edu.pl

² Iouri Semenov, [0000-0002-2250-9591], West Pomeranian University of Technology, Faculty of Maritime Technology and Transport, al. Piastów 41, 71-899 Szczecin, Poland, email: Iouri.Semenov@zut.edu.pl

dystrybutorów, hurtowników oraz detalistów i kończy się u ich odbiorcy. Usprawnianie procesów wynika przede wszystkim z doskonalenia koordynacji działań poszczególnych uczestników łańcucha dostaw i tym samym minimalizacji ryzyka niewykonania zadania zaopatrzeniowego [31].

W okresie eksploatacji pojazdu, na ogół, wyróżnia się dwa stany: użytkowania i obsługiwanie. Stan użytkowania dotyczy wykorzystania pojazdu zgodnie z jego przeznaczeniem tzn. przemieszczaniem osób i ładunków w czasie i przestrzeni [3, 29]. Natomiast obsługiwanie, to czynności organizacyjno-techniczne mające na celu przywracanie i podtrzymanie stanu zdatności użytkowej pojazdu [50].

Aktualnie, obok czynników technologicznych i ekonomicznych bardzo ważnego znaczenia w przywracaniu części pojazdu do zdatności (regeneracja) nabiera czynnik środowiskowy [40, 43]. Wykorzystanie części pochodzących z regeneracji ogranicza negatywny wpływ procesów produkcyjnych na środowisko [13].

Jakość prac wykonanych w ramach łańcuchów dostaw części zamiennych ma istotne znaczenie dla skuteczności wszystkich segmentów branży motoryzacyjnej. W sytuacji pandemii COVID-19 nastąpiło czasowe załamanie procesów produkcji nowych samochodów, stąd oczekiwania, że po roku 2026 wartość segmentu motoryzacyjnego osiągnie tylko ok. 810 mld \$ [1]. Oznacza to, że utrzymanie całej branży motoryzacyjnej w dużej mierze uzależnione będzie od usług serwisowych. Ponadto, w miarę wzrostu liczby sprzedanych samochodów zwiększa się liczba pojazdów przedterminowo wycofywanych z eksploatacji, a w konsekwencji powstaje potężny segment ELVs (ang. *End-of-Life Vehicles*) [47].

Analiza stosowanych praktyk pokazuje, że przyczyny czasowego lub całkowitego wycofania pojazdów z eksploatacji to przede wszystkim:

- konieczność zapewnienia pojazdom poziomu bezpieczeństwa wymaganego przepisami (modernizacja układów lub podzespołów, np. układu recyrkulacji spalin EGR),
- konieczności naprawy po zdarzeniu wywołującym szkodę (kolizje, wypadki),
- zwroty nowo wyprodukowanych pojazdów (opcje zawarte w umowach w przypadku wykrycia wad konstrukcyjnych lub fabrycznych),
- potrzeba renowacji samochodów z przesłanek prestiżowych, społecznych lub służbowych,
- przyspieszone starzenie się materiałów wykorzystywanych w elementach konstrukcyjnych (nadwozia i podwozia).

Te wszystkie wymagania sprawiają, że postępuje wzrost popytu na usługi stacji obsługi pojazdów samochodowych oraz potrzebę stałego doskonalenia oferty serwisowej. Tym bardziej, że przedsiębiorstwa transportowe niezależnie od profilu działalności i wielkości taboru samochodowego skupiają się na wykonaniu zadań przewozowych, co wymaga wysokiego poziomu gotowości ich floty. Natomiast samochody, bez względu na markę czy przeznaczenie, w miarę upływu czasu eksploatacji i zużywania się potrzebują coraz bardziej pracochłonnych usług diagnostycznych i naprawczych. Skutkuje to czasowym wycofywaniem pojazdów z eksploatacji coraz częściej z przyczyn losowych. Stąd rośnie popyt na naprawy w segmencie tzw. DIFM (ang. *Do-It-for Me*).

W ramach napraw wykonywane są różne czynności, w tym m.in. [6]:

- naprawy powypadkowe i poawaryjne;
- modernizacja układów i podzespołów w celu spełnienia nowych wymogów legislacyjnych;
- regeneracja zużytych części i usunięcie wad fabrycznych lokalizowanych na podstawie pomiarów i badań diagnostycznych;
- kasacja i recykling samochodów zużytych.

Taki wachlarz zadań stawia różnorodne wymagania dotyczące organizacji zaopatrzenia stacji obsługi pojazdów samochodowych w części zamienne. Poza tym, brak ujednoliconych technologii napraw serwisowych skutkuje zarówno mnogością podejść w projektowaniu

łańcuchów zaopatrzenia tych stacji w części zamiennie oraz dużą elastycznością wymagań co do realizacji ich dostaw. Klienci poszukują stacji obsługi pojazdów samochodowych gwarantujących usługi o wysokiej jakości i terminowości oraz nie są skłonni do akceptacji wydłużenia czasu naprawy. Co więcej, ze względu na losowy charakter zgłoszeń usług serwisowych, łańcuchy dostaw części zamiennych charakteryzują się wysokim poziomem niepewności w zamówieniach, ponadto specyfikacja zamówienia tworzona jest w krótkim horyzoncie planowania i niepewnych okolicznościach (patrz prace: [18, 27]).

W celu uniknięcia nieplanowanych przerw w procesie naprawy pojazdów samochodowych, spowodowanych brakiem odpowiednich części zamiennych, w niniejszym artykule przedstawiono autorskie modele decyzyjne odzwierciedlające proces zaopatrzenia stacji obsługi pojazdów samochodowych w takie części. Punktem wyjściowym była analiza segmentów rynku motoryzacyjnego w aspekcie świadczonych usług serwisowych celem identyfikacji podstawowych problemów sieci zaopatrzenia w części zamiennie oraz analiza szerokiego spektrum literatury w tym obszarze. Opracowując modele, założono, że poprawnie funkcjonująca sieć zaopatrzeniowa stacji obsługi pojazdów samochodowych realizująca zamówienia na części zamiennie uzależniona jest w dużej mierze od pewności informacji co do wykonywanych napraw czy określonych przeglądów. Ponieważ proces zamówień na brakujące części zamiennie jest procesem losowym wynikającym z różnego typu uszkodzeń pojazdów, dlatego niepewność informacji co do sprecyzowania zamówienia na ewentualne części zamiennie jest czynnikiem negatywnie wpływającym na efektywne funkcjonowanie stacji obsługi. Dłuższy okres oczekiwania na części spowalnia pracę danej stacji, ale również wpływa negatywnie na jakość wykonywanych usług, co w dobie dużej konkurencji na rynku usług serwisowych jest sytuacją niedopuszczalną.

Dla opracowanych modeli zaproponowano nowatorski algorytm optymalizacyjny, minimalizujący ryzyko zamówienia niepotrzebnych lub niepasujących części uwzględniający niepewne informacje wynikające z przepływu ich pomiędzy poszczególnymi uczestnikami procesu zaopatrzenia. Zaproponowany algorytm jest modyfikacją klasycznego algorytmu genetycznego szeroko opisywanego w literaturze. Algorytm ten kształtuje w taki sposób łańcuch dostaw, aby przepływy informacji co do wielkości zamówień czy rodzaju towaru obarczone były dopuszczalnym ryzykiem gwarantującym ciągłość procesów naprawy pojazdów.

2. Charakterystyka segmentów rynku motoryzacyjnego w aspekcie świadczonych usług serwisowych

Dane Europejskiego Stowarzyszenia Producentów Samochodów (ACEA) [4] wskazują, że czynnikiem wpływającym na rozwój usług naprawczych i serwisowych jest średni wiek samochodów, który w 2018 r. wynosił około 14 lat. Połowę rejestracji w 2018 roku stanowiły samochody w wieku 11-20 lat, kolejne 15% zaś powyżej 20 lat. Samochody osobowe w UE mają średni wiek poprodukcyjny 11,1 lat, samochody dostawcze 11 lat zaś samochody ciężarowe 12 lat [4]. To skutkuje stosunkowo dużą awaryjnością pojazdów na skutek rozmaitych usterek czy uszkodzeń. Ponadto, w okresie swojej eksploatacji ponad 60% aut ulega wypadkom, po których część z nich przeznaczana jest do kasacji. Przeciętny samochód w ciągu cyklu życia przejeżdża 320 tys. km i zużywa 3 komplety opon. W trakcie cyklu życia auta jego właściciel przeznacza na naprawy średnio 16.000 zł (3.500 euro) [22].

Analiza rynku motoryzacyjnego wskazuje na zmiany w strukturze pojazdów poruszających się po drogach. Na przykład w roku 2018 w Polsce zakupiono 532 tys. pojazdów fabrycznie nowych, a w trzech pierwszych kwartałach 2019 r. zarejestrowano 410,8 tys. nowych samochodów osobowych (+1,9% r/r) [45]. Bardzo dynamicznie rośnie liczba rejestracji samochodów z napędami alternatywnymi [44, 49], których od początku roku zarejestrowano

28,6 tys. (+60,3% r/r). Nie mniej jednak udział kupna używanych samochodów w wieku do 4 lat w 2018 roku wzrósł o 10,7 %, a więc o blisko 1 punkt proc. Udział najstarszych, ponad 10-letnich pojazdów, wzrósł o 0,7 punktu proc. i stanowi 54% wszystkich samochodów.

Postęp technologiczny sprawia, że produkowane samochody są coraz bardziej zaawansowane technicznie. Powoduje to kurczenie się segmentu napraw opartych na zasadzie „zrób to sam” - DIY (ang. *Do It Yourself*) [7, 8]. Co istotne, wartość polskiego rynku dystrybucji części zamiennych oraz prac diagnostycznych i naprawczych rośnie od wielu lat i na przełomie lat 2019/2020 przekroczyła poziom 30 mld zł. Natomiast dziennie w Polsce, do warsztatów i sklepów motoryzacyjnych, trafia 640 tys. sztuk części zamiennych [22].

Biorąc pod uwagę powyższe można wskazać, że podstawowe problemy związane z zaopatrzeniem w części zamienne wynikają:

- ze znacznej różnorodności technologii obsługi pojazdów (determinowana różnorodnością charakterystyk obsługiwanych samochodów, rozmaitością wad, usterek i uszkodzeń itp.);
- z wysokiego zróżnicowania wymagań ze strony klientów;
- z niepewności informacyjnej dotyczącej rzeczywistego stanu technicznego samochodu;
- z ostrego ograniczenia akceptowalnego kosztu wykonywanych prac diagnostycznych i naprawczych;
- z niskiego poziomu inwestycji w nowe technologie w zakresie serwisu.

Rozwiązywanie wymienionych problemów zależy od specyfiki systemów zaopatrzenia stacji obsługi pojazdów samochodowych. I tak w przypadku systemu:

- zdecentralizowanego (tzw. jednowarstwowy system zaopatrzenia), obsługa klientów w warsztatach (mikro firmy serwisowe) realizowana jest poprzez bezpośredni zakup części w sklepach detalicznych;
- zcentralizowanego (tzw. wielowarstwowy, zamknięty system zaopatrzenia), obsługa w ramach zrzeszonych autoryzowanych przedsiębiorstw serwisu samochodów jednego producenta;
- rozproszonego (tzw. otwarta sieć niezależnych centrów autoserwisu), obsługa w ramach połączonych w jedną całość sieci niezależnych centrów autoserwisu.

Z punktu widzenia obsługi klienta w zidentyfikowanych systemach zaopatrzenia, niezbędna jest analiza czynników zwiększających ryzyko popełnienia błędu przez osoby podejmujące decyzje w przedsiębiorstwach serwisowych oraz zrozumienie mechanizmu konkurencji na rynku autoserwisu i jego wpływu na jakość obsługi klientów. W miarę przyspieszenia rozwoju rynku motoryzacyjnego dużego znaczenia nabiera wymiar informacyjnego wsparcia przy podejmowaniu decyzji. Wynika to przede wszystkim z faktu, że [34]:

- wnioski wyciągnięte z analiz przestarzałych informacji stają się nieaktualne, a nawet przynoszą efekty negatywne – odwrotne do oczekiwanych;
- coraz większa otwartość sieci firm serwisowych powoduje coraz większe rozproszenie informacji, co z kolei komplikuje jej gromadzenie, analizę i wykorzystanie;
- globalizacja gospodarcza przyczynia się do wejścia na rynek motoryzacyjny nowych graczy, którzy preferują ofensywną formę rywalizacji, co skutkuje powstaniem tzn. zjawiska asymetrii informacji.

Zdaniem autorów w obsłudze serwisowej warsztatów napraw należy uwzględnić podejścia do podejmowania decyzji stosowane w krajowym autoserwisie podczas organizacji łańcuchów zaopatrzenia w materiały naprawcze w relacjach „klient – przedsiębiorstwo serwisowe – producent części zamiennych”. Natomiast budowane modele decyzyjne w tym zakresie, powinny obejmować co najmniej jeden z poziomów wielopoziomowej hierarchii krajowej sieci diagnostyczno-naprawczej, którą tworzą mikro, małe i duże przedsiębiorstwa serwisowe.

3. Przegląd literatury

Wymagania dotyczące logistyki dostaw części zamiennych różnią się pod wieloma względami, co skutkuje zróżnicowaniem podejść do wyboru metod ich badań. Nie istnieje wspólny pogląd na temat opracowania jednolitego podejścia do tej kwestii. Wynika to z faktu, iż [21]:


- spektrum usług świadczonych w segmencie autoserwisu jest na ogół bardzo szeroki,
- popyt na części zamienne jest często sporadyczny, a wahania tego popytu utrudniają przewidywanie potrzeb tak asortymentu jak i liczby potrzebnych części i akcesoriów,
- zbyt niska dostępność do zapasów części zamiennych może prowadzić do podwyżek ich cen lub opóźnień terminów likwidacji szkód powypadkowych, napraw poawaryjnych itp.,
- zbyt wysokie zapasy części zamiennych i akcesoriów mogą doprowadzić do znacznych strat finansowych wynikających z kosztów ich składowania.

Problematyka organizacji łańcuchów dostaw w zaopatrzeniu i logistyki odzysku w obszarze dostaw części i serwisowania produktów jest przedmiotem zainteresowania naukowców od wielu lat. W roku 1967 zagadnienia stanowiące pierwsze podstawy tego czym jest dzisiejsza logistyka w zaopatrzeniu w części zamienne przedstawiono w pracy [48]. W tym samym czasie autor pracy [14] zwrócił uwagę na potrzebę wyodrębnienia dwóch kierunków aktywności posprzedażowej na rynku motoryzacyjnym: obsługi serwisowej nowych aut, które zostały zakupione od producenta i zostały wycofane z eksploatacji z przyczyn leżących po jego stronie oraz obsługi segmentu używanych samochodów [23]. W latach 70-80-tych logistyka służąca obsłudze używanych aut była kojarzona wyłącznie z recyklingiem, natomiast problemy napraw samochodów były rozpatrywane jako wtórne [15]. Dokonana analiza literatury w tym zakresie pozwala na stwierdzenie, iż pewnym podsumowaniem osiągnięć w tym okresie była publikacja poruszająca problem wsparcia logistycznego procesów serwisowania środków transportowych [41]. Ta publikacja może być uznana jako pierwsza, w której zwrócono uwagę na powiązanie logistyki tzw. zwrotnej z aktywnością diagnostyczną i naprawczą. W ostatnich latach badacze podkreślają rolę kontroli zapasów części zamiennych jako jednego z najważniejszych czynników wpływających na wykonanie działań serwisowych [24, 54].

O potrzebie szerszego badania roli wymiaru informacyjnego w organizacji i realizacji łańcuchów zaopatrzenia stacji obsługi pojazdów w materiały naprawcze oraz zastosowania technologii IT w obszarze tego segmentu logistyki można znaleźć m.in. w pracy [36]. Pomimo dostępności takich technologii i uznaniu ich za efektywne narzędzia zwiększenia skuteczności efektywnego zarządzania łańcuchami dostaw, dyskusja o ich wdrożeniu sprowadza się do oceny dostępności informacji wejściowej potrzebnej do realizacji zadań zaopatrzenia w części zamienne nowe jak i z odzysku [19, 42] oraz optymalizacji powiązanych kosztów i przychodów [52]. Wyniki analizy dostępnej literatury świadczą o pewnych brakach w dyskusji na temat roli informacji w usprawnieniu procesów zaopatrzenia stacji obsługi pojazdów samochodowych.

Elementy takiej analizy pojawiają się w ostatnim czasie w związku z ciągłym wzrostem znaczenia koncepcji systemowego zarządzania flotą samochodową, która dotyczy w dużej mierze planowania procesów napraw, modernizacji i wymiany w ujęciu eksploatacyjnym [46]. Problemy eksploatacji pojazdów samochodowych w trybie zarobkowym i wynikające z nich uwarunkowania odnowy mają znaczny wpływ na modele łańcuchów dostaw [51], które pełnią rolę systemu odnawiającego, przywracającego pojazdowi gotowość [28]. Wpasowanie tego systemu odnawiającego w łańcuchy dostaw części zamiennych podejmowane było m.in. w pracach [30] oraz [31].

W celu przeprowadzenia analizy zagadnień dotyczących stanu i trendów rozwojowych wielosegmentowego rynku obsługi pojazdów samochodowych dokonano przeglądu wybranych publikacji podsumowujących osiągnięcia w badanej tematyce. Szczególna uwaga została poświęcona analizie modeli logistyki dostaw towarów (rys. 1). Badaniu zostały poddawane publikacje cytowane w bazach Web of Science (Core Collection) oraz Scopus.



Rys. 1. Klasyfikacja modeli analizowanych w trakcie przeglądu literatury

Źródło: Opracowanie własne

W ostatnich dziesięcioleciach próbowano w różny sposób rozwiązać problem modelowania procesu obsługi pojazdów samochodowych. Autorzy skupili się na dwóch ważnych kwestiach, mianowicie na wsparciu procesu podejmowania decyzji oraz badaniu zależności „*wiarygodność prognoz popytu na towary – trafność decyzji o ich produkcji, składowaniu i dostawach*”. Przy czym ten ostatni kierunek skupiał się generalnie na prognozach sporadycznych zmian popytu na towary, w tym i części zamiennych; niestabilności struktury popytu na ten towar oraz poszukiwania sposobów złagodzenia ryzyka załamania dostaw na skutek niepewności informacyjnej (tabela 1). W trakcie badań analizie poddano tak modele klasyczne, w tym modele zorientowane na wykorzystanie narzędzi SCM [6] jak i zintegrowane modele sztucznych sieci neuronowych [17].

Tabela 1. Lista wyników badania modeli stosowanych w procesie dostaw towarów

Modele oparte na procedurach zarządzania ryzykiem		
Wu T. et.al, 2006 [55]	PHA/AHP - based model	Model przywidiuje dwuetapową ocenę ryzyka dostaw. Na pierwszym etapie wykonuje się analizę ewentualnych zagrożeń PHA (ang. <i>Preliminary Hazard Analysis</i>), eliminująca zaopatrzeniowców wysokiego ryzyka. Inni dostawcy przechodzą drugi etap oceny metodą hierarchii analitycznej. Zakres modelu jest ograniczony do badania dostaw jako procesu jednopoziomowego.
Heckmann I., 2016 [18]	FTA-based model	Model jest zbudowany z zastosowaniem metody FTA (ang. <i>Fault Tree Analyses</i>) do celów analizy przejawów pojedynczych zagrożeń w aspekcie terminowości dostaw. Możliwości wystąpienia wspólnych przyczyn powstania nieplanowanych przerw w dostawach nie są brane pod uwagę.
Modele oparte na oprogramowaniu pozyskania rozwiązań optymalnych		
Du F., 2008 [11]	Pareto-based model	Model dwu-kryterialnej optymalizacji według minimalizacji ogólnych kosztów obsługi samochodów i minimalizacja opóźnień w wykonaniu przedmiotu zamówienia na ich diagnostykę i naprawę
Frazzon E. M. et al., 2014[12]	MILP - based model	Model jest zorientowany na minimalizację nieplanowanych przerw w łańcuchu dostaw w procesie zaopatrzenia stacji obsługi pojazdów samochodowych oraz utrzymania ich kosztów operacyjnych na optymalnym poziomie. Symulacja wykonuje się zgodnie z utworzonym scenariuszem deterministycznym i ma na celu pozyskanie sposobów ulepszenia procesu zaopatrzeniowego poprzez optymalizację zadań logistycznych w kontekście efektywności ekonomicznej i środowiskowej.
Modele oparte na oprogramowaniu firm -producentów		
Ho C. et al., 2007 [20]	ERP-based model	Model został zbudowany w celu dokonania ocen kosztów zaopatrzenia w zależności od efektywności łańcucha dostaw realizowanych w warunkach kooperacji różnych firm współpracujących w ramach trzywarstwowego systemu ERP (ang. <i>Enterprise Resource Planning</i>).

Li SG, et al., 2008 [37]	EFNN – based model	Model jest oparty na założeniu, że w trakcie planowania dostaw menedżer posiada pewną i pełną informacje w aspektach finansowym, środowiskowym i rynkowym z wskazaniem związków przyczynowo skutkowych.
Modele dynamiczne skierowane na badanie procesów biznesowych		
Bidhandi H.M et.al, 2011 [8]	Stochastic approach – based model	Model opracowany jest na potrzebę zaopatrzenia producentów (OEM), a proces zaopatrzenia jest analizowany wyłącznie pod względem ewentualnego wzrostu kosztów operacyjnych na skutek redukcji popytu i/lub wydajności fabryk produkcji samochodów.
Ambe I., et al., 2011 [6]	Demand-driven model	Model nie przewiduje uwzględnienia zdarzeń losowych szkodliwych dla stabilności dostaw części zamiennych. Jako jedyny sposób zapewnienia ciągłości procesu dostaw wskazano na potrzebę permanentnego uzupełnienia zapasów tych części w celu łagodzenia konsekwencji sytuacji nadzwyczajnych.
Deloitte Consulting, 2017 [10]	Scenario - based model	Model jest oparty na wykorzystaniu informacji zgromadzonej poprzez wywiady ekspertów, doświadczenie menedżerów zdobytego w trakcie organizacji poprzednich dostaw i/lub na podstawie informacji zebranych w ramach monitorowania stanu oraz baz danych historycznych. Zastosowane założenie powoduje brak elastyczności w przepływach informacji oraz niekompletności pozyskanych rezultatów, ogranicza właściwą ocenę odporności SC na ryzyka.
Modele uwzględniające niepewność informacyjną		
Kochak A., 2015 [33]	ANN-based model	Model jest opracowany w celu przeprowadzenia badania zależności „wiarygodność prognoz popytu na towary – trafność decyzji o ich produkcji i dostawach”. Prognozowanie jest oparte na bardzo prostym modelu regresji, który zakłada iż popyt na towary jest funkcją czasu.
Luksch, S., 2014 [38]	ASRIM-based model	Model jest opracowany z uwzględnieniem niepewności wynikającej z braku pełnej i wiarygodnej informacji o dostawcach części zamiennych (ang. <i>inbound suppliers</i>). Nie uwzględnia zagrożeń losowych na poszczególne ogniwa łańcucha dostaw. Deklaruje się potrzeba wykorzystania zależności przyczynowo skutkowych w celu redukcji niepewności informacyjnej
He W., 2013 [17]	ANN-base model	Model jest opracowany w celu wypracowania prognoz dot. zapewnienia bezpiecznych poziomów zapasów towarów. Ma ograniczone zastosowanie, ponieważ nie określa liczby warstwy węzłów (część z nich może być ukryta) i nie porusza się kwestia optymalizacji struktury sieci, co może powodować wysunięcie błędnych wniosków. Deklaruje się potrzeba wykorzystania doświadczenia w celu eliminacji niewłaściwych decyzji
ANN - Artificial Neural Networks; ARIMA- Autoregressive Integrated Models of Moving Averages ASRIM - After Sales Risk Management; ERP - Enterprise Resource Planning; FTA- Fault Tree Analyses EFNN - Enhanced Fuzzy Neural Network, MADM- Multi Attribute Decision-Making; MILP - Mixed Integer Linear Programming; SCM- Supply Chain Management		
Źródło: Opracowanie własne		

Stwierdzono, iż autorzy tych oraz innych publikacji łączy dążenie do pozyskania skutecznych sposobów przezwyciężenia problemów istniejących w organizacji i zarządzaniu łańcuchów dostaw, opracowaniu skutecznych modeli dystrybucji towarów do magazynów lub sieci sklepów [53]. Z analizy publikacji krajowych wynika iż algorytmy genetyczne [16] mogą być zastosowane m.in. w zagadnieniach transportowych rozwiązujących problem komiwojażera [2] czy dobór środków do zadań [32].

Istniejące luki wiedzy w podstawach merytorycznych logistyki procesów zaopatrzenia stacji obsługi pojazdów samochodowych przyczyniają się do popełniania błędów w planowaniu i zarządzaniu łańcuchami dostaw a w konsekwencji do niskiej skuteczności całego systemu logistyki zaopatrzenia branży motoryzacyjnej. W związku z powyższym autorzy podjęli próbę rozwiązania szeregu problemów, mianowicie strukturyzacji polskiego rynku obsługi sprzedanych pojazdów oraz opracowania narzędzia badawczego, zwracając swoją uwagę na model ASRIM, który jest modyfikacją modelu ARIMA i daje możliwość prognozowania przepływu przesyłek towarów w warunkach niepewności informacyjnej. W celu dostosowania

tego modelu do realiów rynku krajowego zaproponowano autorskie modele adaptowane do optymalizacji wielokryterialnej, w którym oprócz minimalizacji ryzyka zamówienia niepotrzebnych lub niepasujących części zamiennych, poszukiwany jest również minimalny koszt dostaw części zamiennych. Model przywodzi możliwość doboru właściwego dostawcy, uwzględnia nieliniową dynamikę badanych zjawisk oraz złożoność procesu zaopatrzenia stacji obsługi pojazdów samochodowych [25, 26, 29]. Dążąc do ociążnięcia wyznaczonego celu autorzy podjęły decyzje o zastosowaniu algorytmu pozyskania rozwiązań opartego o sztuczne sieci neuronowe (ANN).

4. Modele decyzyjne zaopatrzenia stacji obsługi pojazdów samochodowych w części zamienne

4.1. Założenia budowy modeli decyzyjnych

Wyniki analizy literatury przedmiotu pokazują, że brakuje zwartej koncepcji definiowania modeli decyzyjnych zaopatrzenia w części zamienne podmiotów segmentu autoserwisu, szczególnie w warunkach wzrastającej rangi zarządzania flotowego.

Na rynku usług serwisowych samochodów istnieją dwa poważne problemy:

- 1) podział tego segmentu rynku motoryzacyjnego na zróżnicowane sektory;
- 2) brak efektywnych modeli łańcuchów dostaw dominujących w tych sektorach rynku.

W oparciu o zasadę tzw. Nisko Wiszącego Owocu, czyli przyjęcia najłatwiejszego z dostępnych dobrych rozwiązań (*Low Hanging Fruit*/) autorzy wskazują, że w segmencie autoserwisu rynku motoryzacyjnego można wyodrębnić trzy sektory, tj.:

1. Pierwszy sektor (S1) łączy wszystkie stacje obsługi pojazdów samochodowych, które realizują wszystkie zamówienia niezależnie od stanu technicznego, wieku lub marki pojazdu (LHF oznacza akceptację wszystkich zleceń). Wyróżniają się przestarzałym lub niespecjalistycznym sprzętem, niską wydajnością oraz wysokim stopniem zaangażowania właścicieli naprawianych aut w proces dostawy części zamiennych oraz innych materiałów. Do tego sektora zaliczono małe, niskobudżetowe, niezrzeszone oraz nieautoryzowane warsztaty, które specjalizują się głównie w mechanice pojazdowej, blacharstwie i lakiernictwie, a za usługi pobierają niższe wynagrodzenie niż stacje autoryzowane.
2. Do drugiego sektora (S2) zaliczono wysokobudżetowe autoryzowane stacje obsługi, dla których LHF oznacza serwisowanie samochodów jednego producenta, każdego stopnia złożoności, stosujące tylko oryginalne części zamienne, połączone w sieć z innymi stacjami tego samego producenta. Oferują szeroki zakres usług, a w ich ofercie znajduje się również sprzedaż części zamiennych, co znacznie przyspiesza naprawę, dysponują lepszym wyposażeniem, np. komputerami diagnostycznymi co ułatwia pracę mechaników.
3. Do trzeciego sektora (S3) zalicza się firmy usługowe, które wykonują wszelkiego rodzaju usługi serwisowe dla wszelkich marek samochodów z wykorzystaniem oryginalnych części zamiennych i akcesoriów, specjalizujące się w elektronice samochodowej, diagnostyce bezinwazyjnej, serwisie i obsłudze klimatyzacji oraz innych złożonych systemów samochodów. Takie firmy są zazwyczaj autoryzowane przez kilku producentów i połączone zgodnie z zasadą Business-to-Business integrated (B2Bi).

W tabeli 2 przedstawiono główne bariery ograniczające rozwój poszczególnych segmentów ze względu na niepewność informacji. Dla opracowania odpowiednich modeli łańcuchów dostaw części zamiennych i potrzebnych akcesoriów należy uwzględnić niektóre zasady wyboru strategii zarządzania tymi łańcuchami na które wskazuje m.in. Lee, H. w pracy [35]. Według zaleceń wybrana strategia zarządzania powinna:

- zapewnić minimalne koszty zaopatrzenia i utrzymania zapasów na minimalne wymagany poziomie;

- brać pod uwagę fakt, że popyt na części zamienne ma charakter probabilistyczny wynikający z sezonowej nierówności zleceń serwisowych, regionalnych rozbieżności popytu itp.;
- eliminować błędy w organizacji łańcuchów dostaw jako źródła strat finansowych proporcjonalnych do liczby klientów utraconych z przyczyn powstania deficytu części zamiennych lub innych materiałów naprawczych.

Tabela 2. Udział poszczególnych barier w rozwoju stacji obsługi pojazdów samochodowych w poszczególnych sektorach

Barierzy rozwoju logistyki zwrotnej		Ogólny			Częściowy			Lokalny			Udział (%)		
		S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
1	Brak odpowiednio wykwalifikowanego personelu	0,8	0,8	4,7	7,7	7,7	3,1	9,2	5,3	4,3	17,7	13,8	12,1
2	Przestarzałe modele biznesowe	0,3	0,2	3,2	2,1	0,6	0,7	6,0	8,1	0,2	8,4	8,9	4,1
3	Brak kompatybilności technologii stosowanych i planowanych do zastosowania	0,4	0,9	0,7	1,9	3,1	2,8	3,0	2,8	4,1	5,3	6,8	7,6
4	Zbyt wysoki koszt wdrożenia innowacji	8,4	2,4	1,4	2,0	8,3	5,3	11,1	0,4	3,4	21,5	11,1	10,1
5	Brak osobistej motywacji	2,2	7,9	12,9	5,0	7,1	4,1	8,1	3,2	2,2	15,3	18,2	19,2
6	Wykorzystanie przestarzałego sprzętu	0,1	0,0	0,1	2,0	0,7	3,7	9,3	6,2	8,3	11,4	6,9	12,1
7	Niepełność informacyjna w aspektach finansowym, środowiskowym i rynkowym	12,3	15,3	20,1	4,2	17,2	11,1	3,9	1,8	3,6	20,4	34,3	34,8
Udział (%)		24,5	27,5	43,1	24,9	44,7	30,8	50,6	27,8	26,1	100	100	100
Opracowanie własne na podstawie: [34]													

Mając powyższe na uwadze autorzy zaproponowali trzy modele przepływów materiałów i części zamiennych opracowane na podstawie wyników analizy krajowego systemu posprzedażowej obsługi samochodów. W modelach tych jako kryterium oceny przyjęto minimalizację ryzyka błędnie podejmowanych decyzji na podstawie asymetrii informacji, niepełnej lub przestarzałej informacji.

4.2. Model łańcucha dostaw dla mikro-segmentu nieautoryzowanych stacji obsługi pojazdów samochodowych

4.2.1 Założenia modelu


Ten segment stacji obsługi pojazdów samochodowych obejmuje mikro przedsiębiorstwa, które zwykle są nieautoryzowanymi jednostkami niezależnymi. Zatrudniają 1-2 pracowników, którzy w ciągu dnia roboczego mogą dokonać naprawy średnio 2-3 samochodów. Klienci decydują się na zaangażowanie w prace naprawcze stacje z tego segmentu, jeżeli wymianie podlegają nieliczne elementy, najczęściej w układach hamulcowych, elektrycznym lub zawieszeniu, czyli na naprawy typu R&I (ang. *Remove & Install*) lub R&R (ang. *Remove & Replace*). W przypadku potrzeby niezwłocznej naprawy, ciężar znalezienia i dostawy części

zamiennych spada często na klientów, którzy mogą zamówić te części online np. stosując system dostaw iPARTS [dostawy ekspresowe].

Przy tym, obieg informacji w jednostkach tego segmentu autoserwisu ma dwa tryby:

1. spowolniony, wynikający z potrzeby dogłębnej analizy stanu samochodu, wyboru technologii zdiagnozowania ewentualnych usterek zmęczenia, załatwienia niezbędnych formalności itp.
2. przyspieszony, wynikający z potrzeby wywiązania się z warunków umowy na naprawą

Proces podejmowania decyzji występuje we wszystkich etapach napraw samochodów i może być opisany zależnością o kształcie litery S (rys.2).



Rys. 2. Dynamika przebiegu podejmowania decyzji. Źródło: Opracowanie własne

Z taką sytuacją wiąże się:


1. Spowolnienie wymiany informacji wykorzystywanych w procesie decyzyjnym dotyczącym załatwienia formalności związanych z naprawą i rozliczeniem, uzgodnienia terminu naprawy, planowania prac diagnostycznych i naprawczych, wyceny kosztów usługi, organizacji dostaw części zamiennych, wnioskowania na podstawie wyników diagnostyki uszkodzeń. Źródło ryzyka niewłaściwych decyzji na tym etapie – posługiwanie się niewiarygodną informacją od klientów, dostawców itp.
2. Przyspieszenie wymiany informacji wykorzystywanych w procesie decyzyjnym w trakcie demontażu zużytych części samochodowych, naprawy oraz następnego montażu części zamiennych i akcesoriów. Źródło ryzyka niewłaściwych decyzji na tym etapie – wewnętrzny czynnik ludzki.
3. Spowolnienie wymiany informacji wykorzystywanych w procesie decyzyjnym dotyczącym sprawdzenia jakości wykonanej naprawy, udzielenia gwarancji na wykonaną naprawę, trybu postępowania w przypadku złożenia reklamacji. Źródło ryzyka niewłaściwych decyzji na tym etapie – posługiwanie się niewiarygodnymi wynikami wykonanych testów, nieprawdziwą informacją o jakości dostarczonych części zamiennych i akcesoriów itp.

4.2.2 Zapis formalny problemu decyzyjnego

Analiza sytuacji decyzyjnej wskazuje, że model charakteryzuje się:

- niestabilnym okresem zaopatrzenia, ponieważ klienci nie mają rozeznania rynku części zamiennych i materiałów naprawczych,
- częstotliwość zleceń naprawy zależy od zjawisk sezonowych, warunków pogodowych, fachowości wcześniej wykonanych przeglądów i prac diagnostycznych,

- bardzo wysokim poziomem asymetrii informacji, którą wymieniają się strony w relacjach „Klient – stacja obsługi pojazdów” oraz ”Klient - Sklep Części Zamiennych” (rys.3).



Rys. 3. Aktywność logistyczna na mikro segmencie nieautoryzowanych warsztatów autoserwisu.
Źródło: Opracowanie własne

Analiza sytuacji z punktu widzenia decydenta pozwala na wyróżnienie dwóch stanów:

- ST-I - Jeżeli decydent znajdzie się w sytuacji, która charakteryzuje się bieżącym dostarczaniem i odbiorem danych dotyczących popytu na usługi autoserwisu, jego poziom niepewności informacyjnej może być oceniony jako U_i^o . W tej sytuacji ryzyko podjęcia wadliwej decyzji może być ocenione jako $R(U_i^o)$.
- ST-II - w tym stanie możliwa jest również sytuacja, kiedy decydentowi przez pewien okres czasu Δt , nowa informacja nie jest dostarczana. Zwiększa to ryzyko podjęcia niekorzystnej decyzji, a wartość tego wzrostu określa się jako $U_{\Delta t}$.

Ryzyko podjęcia błędnych decyzji w każdym elemencie ogniwie łańcucha dostaw tj. przez przedstawiciela stacji obsługi pojazdów, klienta, producenta czy sklep motoryzacyjny może być opisane jako:

$$R(U_i^o + U_{\Delta t}) - R(U_i^o) = \Delta R_i^o \quad (1)$$


Z równania (2) wynika, że wartość ΔR_i^o jest miarą ryzyka decyzji na podstawie przestarzałej informacji. W przypadku, kiedy decydent opiera swoje decyzje na informacji jemu dostarczanej:

- w sposób regularny, czyli $R(U_{\Delta t}) \rightarrow 0$, to niezależnie od kategorii takiej informacji (proces starzenia dostarczanych danych ma charakter przyspieszony lub nie) ryzyko podjęcia błędnych decyzji jest na poziomie akceptowalnym;
- w sposób nieregularny, czyli $R(U_{\Delta t}) \gg R(U_i^o)$ to ryzyko podjęcia niewłaściwej decyzji może przekroczyć poziom akceptowalności.

W rezultacie dąży się, aby $\Delta R_i^o \rightarrow 0$.

Przepływ informacji w modelu dla mikro-segmentu nieautoryzowanych stacji obsługi pojazdów samochodowych odbywa się na dwóch płaszczyznach: warsztat - klient oraz stacja obsługi – sklep motoryzacyjny. W pierwszym przypadku klient organizuje proces zaopatrzenia

części do stacji obsługi pojazdów samochodowych, w drugim przypadku klient nie bierze udziału w procesie zaopatrzenia, stacji obsługi pojazdów samochodowych dokonuje zamówienia towaru. Przepływ informacji w relacji stacja obsługi-klient można przedstawić w następujący sposób: m -ta stacja obsługi pojazdów samochodowych obsługuje k -tego klienta i diagnozuje awarie w j -tym pojeździe (Rys 4).



stacja obsługi pojazdów – klient stacja obsługi pojazdów – sklep motoryzacyjny
Rys. 4 Graf przepływu informacji w modelu łańcucha dostaw dla mikro-segmentu nieautoryzowanych stacji obsługi pojazdów samochodowych. Źródło: opracowanie własne

Ryzyko niepoprawnej diagnozy uszkodzenia pojazdu danego klienta wydana przez m -ta stacja obsługi pojazdów samochodowych przyjmuje się jako $\Delta R1^0(m, k)$. Klient podejmując się zakupu i -tej brakującej części w s -tym sklepie motoryzacyjnym, ryzyko popełnienia błędu w zakupie przez klienta można określić jako $\Delta R2^0(k, (i, s))$. Ryzyko związane z niedopasowaniem części kupionej w danym sklepie do pojazdu można określić jako $\Delta R3^0((i, s), j)$. W przypadku niedopasowania części zakupionej przez klient do swojego samochodu stacja obsługi pojazdów samochodowych odkupuje ją i wykorzystuje w innych pojazdach zgodnie z znanym ryzykiem dopasowania $\Delta R3^0((i, s), j)$. Problematiczne jest znalezienie takiego przepływu informacji pomiędzy stacją obsługi pojazdów samochodowych a klientem, aby ryzyko niepowodzenia naprawy pojazdu wynikające z błędnych informacji była minimalna.

Biorąc pod uwagę powyższe rozważania przyjęto trzy typy zmiennych decyzyjnych modelu: X1 – przepływ informacji od m -tą stacja obsługi pojazdów samochodowych do k -tego klienta, Y1 – przepływ informacji pomiędzy k -tym klientem a s -tym sklepem motoryzacyjnym oferującym i -tą część, Z1 – przepływ informacji wynikający ze zgodność dopasowania i -tej części do j -tego uszkodzonego pojazdu oferowanej przez s -ty sklep motoryzacyjny, tj.:

$$X1 = [x1(m, k): x1(m, k) \in \{0,1\}, m \in M, k \in K]$$

$$Y1 = [y1(k, s, i): y1(k, s, i) \in \{0,1\}, k \in K, s \in S, i \in I]$$

$$Z1 = [z1((i, s), j): z1((i, s), j) \in \{0,1\}, i \in I, s \in S, j \in J]$$

Funkcja kryterium została zdefiniowana jako minimalizacja ryzyka błędnych decyzji podejmowanych przez wszystkich klientów dla zaopatrzenia m -tej stacji obsługi pojazdów samochodowych w brakujące części, tj.:

$$\forall m \in M$$

$$\begin{aligned}
F1(\mathbf{X1}, \mathbf{Y1}, \mathbf{Z1}) &= \prod_{k \in K} x1(m, k) \cdot \Delta R1^0(m, k) \cdot \prod_{k \in K} \prod_{s \in S} \prod_{i \in I} y1(k, s, i) \cdot \Delta R2^0(k, (i, s)) \\
&\cdot \prod_{s \in S} \prod_{i \in I} \prod_{j \in J} z1((i, s), j) \cdot \Delta R3^0((i, s), j) \rightarrow \min
\end{aligned} \tag{2}$$

Natomiast przepływ informacji w relacji stacja obsługi-sklep samochodowy odbywa się następująco: stacja obsługi pojazdów samochodowych po diagnozie uszkodzenia w danym pojeździe zamawia daną część w sklepie samochodowym, ryzyko błędnego zdiagnozowania i zamówienia i -tej części przez m -tą stację obsługi w s -tym sklepie samochodowym wynosi $\Delta R4^0(m, i, s)$. Ryzyko związane z niedopasowaniem części kupionej w danym sklepie do pojazdu można określić jako $\Delta R3^0((i, s), j)$.

W tym przypadku zdefiniowano dwa typy zmiennych decyzyjnych: $\mathbf{X2}$ – o interpretacji przepływu informacji od m -tej stacji obsługi pojazdów samochodowych do s -tego sklepu w sprawie zamówienia i -tej części, $\mathbf{Z1}$ - zmienna określająca przepływ informacji wynikający ze zgodności dopasowania i -tej części do j -tego uszkodzonego pojazdu oferowanej przez s -ty sklep motoryzacyjny przyjmuje postać identyczną jak w relacji stacja obsługi-klient.

$$\mathbf{X2} = [x2(m, i, s): x2(m, i, s) \in \{0, 1\}, m \in M, i \in I, s \in S]$$

W tym przypadku funkcja kryterium minimalizująca ryzyko błędnych decyzji podejmowanych przez m -tą stację obsługi pojazdów w brakujące części przyjmuje postać:

$$\begin{aligned}
F2(\mathbf{X2}, \mathbf{Z1}) &= \prod_{i \in I} \prod_{s \in S} x2(m, i, s) \cdot \Delta R4^0(m, i, s) \cdot \\
&\cdot \prod_{s \in S} \prod_{i \in I} \prod_{j \in J} z1((i, s), j) \cdot \Delta R3^0((i, s), j) \rightarrow \min
\end{aligned} \tag{3}$$

4.3 Model łańcuchu dostaw dla mikro-segmentu autoryzowanych stacji obsługi pojazdów samochodowych

4.3.1 Uwagi ogólne

Model łańcuchu dostaw dla mikro-segmentu autoryzowanych stacji obsługi pojazdów samochodowych obejmuje Centra dilerskie, które zwykle są autoryzowanymi jednostkami zależnymi, połączonymi w sieci dystrybucji nowych aut produkowanych przez jednego producenta. Zatrudniają 3-5 pracowników, którzy w ciągu dnia roboczego mogą średnio dokonać napraw 4-6 aut. Mając do dyspozycji specjalistyczne narzędzia dedykowane dla konkretnych modeli samochodów oraz elektroniczne systemy diagnostyki, realizują różne rodzaje usług serwisowych, pośród których oprócz R&I i R&R wykonywane naprawy typu FEA (*Front- End Alignment*). Centra dilerskie cechują się możliwością korzystania z zapasów zgromadzonych w niewielkich magazynach będących częścią funkcjonalną takiej stacji obsługi pojazdów samochodowych.

Producenci inwestują w obiekty magazynowe, które gromadzą do kilku tysięcy części zamiennych. Dzięki temu Centra dilerskie są w stanie utrzymać zdolność naprawczą dla wcześniejszych modeli samochodów i reagować szybciej na zapotrzebowanie. Dostawy do krajowych Centrów Dilerskich odbywają się 3-4 razy w tygodniu. Przykładem takiego systemu jest system dystrybucji Grupy InterCars zbudowany na trzech płaszczyznach: filie, magazyny regionalne i magazyn centralny. Niezależnie od struktury standardowej funkcjonuje system


Service 24h, gdzie w przypadkach awaryjnych można dokonać wysyłki części zamiennych także w święta [22].

Dla mikro-segmentu autoryzowanych Centrów dilerskich główną barierą jest niepewność informacyjna, która powstaje kiedy jedna ze stron posiada ich więcej (np. producent samochodów) niż druga strona (np. menadżer stacji obsługi pojazdów samochodowych), który znajduje się w tzw. niedoczasy informacyjnym. Ponieważ trafność decyzji zależy od wartości posiadanej informacji (użyteczności pod względem przydatności, terminowości, kompletności i wiarygodności) menadżerowie zawsze dążą do uzyskania dodatkowych informacji.

4.3.2 Opis formalny problemu decyzyjnego

W przypadku stwierdzenia braku wymaganych materiałów naprawczych istnieją dwa sposoby ich dostarczenia do stacji obsługi pojazdów samochodowych (rys.5):

- dostarczenie ich przez właściciela samochodu serwisowanego (na znikomym poziomie);
- wykonanie zamówienia, które wymaga planowania okresu i struktury zaopatrzenia, w zależności od stanu zapasów w magazynie. W celu minimalizacji kosztów transportowych i kosztów dostawy nawet w zadaniach krótkoterminowego planowania zakłada się przeważnie zwiększenie zapasów części zamiennych do stanu maksymalnego.



Rys. 5. Aktywność logistyczna na mikro segmencie autoryzowanych centrów dilerskich

Źródło: Opracowanie własne

Okres zaopatrzenia jest niestabilny na skutek asymetrii informacji o rzeczywistym stanie technicznym samochodu dostarczonego do naprawy (nawet szczegółowa diagnoza nie zawsze wykrywa wszystkie usterki) oraz nieznanych priorytetach dostaw części przez dystrybutora.

Większość decydentów np. menadżerów Centrów Dilerskich wyróżnia się niechęcią do podejmowania ryzyka. Przyjęto, więc że udaje się im w czasie Δt podejmowania decyzji wejść w posiadanie dodatkowej informacji $I_{\Delta t}$, która redukuje poziom niepewności o $U_{\Delta t}$. Wówczas:

- asymetria jego wiedzy maleje do poziomu $[U_i^v - U_{\Delta t}]$.
- redukcja ryzyka podjęcia decyzji w tym przypadku wynosi:

$$R(U_i^v) - R(U_i^v - U_{\Delta t}) = \Delta R_i^v \quad (4)$$

gdzie:

U_i^v – niepewność informacyjna decydentów po każdej i -tej decyzji; $R(U_i^v)$ – ryzyko podjęcia i -tej decyzji.

Wartość ΔR_i^v odzwierciedla poziom ewentualnej asymetrii informacji posiadanej przez menadżerów autoryzowanych stacji obsługi pojazdów samochodowych.

Dla takiej sytuacji zdefiniowano zmienne decyzyjne określające przepływ informacji, tj.: $X2$ – przepływ informacji pomiędzy c -tym centrum dilerskim a k -tym klientem, ryzyko złej diagnozy można określić jako $\Delta R5^v(c, k)$, $Y2$ – przepływ informacji między c -tym centrum dilerskim a w -tym magazynem zaopatrzeniowym, ryzyko błędnego zamówienia i -tej części $\Delta R6^v(c, w, i)$; $Z2$ – przepływ informacji między magazynem a centrum dilerskim określającym ryzyko wysłania złej i -tej części $\Delta R7^v(w, c, i)$.

Funkcja kryterium określająca minimalizację ryzyka dokonania zamówienia nieodpowiedniej części zamawianej przez dane centrum dilerskie przyjmuje postać:

$$F2(X2, Y2, Z2) = \prod_{c \in C} x2(c, k) \cdot \Delta R5^v(c, k) \cdot \prod_{w \in W} \prod_{i \in I} y2(c, w, i) \cdot \Delta R6^v(c, w, i) \cdot \prod_{w \in W} \prod_{i \in I} z2(w, c, i) \cdot \Delta R7^v(w, c, i) \rightarrow \min \quad (5)$$

4.4 Model łańcucha dostaw dla mikro-segmentu wysokobudżetowych centrów serwisowych

4.4.1 Założenia modelu

Jedną z tendencji na rynku jest kierowanie zwrotów sprzedanej produkcji do wyspecjalizowanych centrów zwrotów (ang. *Centralized Return Center*), zamiast do tradycyjnych centrów dystrybucyjnych CDC. Przyczyną tego jest fakt, że większość centrów dystrybucyjnych koncentruje się na sprzedaży nowych towarów i ich serwisowaniu, a nie na pracach diagnostycznych i naprawczych. Celem CRC jest więc minimalizacja kosztów napraw w rezultacie wykonania prac na wysoko wyspecjalizowanych stanowiskach jak i ryzyka zakupu nowego produktu.


Analizowany mikro-segment obejmuje duże Centra zwrotu samochodów – CRC. Takie centra zatrudniają ponad 10 pracowników, którzy w ciągu dnia roboczego dokonują średnio 7–10 napraw samochodów. Dysponują częściami zamiennymi i akcesoriami samochodowymi oraz biorą czynny udział w procesie logistyki zwrotnej. Od ponad dziesięciu lat CRC wdrażają procedury e-commerce i funkcjonują w trybie on-line. W ofercie takich platform internetowych znajduje się do miliona części zamiennych oraz innych materiałów potrzebnych do naprawy samochodów [39].

Dla mikro-segmentu CRC główną barierą jest niepewność informacyjna jako rezultat jej zniekształcenia w wyniku rozproszenia w trakcie gromadzenia, przekazywania i przetwarzania w rozległych sieciach. Stopień zniekształcenia danych jest wprost proporcjonalny do liczby kanałów przez które informacje są przekazywane (np. relacja „stacja obsługi pojazdów samochodowych – centrum zwrotu”, czy „centrum zwrotu – magazyn”).

4.4.2 Formalny zapis problemu decyzyjnego

Model serwisowania usług w mikro-segencie jest oparty na zasadzie utrzymania krytycznych poziomów zapasów materiałów potrzebnych do realizacji zadań obsługi serwisowej samochodów oraz zapasów zorientowanych na sprzedaż osobom trzecim. Zaopatrzenie jest dokonywane po osiągnięciu ich minimalnego poziomu. Planowany okres zaopatrzenia nie wpływa na czas obsługi indywidualnych klientów.

W sytuacji obsługi samochodów wycofywanych z eksploatacji grupowo na skutek wykrycia wady fabrycznej, trzeba wziąć pod uwagę oczekiwanie na dostawę całej partii części zamiennych, a okres zaopatrzenia jest niestabilny w wyniku asymetrii informacji w relacji „CRC – Producent samochodów” (rys. 6).



Rys. 6. Aktywność logistyczna na mikro-segencie Centrów zwrotu
Opracowanie własne

Analiza sytuacji z punktu widzenia decydenta pozwala na wyróżnienie dwóch stanów. Niech decydent znajdzie się w sytuacji, która charakteryzuje się możliwością uzyskania informacji bezpośrednio z jej źródła, a liczba tych źródeł jest ograniczona. W tym przypadku U_i^d oznacza niepewność informacyjną menadżera pracującego w sieci CRC, a $R(U_i^d)$ oznacza ryzyko podjęcia błędnej decyzji. Możliwa jest też sytuacja, w której decydent pozyskuje informacje z rozmaitych kanałów, które z kolei pozyskują dane z jeszcze innych źródeł. W tym przypadku procesy gromadzenia, przekazywania i przetwarzania danych są obciążone z prawdopodobieństwem zniekształcenia informacji. W tym przypadku ryzyko podjęcia błędnej decyzji może być ocenione jako:

$$R_i^d \left(U_i^d + \sum_{n=1}^m U_n^f \right) - R(U_i^d) = \Delta R_i^d \quad (6)$$

gdzie:

m – liczba źródeł informacji,

n – liczba kanałów przekazania informacji w każdy z których może dojść do jej zniekształcenia.

Wartość ΔR_i^d odzwierciedla stopień ewentualnego zniekształcenia informacji w otwartej sieci CDC.

W tym przypadku zdefiniowano cztery typy zmiennych decyzyjnych, tj.: X3 - przepływ informacji pomiędzy centrum zwrotu pojazdów wadliwych a magazynem, ryzyko związane z wadliwym zamówieniem i -tej części, $\Delta R8^d(cr, w, i)$; Y3 - przepływ informacji pomiędzy centrum zwrotu pojazdów wadliwych a sklepem części zamiennych, ryzyko związane z wadliwym zamówieniem i -tej części, $\Delta R9^d(cr, s, i)$; Z3 - przepływ informacji pomiędzy magazynem a centrum zwrotu pojazdów, ryzyko wysłania niepasującej części, $\Delta R10^d(w, cr, i)$; K4 - przepływ informacji pomiędzy sklepem a centrum zwrotu pojazdów, ryzyko wysłania niepasującej części, $\Delta R11^d(s, cr, i)$.

Funkcja kryterium określająca minimalizację ryzyka dokonania zamówienia niepasującej części zamawianej przez dane centrum zwrotu przyjmuje postać:


$$\begin{aligned}
 & \forall cr \in CRC \\
 F3(X3, Y3, Z3, K3) = & \prod_{w \in W} \prod_{i \in I} x3(cr, w, i) \cdot \Delta R8^d(cr, w, i) \cdot \\
 & \cdot \prod_{s \in S} \prod_{i \in I} y3(cr, s, i) \cdot \Delta R9^d(cr, s, i) \\
 & \cdot \prod_{w \in W} \prod_{i \in I} z3(w, cr, i) \cdot \Delta R10^d(w, cr, i) \cdot \prod_{s \in S} \prod_{i \in I} k3(s, cr, i) \cdot \Delta R11^d(s, cr, i) \\
 & \rightarrow \min
 \end{aligned}
 \tag{7}$$

5. Algorytm minimalizacji ryzyka w procesie zaopatrzenia stacji obsługi pojazdów samochodowych w części zamienne

5.1. Założenia ogólne algorytmu genetycznego

Rozwiązanie modeli decyzyjnych opracowanych w rozdziale czwartym wymaga zastosowania odpowiedniego algorytmu optymalizacyjnego adekwatnego do zastosowanych w modelach zmiennych decyzyjnych. Algorytm genetyczny jest algorytmem iteracyjnym, więc generowane rozwiązanie poprawia się z każdym jego przejściem do kolejnych iteracji. Każdy osobnik w populacji jest oceniany zgodnie z przyjętą do problemu funkcją przystosowania. Proces selekcji w algorytmie genetycznym polega na wyborze najlepszych osobników (chromosomów) z populacji początkowej do następnego pokolenia. Proces krzyżowania polega na wymianie materiału genetycznego pomiędzy dwoma osobnikami, w wyniku którego uzyskuje się osobniki populacji potomnej. Proces mutacji polega na zamianie pojedynczych genów w chromosomie. Populacja osobników składa się z pojedynczych chromosomów, które reprezentują rozwiązanie danego problemu decyzyjnego.

Uproszczony schemat działania klasycznego algorytmu genetycznego przedstawiono na Rys. 7.



Rys. 7. Schemat algorytmu genetycznego

Źródło: opracowane własne.

5.2. Etapy konstruowania algorytmu

Etapy konstruowania algorytmu genetycznego zostały przedstawione w oparciu o model łańcucha dostaw dla mikro-segmentu nieautoryzowanych stacji obsługi pojazdów samochodowych. Etapy algorytmu można przedstawić jako: **Etap 1.** Określenie struktury danych wejściowych. **Etap 2.** Określenie funkcji przystosowania. **Etap 3.** Określenie procesu reprodukcji. **Etap 4.** Określenie procesu krzyżowania. **Etap 5.** Określenie procesu mutacji.

Etapy I-II są etapami jednorazowymi, zachodzącymi na początku działania algorytmu, etapy III-V powtarzane są określoną liczbę iteracji, aż do momentu uzyskania warunku stopu. Warunkiem stopu jest określona liczba iteracji. Ocena osobników jest przeprowadzona na podstawie funkcji przystosowania, która jest opracowana w oparciu o funkcje kryteriów poszczególnych modeli przepływu informacji w łańcuchach zaopatrzeniowym.

Struktura danych przetwarzanych przez algorytm jest strukturą macierzową określającą połączenia pomiędzy poszczególnymi obiektami sieci zaopatrzeniowej, jak również przedstawia liczbę części zamówionych od poszczególnych dostawców. Struktury przedstawiają wartości jakie przyjmują zmienne decyzyjne modelu łańcucha dostaw dla mikro-segmentu nieautoryzowanych stacji obsługi pojazdów samochodowych (zmienna decyzyjna X1 – przepływ informacji pomiędzy stacją obsługi (wiersze macierzy) a klientem (kolumny macierzy), zmienna decyzyjna Y1 – przepływ informacji pomiędzy klientem (wiersze macierzy) a sklepem (kolumny macierzy), zmienna decyzyjna Z1 – dopasowanie części (wiersze macierzy) do pojazdu uszkodzonego (kolumny macierzy)). Zmienna decyzyjna Y1a jest zmienną określającą zakup określonej liczby części przez danego klienta (wiersze macierzy) w danym sklepie motoryzacyjnym (kolumny macierzy). Każdy sklep oferuje daną część po różnej cenie. Problematyczne jest wskazanie sklepów, w których można dokonać zaopatrzenia w daną część po minimalnych kosztach zakupu. Przykładowa struktura została przedstawiona na Rys. 8.

Zmienna decyzyjna X1										Zmienna decyzyjna Y1										Zmienna decyzyjna Z1										Zmienna decyzyjna Y1a									
	1	2	3	4	5	6	7	8	9		1	2	3	4	5	6	7	8	9		1	2	3	4	5	6	7	8	9		1	2	3	4	5	6	7	8	9
1	0	1	0	0	0	0	0	0	0	1	0	0	1	0	0	0	0	0	0	1	0	0	0	1	0	0	0	0	0	1	0	0	3	0	0	0	0	0	
2	0	0	0	1	0	0	0	0	0	2	0	0	0	0	1	0	0	0	0	2	0	1	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	
3	0	0	0	0	0	1	0	0	0	3	0	0	0	0	0	0	0	0	0	3	0	0	0	0	0	0	1	0	0	3	0	0	0	0	0	0	0	0	
4	0	0	1	0	0	0	0	0	0	4	0	1	0	0	0	0	0	0	0	4	0	0	1	0	0	0	0	0	0	4	0	3	0	0	0	0	0	0	
5	0	0	0	0	0	1	0	0	0	5	0	0	0	0	0	0	1	0	0	5	0	0	0	0	0	0	1	0	0	5	0	0	0	0	0	0	2	0	0
6	0	0	0	0	0	0	0	0	0	6	0	0	0	1	0	0	0	0	0	6	1	0	0	0	0	0	0	0	0	6	0	0	0	1	0	0	0	0	

Rys.8 Struktura macierzowa algorytmu genetycznego

Źródło: opracowane własne

Funkcja przystosowania jest funkcją oceniającą daną strukturę macierzową. W celu przedstawienie problemu w ujęciu wielokryterialnym funkcja przystosowania przyjmuje następującą postać:

$$F_{dop} = \frac{F1(X1, Y1, Z1)}{F1min(i)} + \frac{F(Y1a)}{Fmin(i)} \rightarrow min$$

gdzie:

$F1(X1, Y1, Z1)$ - funkcja oceniająca ryzyko powstania błędu w wyniku przepływu niepoprawnej informacji,

$F(Y1a)$ - funkcja kosztu zakupu części,

$F1min(i)$ - minimalna wartość funkcji ryzyka wybrana w całej populacji w danej iteracji,

$Fmin(i)$ - minimalna wartość funkcji kosztów wybrana w całej populacji w danej iteracji,

Operacja reprodukcji (selekcji) polega na powielaniu struktur macierzowych w kolejnych pokoleniach (iteracjach algorytmu) w zależności od funkcji przystosowania tych struktur. W procesie selekcji zastosowano tzw. metodę ruletki opartą na wyborze nowej populacji zgodnie z rozkładem prawdopodobieństwa określonym na wartościach funkcji dopasowania [16].

Krzyżowanie chromosomów (struktur macierzowych) polega na losowym wybraniu zmiennej decyzyjnej w której proces krzyżowania będzie realizowany, losowym wyborze podstruktury macierzowej, która będzie wymieniana pomiędzy dwoma chromosomami. W przypadku wylosowania zmiennej Y1 proces krzyżowania musi zajść jednocześnie dla zmiennej Y1 i Y1a.

Proces mutacji polega na losowym wyborze zmiennej decyzyjnej i losowym zmianie genu. W przypadku zmiennych decyzyjnych binarnych z 0 na 1 lub 1 na zero, natomiast dla zmiennej całkowitoliczbowej zwiększenie wartości genu o 1 lub zmniejszenie o 1.

Końcowym efektem algorytmu po zrealizowaniu określonej liczby iteracji jest ustalenie takich zmiennych decyzyjnych, które wpływają jednocześnie na minimalizację ryzyka i kosztu zamówienia określonych części do stacji obsługi pojazdów samochodowych.

6. Wnioski

W artykule przedstawiono podstawy teoretyczne opracowania modeli decyzyjnych łańcuchów dostaw zaopatrujących stacje obsługi pojazdów samochodowych w części w oparciu o niepewność informacji związana z różnymi sytuacjami losowymi np. ryzykiem błędnej diagnozy uszkodzonego pojazdu i w konsekwencji kupnem niepasującej części, ryzykiem pomyłki w wydaniu części przez sklep motoryzacyjny. Zaproponowano również oryginalny autorski algorytm optymalizacyjny minimalizujący ryzyko związane z zakupem części.

W sytuacji niskiego popytu na usługi serwisowe i niepewności jego wzrostu w krótkoterminowej perspektywie, efektywność wsparcia logistycznego jest jedyną przewagą

konkurencyjną warsztatów serwisowych, a zdolność racjonalizacji kosztów i sprawność działania w wymiarze informacyjnym są dwoma składowymi tej efektywności.

Natomiast w przypadku wysokiego popytu na usługi serwisowe z przyczyn sezonowych lub modernizacyjnych zakrojonych na szeroką skalę, jednym z zadań logistyki jest zaprojektowanie łańcuchów dostaw części zamiennych oraz innych materiałów naprawczych. Takie dostawy na skutek wysokiego popytu muszą być wykonywane wg zasady maksymalnej ich sprawności. Stacje obsługi pojazdów samochodowych w tej sytuacji stają się wysoko rentowne w przypadku obsługi klientów korporacyjnych. Należy podkreślić, że w przypadku wysokiego popytu na usługi serwisowe i pewności długookresowego trendu wzrostowego zwiększa się poziom niepewności w stosunku do możliwości dostaw części zamiennych wg zasady JIT. Taka przesłanka stanowi ryzyko niewykonania prac remontowych na czas i niesprostania oczekiwaniom klienta.

Literatura

1. A Look at Trends and Statistics in the Automotive Aftermarket Industry. <https://v12data.com/blog/a-look-at-trends-and-statistics-in-the-automotive-aftermarket-industry-2017/> [dostęp 22.04.2020]
2. Abdoun O, Abouchabaka J. A Comparative Study of Adaptive Crossover Operators for Genetic Algorithms to Resolve the Traveling Salesman Problem. *International Journal of Computer Applications* 2011; 31(11): 49-57.
3. Abramek K F, Uzdowski M. Pojazdy samochodowe. Podstawy obsługi i napraw. Wydawnictwa Komunikacji i Łączności 2009.
4. ACEA: Report Average age of the EU motor vehicle fleet, by vehicle type., 11/06/2019, <https://www.acea.be/statistics/tag/category/average-vehicle-age> [dostęp 15.04.2020]
5. ACEA: *Report Vehicles in use Europe 2019* https://www.acea.be/uploads/publications/ACEA_Report_Vehicles_in_use-Europe_2019.pdf [dostęp 22.04.2020]
6. Ambe I M, Badenhorst-Weiss J A. An automotive supply chain model for a demand-driven environment. *Journal of Transport and Supply Chain Management* 2011.
7. Assessment of the potential consumer response to the Extended Vehicle approach. Global report I Research Now SSI, p. 15. December 2018
8. Bidhandi H.M et.al: Integrated supply chain planning under uncertainty using an improved stochastic approach. *Applied Mathematical Modelling*. Vol. 35, Issue 6, 2011, Pages 2618-2630
9. Carter C, Ellram L. Reverse logistics: a review of literature and framework for future investigation. *Journal of Business Logistics* 1998; 19(1): 85–102.
10. Deloitte Consulting: The Deloitte Automotive Value Chain Industry Model <https://www2.deloitte.com/content/dam/Deloitte/us/Documents/consumer-business/us-cb-future-of-the-automotive-supplier-industry-outlook.pdf>. 12/2017
11. Du F.: A bi-objective reverse logistics network analysis for post-sale service *Computers & Operations Research*. Volume 35, Issue 8, August 2008, Pages 2617-2634
12. Frazzon E. M. et al.: Spare parts supply chains' operational planning using technical condition information from intelligent maintenance systems *Annual Reviews in Control*, 2014
13. De Souza V, Borsato M, Bloemhof-Ruwaard J. Designing eco-effective reverse logistics networks. *Transdisciplinary Engineering: Crossing Boundaries* 2016; 4: 851-860.
14. Freiheit J E. A continuous review model for the reparable item inventory system. The NPS Institutional Archive. Thesis. California. U.S, 1967.

15. Ginter P M, Starling J. Reverse distribution channels for recycling. *California Management Review* 1978; 20(3):72–81.
16. Goldberg D E. Algorytmy genetyczne i ich zastosowanie, Wydawnictwo Naukowe – Techniczne Warszawa 1995.
17. He W.: An Inventory Controlled Supply Chain Model Based on Improved BP Neural Network. *Discrete Dynamics in Supply Chain Management*, Vol. 5, 2013: 1-7
18. Heckmann I.: *Towards Supply Chain Risk Analytics: Fundamentals, Simulation Optimization*, Springer, 2016
19. Herbert-Hansen Z N L, Larsen S, Nielsen A, Groth A, Gregersen N G, Ghosh A. Combining or Separating Forward and Reverse Logistics. *International Journal of Logistics Management* 2018; 29(1): 216-236.
20. Ho C. et al.: Measuring system performance of an ERP-based supply chain. *International Journal of Production research*, 2006, Vol. 45 (6): 1255-1277
21. Huiskonen J.: Maintenance spare parts logistics: special characteristics and strategic choices. *International Journal of Production Economics* 71(1-3) February 2001:125-133
22. <http://motoraporter.com/2015/07/Z-historii-zycia-statystycznego-samochodu-Ekspert-motoryzacyjny-Motoraporter-radzi> [dostęp 15.04.2020]
23. Islam M T, Huda N. Reverse logistics and closed-loop supply chain of Waste Electrical and Electronic Equipment (WEEE)/E-waste: A comprehensive literature review. *Resources, Conservation and Recycling* 2018; 137: 48-75.
24. Ilgın M. A: A spare parts criticality evaluation method based on fuzzy AHP and Taguchi loss functions. *Eksploatacja i Niezawodność - Maintenance and Reliability* 2019; 21(1): 145-152
25. Izdebski M, Jacyna-Golda I, Jakowlewa I. Planning international transport using the heuristic algorithm. In: *Integration as Solution for Advanced Smart Urban Transport Systems. Advances in Intelligent Systems and Computing* 2018; 844: 229-241.
26. Izdebski M, Jacyna-Golda I, Markowska K, Murawski J. Heuristic algorithms applied to the problems of servicing actors in supply chains. *Archives of Transport* 2017; 44(4): 25-34.
27. Jaaron A, Backhouse C. A systems approach for forward and reverse logistics design: Maximising value from customer involvement. *International Journal of Logistics Management* 2016; 27(3): 947 – 971.
28. Jacyna M, Izdebski M, Szczepański E, Gołda P. The task assignment of vehicles for a production company. *Symmetry* 2018; 11(10): 1-19.
29. Jacyna M, Wasiak M. Multicriteria decision support in designing transport systems. *Communications in Computer and Information Science* 2015; 531: 11-23.
30. Jacyna-Golda I, Lewczuk K. The method of estimating dependability of supply chain elements on the base of technical and organizational redundancy of process. *Eksploatacja i Niezawodność – Maintenance and Reliability* 2017; 19(3): 382-392.
31. Jacyna-Golda I, Izdebski M, Szczepański E, Gołda P., 2018. The assessment of supply chain effectiveness. *Archives of Transport*, 45(1), 43-52
32. Jacyna-Golda I, Izdebski M, Podvieszko A. Assessment of efficiency of assignment of vehicles to tasks in supply chains. A case study of a municipal company. *Transport* 2017; 32(3): 243-251.
33. Kochak A.: Demand forecasting using neural network for supply chain management. *International Journal of Mechanical Engineering & Robotics Research*, 2015, 4(1): 96-104.

34. Landes X, Néron P. Morality and Market Failures: Asymmetry of Information. *Journal of Social Philosophy* 2018; 49(4): 564–588.
35. Lee H L. Aligning Supply Chain Strategies with Product Uncertainties. *California Management Review* 2002; 44(3): 105-119.
36. Li J Q, Wang J D, Pan Q K, Duan P Y, Sang H Y, Gao K Z, Xue Y. A hybrid artificial bee colony for optimizing a reverse logistics network system. *Soft Computing* 2017; 21(20): 6001-6018.
37. Li SG, et al.: The inventory management system for automobile spare parts in a central warehouse. *Expert Systems with Applications: An International Journal*, 2008; 34:1144-53
38. Luksch, S.: After sales supply chain risk management, University of Louisville. 2014, (5), p.137.
39. Lutrowicz K. Największy taki dystrybutor w Polsce, *TSL biznes* 2015; 3: 20-21.
40. Merkisz J, Jacyna M, Merkisz-Guranowska A, Pielecha J. Exhaust emissions from modes of transport under actual traffic conditions. *WIT Transactions on Ecology and the Environment* 2014; 190: 1139-1150.
41. Murphy P R, Poist R F. Management of logistical retro movements: an empirical analysis of literature suggestions. *Transportations Research Forum* 1988; 29: 177-184.
42. Nagel C, Meyer P. Caught between ecology and economy: end-of-life aspects of environmentally conscious manufacturing. *Computers & Industrial Engineering* 1999; 36(4): 781– 792.
43. Pyza D, Gołda P. Transport cargo handling shipments in air transport in the aspect of supply chains . *Proceedings - ICSEng 2011: International Conference on Systems Engineering*, 2011.
44. Pyza D, Jacyna-Gołda I, Gołda P, Gołębiowski P. Alternative fuels and their impact on reducing pollution of the natural environment. *Rocznik Ochrona Środowiska* 2018; 20: 819-836.
45. Quarterly report by PZPM and KPMG in Poland. Q4/2019.
46. Rudyk T, Szczepański E, Jacyna M. Safety factor in the sustainable fleet management model. *Archives of Transport* 2019; 49(1): 103-114.
47. Saidani M, Kendall A, Yannou B, Leroy Y, Cluzel F. Management of the end-of-life of light and heavy vehicles in the U.S.: comparison with the European union in a circular economy perspective, *Journal of Material Cycles and Waste Management*, Springer Verlag (Germany), 2019.
48. Schrady D A. A deterministic inventory model for repairable items. *Naval Research Logistics* 1967, 14: 391- 398.
49. Sendek-Matysiak E, Pyza D. The assignment of vehicle assessment based on multi criteria decision making. *Archives of Transport* 2018; 48(4): 77-85.
50. Świdorski A. Studies and quality assurance neural modelling of the technical transport means. *Archives of Transport* 2009; 21(3) 177-188.
51. Wasiak M, Jacyna-Gołda I, Markowska K, Jachimowski R, Kłodawski M, Izdebski M. The use of a supply chain configuration model to assess the reliability of logistics processes. *Eksploatacja i Niezawodność – Maintenance and Reliability* 2019; 21(3): 367–374.
52. Wasiak M, Jacyna M. Model of transport costs in the function of the road vehicles structure. *Transport Means - Proceedings of the International Conference*, Lithuania, 2015.
53. Wagner S. M., Jönke R., Eisingerich A. B.: A Strategic Framework for Spare Parts Logistics *California Management Review* Vol. 54, No. 4 Summer 2012, p. 69-92

54. Wang C., Xu J., Wang H., Zhang Z.: A criticality importance-based spare ordering policy for multi-component degraded systems, *Eksploracja i Niezawodność - Maintenance and Reliability*, 2018; 20(4): 662-670.
55. Wu T. et.al: A model for inbound supply risk analysis, *Computers in Industry* 57 (2006): 350–365