

**POLITECHNIKA POZNAŃSKA**  
**Wydział Inżynierii Środowiska i Energetyki**  
**Instytut Energetyki Ciepłej**

**MODEL WSPOMAGANIA PROCESU DECYZYJNEGO NA  
POTRZEBY ZAPEWNIENIA ENERGII DLA SIŁ ZBROJNYCH  
NA PODSTAWIE ZARZĄDZANIA PALIWEM**

**Autoreferat rozprawy doktorskiej**



**mgr inż. Artur Kępczyński**

Promotor: prof. dr hab. inż. Andrzej Frąckowiak  
Promotor pomocniczy: dr inż. Dariusz Łukowski

Poznań 2026



## 1. SPIS TREŚCI

<b>1. Spis treści.....</b>	<b>3</b>
<b>2. Wykaz skrótów i oznaczeń.....</b>	<b>5</b>
<b>3. Dane osobowe .....</b>	<b>6</b>
3.1 Imię i nazwisko .....	6
3.2 Aktualne miejsce zatrudnienia .....	6
3.3 Obszar zainteresowań naukowych .....	6
<b>4. POSIADANE DYPLOMY, TYTUŁY ZAWODOWE, ODBYTE SZKOLENIA .....</b>	<b>7</b>
4.1 Posiadane dyplomy oraz tytuły zawodowe .....	7
4.2 Odbyte szkolenia.....	7
<b>5. Informacje o dotychczasowym zatrudnieniu .....</b>	<b>8</b>
<b>6. Wskazanie osiągnięć naukowych wchodzących w skład dysertacji.....</b>	<b>10</b>
6.1 Tytuł rozprawy doktorskiej.....	10
6.2 Zestawienie prac naukowych stanowiących podstawę rozprawy doktorskiej .....	10
6.3 Mapowanie publikacji na cele, wyniki i rozdziały rozprawy doktorskiej.....	11
<b>7. Streszczenie w języku polskim oraz w języku angielskim .....</b>	<b>13</b>
7.1 Streszczenie (PL) .....	13
7.2 Abstract (EN) .....	14
<b>8. Uzasadnienie podjętej tematyki oraz wprowadzenie .....</b>	<b>16</b>
8.1 Wizja docelowa: systemowe wspomaganie decyzji w logistyce SZ RP.....	16
<b>9. Określenie problemu badawczego, tezy oraz zadań badawczych.....</b>	<b>20</b>
9.1 Problem badawczy .....	20
9.2 Teza badawcza .....	20
9.3 Zadania badawcze .....	21
<b>10. Metody badawcze wykorzystane do realizacji rozprawy doktorskiej.....</b>	<b>22</b>
10.1 Przygotowanie danych i reżim walidacji predykcji .....	23
<b>11. Obiekty badawcze oraz program realizacji badań.....</b>	<b>26</b>
11.1 Obiekt badawczy i krok czasowy.....	26
11.2 Struktura danych i zmienne wejściowe.....	27
11.3 Program realizacji badań – przebieg.....	28
<b>12. Wyniki badań (na podstawie publikacji).....</b>	<b>30</b>
12.1 Porównanie algorytmów uczenia MLP i dobór konfiguracji referencyjnej.....	30
12.2 Modele wielokryterialne i rola informacji w procesie decyzyjnym.....	32
<b>13. Badania i wyniki implementacyjne prototypu LSWD/LDSS (wyniki niepublikowane)</b> .....	<b>34</b>
13.1 Założenia funkcjonalne i użytkowe prototypu.....	34
13.2 Parametry wprowadzane w GUI .....	34
13.3 Logika trzech wariantów działania i rozróżnialność scenariuszy .....	35
13.4 Alerty MIN/MAX i rekomendacje.....	36
13.5 Zapis iteracji i raportowanie: audytowalność decyzji.....	37
13.6 Walidacja funkcjonalna i testy scenariuszowe.....	37
13.7 Ograniczenia prototypu i ryzyka wdrożeniowe .....	43
<b>14. Wkład własny i elementy nowości.....</b>	<b>45</b>

<b>15. Wnioski i kierunki dalszych badań .....</b>	<b>46</b>
<b>16. WYKAZ PUBLIKACJI STANOWIĄCA PODSTAWĘ ROZPRAWY DOKTORSKIEJ .....</b>	<b>47</b>
<b>17. Literatura.....</b>	<b>48</b>
<b>18. Wykaz dorobku naukowego, organizacyjnego i innych osiągnięć .....</b>	<b>54</b>
<b>19. Publikacje stanowią podstawę merytoryczną rozprawy doktorskiej.....</b>	<b>56</b>

## 2. WYKAZ SKRÓTÓW I OZNACZEŃ

AI – sztuczna inteligencja (*Artificial Intelligence*)  
BR – regularyzacja bayesowska (*Bayesian Regularisation*)  
BFGS – algorytm quasi-Newtona Broydena–Fletcher–Goldfarba–Shanno  
GUI – graficzny interfejs użytkownika  
LM – algorytm Levenberga–Marquardta  
LSWD – Logistyczny System Wspomagania Decyzji (j.ang. *Logistic Decision Support System*, LDSS)  
MSE – błąd średniokwadratowy (Mean Squared Error)  
MLP – perceptron wielowarstwowy (Multilayer Perceptron)  
MU – jednostka wojskowa (*Military Unit*)  
NOG – nadrzędny oddział gospodarczy  
OG – oddział gospodarczy  
R/R<sup>2</sup> – parametry oceny regresji: współczynniki korelacji / dopasowania  
RBlog – regionalna baza logistyczna  
RL – uczenie ze wzmocnieniem (*Reinforcement Learning*)  
RMSE – pierwiastek z MSE (*Root Mean Squared Error*)  
RP – resilient backpropagation  
SI LBPP – system informatyczny planowania potrzeb (zestawienie potrzeb/limitów)  
WMPD – wielokryterialny model procesu decyzyjnego  
ZWSI RON – Zintegrowany Wieloszczeblowy System Informatyczny Resortu Obrony Narodowej

### **3. DANE OSOBOWE**

#### **3.1 Imię i nazwisko**

Artur Kępczyński

#### **3.2 Aktualne miejsce zatrudnienia**

Ministerstwo Obrony Narodowej / Departament Wojskowych Spraw Zagranicznych – zgodnie ze stanem na dzień sporządzenia autoreferatu.

#### **3.3 Obszar zainteresowań naukowych**

Zainteresowania naukowe autora koncentrują się na logistyce wojskowej, w szczególności na logistyce energii (paliwa) oraz na metodach wspomagania decyzji w warunkach niepewności i dynamicznie zmieniającego się środowiska operacyjnego. Autor ponadto działa w dziedzinie bezpieczeństwa energetycznego Sił Zbrojnych. Obejmują one:

- sposoby zapewnienia ciągłości zasilania jednostek i instytucji Sił Zbrojnych w energię oraz metody jej alternatywnego pozyskiwania (*energy harvesting*),
- sieci paliwowe/energetyczne rozproszone,
- predykcję zużycia energii przez systemy wojskowe,
- autonomiczne systemy logistyczne,
- modelowanie procesów decyzyjnych w systemach logistycznych,
- zastosowanie sztucznej inteligencji i uczenia maszynowego w logistyce wojskowej,
- prognozowanie stanów zapasów i analizę scenariuszową („*what-if*”) w gospodarce paliwowej,
- projektowanie modułowych systemów teleinformatycznych wspierających dowodzenie i zarządzanie logistyką,
- metody oceny ryzyka i odporności systemów logistycznych;
- bezpieczeństwo systemów logistycznych,
- strategię zarządzania procesami zabezpieczenia sił zbrojnych,
- planowanie wykorzystania zasobów logistycznych w operacji militarnej.

## **4. POSIADANE DYPLOMY, TYTUŁY ZAWODOWE, ODBYTE SZKOLENIA**

### **4.1 Posiadane dyplomy oraz tytuły zawodowe**

#### **1990 – inżynier - dowódca**

Wyższa Oficerska Szkoła Samochodowa

Specjalność: Eksploatacja i naprawa pojazdów mechanicznych,

Tytuł pracy dyplomowej: *Zabezpieczenie inżynieryjno-techniczne wojsk podczas pokonywania szerokich przeszkód wodnych.*

Promotor: płk mgr inż. Ryszard Dragańczuk

#### **1992 – magister inżynier mechanik**

Wojskowa Akademia Techniczna, Wydział Mechaniczny,

Kierunek: pojazdy mechaniczne,

Tytuł pracy dyplomowej: *Analiza automatycznych systemów sterowania silników wysokoprężnych dużej mocy.*

Promotor: płk dr inż. Stanisław Ochwat

### **4.2 Odbyte szkolenia**

#### **Studia podyplomowe:**

2019 – Akademia Sztuki Wojennej w Warszawie – Podyplomowe Studia Polityki Obronnej.

2009 – Uniwersytet im. Kazimierza Wielkiego w Bydgoszczy – studia podyplomowe w zakresie ochrony ludności i zarządzania kryzysowego.

#### **Kursy:**

1999 – Akademia Obrony Narodowej w Warszawie- kurs taktyczno-operacyjny integracji z NATO.

2000 – NATO/PfP Staff Officers Course, szkoła SWEDINT (Szwecja) oraz centrum szkolenia językowego DSL w Londynie (Wielka Brytania),

2001 - 2002 - kursy w NATO School Oberammergau (Niemcy):

- NATO Orientation Course;
- MJLC Course;
- The NATO Logistic Course.

2002 – Kurs Logistyczny NATO w Technische Schule des Heeres w Aachen (Niemcy),

2007 – kurs specjalistyczny – Akademia Obrony Narodowej - Planowanie i realizacja funkcji państwa – gospodarza oraz państwa wysyłającego.

## **5. INFORMACJE O DOTYCHCZASOWYM ZATRUDNIENIU**

Autor ukończył Wyższą Oficerską Szkołę Samochodową w Pile w 1990 r. z tytułem inżynier – dowódca. W 1992 r. uzyskał tytuł magistra inżyniera mechanika na Wojskowej Akademii Technicznej w Warszawie. Następnie służbę wojskową pełnił w 8 Ośrodku Szkolenia Specjalistów Czołgowych w Chełmnie na różnych stanowiskach dowódczych i dydaktycznych (ostatnie to starszy wykładowca) do 2001 r. W latach 1997-1998 r. pełnił służbę w PKW UNIFIL Liban na stanowisku dowódczym w batalionie logistycznym (POLLOG). W latach 2001-2004 zajmował stanowisko starszego oficera w Połączonym Dowództwie NATO w Heidelbergu. W ramach zajmowanego tam stanowiska w 2003 r. służył w Regionalnym Dowództwie NATO w Neapolu (AFSOUTH, Włochy) z zadaniem koordynacji zabezpieczenia logistycznego operacji NATO na Bałkanach w Regionalnym Centrum Operacyjnym (ROC AFSOUTH). Po powrocie do kraju w 2004 roku został skierowany do służby w Dowództwie Wojsk Lądowych na stanowisku starszego specjalisty Oddziału HNS. W 2007 r. został służbowo przniesiony do Inspektoratu Wsparcia Sił Zbrojnych w Bydgoszczy na stanowisko szefa wydziału HNS. W latach 2008-2009 pełnił służbę w J4 Dowództwa Operacji Unii Europejskiej EUFOR Tchad/RCA. Z dniem 17.08.2009 r. został wyznaczony na stanowisko szefa Oddziału Zabezpieczenia Funkcji Państwa Gospodarza w Dowództwie Pomorskiego Okręgu Wojskowego w Bydgoszczy. W 2011 roku został przeniesiony służbowo do Inspektoratu Wsparcia Sił Zbrojnych na stanowisko szefa Oddziału Interoperacyjności Logistycznej i HNS. W 2015 roku objął stanowisko Zastępcy Szefa Logistyki IWsp SZ. W 2018 roku czasowo pełnił obowiązki Zastępcy Szefa Inspektoratu Wsparcia SZ – Szefa Logistyki. W roku 2020 brał udział w pracach zespołu negocjacyjnego w zakresie umowy o wzmocnionej współpracy obronnej Polski i USA. Od 01.04.2021 r. pełnił czasowo, a od 27.11.2021 r. etatowo obowiązki na stanowisku szefa IWspSZ. Z dniem 09.01.2025 r. został przeniesiony do dyspozycji Dowódcy Generalnego RSZ, a od września 2025 r. w ramach przygotowań do objęcia stanowiska poza granicami kraju, do Departamentu Wojskowych Spraw Zagranicznych MON. Decyzją MON z dniem 16.03.2026 r. został wyznaczony na stanowisko Attachée Obrony w Chinach.

W trakcie służby na różnych stanowiskach służbowych czynnie podejmował szereg aktywności w wojskowym, logistycznym środowisku międzynarodowym między innymi w ramach FINABEL-WG Logistics, SWG LOG-MED przy Komitecie WKPW oraz NTCC. W procesie formowania IWspSZ organizował od podstaw system realizacji zadań HNS na poziomie wykonawczym, a w latach 2011-2014 odpowiadał w IWspSZ za koordynację wdrażania terytorialnego systemu zabezpieczenia logistycznego SZ RP opartego na WOG. W 2020 r. uczestniczył w pracach zespołu negocjacyjnego umowy o wzmocnionej współpracy obronnej Polski i USA. Będąc na stanowisku szefa IWspSZ inicjował i rozwijał współpracę z wojskowym i cywilnym środowiskiem naukowym w obszarach związanych z szeroko rozumianym bezpieczeństwem narodowym. W ramach tej działalności nawiązana została oficjalna współpraca m.in. z Wojskową Akademią Techniczną i Politechniką Poznańską, której efektem była współorganizacja szeregu wspólnych przedsięwzięć o charakterze naukowym i dydaktycznym, takich jak: konferencje i seminaria naukowe, szkolenia oraz projekty na rzecz bezpieczeństwa i obronności.

## **6. WSKAZANIE OSIĄGNIĘĆ NAUKOWYCH WCHO- DZĄCYCH W SKŁAD DYSERTACJI**

### **6.1 Tytuł rozprawy doktorskiej**

Tytułem rozprawy doktorskiej jest:

**Model wspomaganie procesu decyzyjnego na potrzeby zapewnienia energii  
dla sił zbrojnych na podstawie zarządzania paliwem.**

### **6.2 Zestawienie prac naukowych stanowiących podstawę rozprawy doktorskiej**

Poniższe publikacje stanowią podstawę merytoryczną rozprawy doktorskiej:

- [1]. Kępczyński A., Application of machine learning in the process of commander decision support in the military fuel distribution system, Archives of Thermodynamics, Vol. 46(2025), No. 4, 201–214; doi: 10.24425/ather.2025.156850
  - [2]. Kępczyński A., Model wspomaganie procesu decyzyjnego na potrzeby zapewnienia energii dla Sił Zbrojnych. Zarządzanie zasobami paliw w SZ, Warszawa: Wydawnictwo ITWL 2024, rozdział w monografii
  - [3]. Prokopowicz W., Kępczyński A., Zastosowanie sieci neuronowych do modelowania procesów decyzyjnych w wojskowym systemie dystrybucji paliw, Warszawa: Wydawnictwo ITWL, 2024, rozdział w monografii
  - [4]. Łukowski D., Kępczyński A., Transformacja energetyczna – wyzwania dla sił zbrojnych, Warszawa: Wydawnictwo ITWL, 2024, rozdział w monografii
  - [5]. Kępczyński A., Stępień S., Optymalizacja i wspomaganie AI w logistyce wojskowej, Warszawa: Wydawnictwo ITWL, 2024,
  - [6]. Kępczyński A., Lisowski G., Prokopowicz W., Stępień S., Metody adaptacyjne w logistyce energii wojsk. Zmiany w procesie kształcenia specjalistów służby czołgowo-samochodowej oraz wybrane zagadnienia dotyczące służby pp, 20-28. Warszawa: Wydawnictwo AWiR AKCES SUKCES-SPORT 2023
- [2,3,4,5] Monografia: Perspektywy logistyki wojskowej i cywilnej w kontekście zapewnienia odporności Siłom Zbrojnym (konferencja Bydgoszcz) 2024, Tom 1.

### 6.3 Mapowanie publikacji na cele, wyniki i rozdziały rozprawy doktorskiej

W celu zapewnienia przejrzystości autoreferatu oraz jednoznacznego powiązania dorobku publikacyjnego z elementami rozprawy, poniżej zestawiono publikacje stanowiące podstawę dysertacji z odpowiadającymi im rezultatami badawczymi. Informacje zawarte w tabeli 1. mają za zadanie ułatwić zarówno ocenę wkładu autora, jak i weryfikację spójności wywodu naukowego rozpoczynając od uzasadnienia problemu, poprzez omówienie metod, kończąc na implementacji prototypu LSWD.

W publikacji [2] przedstawiono docelową architekturę i filozofię wdrażania AI jako elementu systemowego zarządzania zasilaniem w energię z paliw płynnych w logistyce SZ na wszystkich poziomach. Z tego względu praca [2] stanowi oś koncepcyjną, względem której pozostałe prace oraz niniejsze badania (studium przypadku paliwa/energii w OG) są pozycjonowane jako kolejne kroki w kierunku konkretnych rozwiązań, które można wykorzystać w codziennej pracy w postaci modułów predykcyjno-decyzyjnych możliwych do integracji z ZWSI RON.

Tabela 1. Zestawienie publikacji z uwzględnieniem ich roli w dysertacji

Publikacja	Zakres merytoryczny	Rezultat / wkład do dysertacji
[1]	Uczenie maszynowe w systemie dystrybucji paliw; porównanie algorytmów uczenia MLP; koncepcja LDSS/LSWD.	Dobór i empiryczne uzasadnienie konfiguracji MLP+BR jako rozwiązania referencyjnego; zestaw miar jakości (R, RMSE, MSE) oraz ramy predykcji krótkoterminowej.
[2]	Model wspomagania procesu decyzyjnego zapewnienia energii dla SZ; organizacja procesu i znaczenie danych.	Uzasadnienie metodyczne LSWD jako systemu wspomagania decyzji oraz identyfikacja barier danych/procesu (czas przygotowania danych, rozproszenie źródeł).
[3]	Modelowanie procesów decyzyjnych w wojskowym systemie dystrybucji paliw; WMPD; czasoprzestrzeń logistyczna.	Operacjonalizacja problemu decyzyjnego (kroki procesu), zmienne decyzyjne i brzegowe (MIN/MAX), concept wariantowania i kierunki rozwoju (np. aktor-krytyk).
[4]	Transformacja energetyczna i jej implikacje dla SZ;	Uzupełniający kontekst strategiczny: rosnące zapotrzebowanie na energię

Model wspomagania procesu decyzyjnego na potrzeby zapewnienia energii dla Sił  
Zbrojnych na podstawie zarządzania paliwem

---

	interoperacyjność, łańcuchy dostaw, ograniczenia technologiczne.	i trwała rola paliw płynnych (perspektywa łańcucha dostaw i ryzyk).
[5]	AI w logistyce wojskowej: optymalizacja, wspomaganie, metody oceny ryzyka i odporności.	Poszerzenie kontekstu zastosowań AI w logistyce; przesłanki dla integracji prognozy z rekomendacjami i audytem decyzyjnym.
[6]	Metody adaptacyjne w logistyce energii wojsk; podejście systemowe i zdecentralizowane.	Uzasadnienie potrzeby adaptacyjności i odporności LSWD; wskazanie na możliwość integracji z rozwiązaniami sieciowymi i wieloszczeblowymi.

## 7. STRESZCZENIE W JEZYKU POLSKIM ORAZ W JEZYKU ANGIELSKIM

### 7.1 Streszczenie (PL)

Utylitarny charakter rozprawy polega na opracowaniu logistycznego systemu wspomagania decyzji, LSW (j. ang. *Logistic Decision Support System*, LDSS) przeznaczanego do wsparcia procesu planowania i kontroli gospodarki paliwowej w Siłach Zbrojnych RP. Prowadzone w pracy badania dotyczą analiz funkcjonowania oddziału gospodarczego (OG) jako podstawowego węzła zasilnia w energię paliw płynnych oraz obrotu ewidencyjno-magazynowego i dystrybucji zasobów, który jest odpowiedzialny za utrzymanie poziomu zapasów paliwa w nakazanym przedziale (MIN/MAX). W warunkach wysokiej zmienności popytu, ograniczeń infrastrukturalnych oraz presji czasowej, decyzje dowódców i służb logistycznych wymagają wsparcia w postaci narzędzi umożliwiających prognozowanie i szybką ocenę wariantów działania.

Celem rozprawy jest zaprojektowanie i zweryfikowanie rozwiązania, które łączy model predykcyjny oparty o sieci neuronowe z logiką wariantowania decyzji z uwzględnieniem stanów alarmowych, co do ryzyka naruszeń poziomów MIN/MAX. W części badawczej przeprowadzono porównanie perceptronu wielowarstwowego (MLP) uczonego czterema algorytmami (BFGS, regularyzacja bayesowska BR, Levenberg–Marquardt LM oraz resilient backpropagation RP) dla trzech rozmiarów warstwy ukrytej (10, 20 i 50 neuronów). Jakość algorytmów oceniono z zastosowaniem analiz opartych o parametry regresji (współczynniki korelacji i dopasowania), pierwiastek z MSE (Root Mean Squared Error) i błąd średniokwadratowy (Mean Squared Error).

Na bazie najlepiej ocenionej konfiguracji (MLP-BR) opracowano prototyp LSWD w środowisku MATLAB, zintegrowany z arkuszem Excel jako warstwę danych. Prototyp udostępnia decydentowi interfejs użytkownika (w oparciu o interfejs graficzny GUI systemu MATLAB), w którym wprowadza on parametry sytuacyjne i zasobowe (m.in. intensywność działań, dostępność personelu, sprawność sprzętu, czynniki środowiskowe) oraz parametry obciążenia popytowego (liczba jednostek i priorytety). System generuje prognozę stanu paliwa w horyzoncie

wielotygodniowym oraz trzy warianty działania: optymistyczny, optymalny i pesymistyczny, wskazując tygodnie ryzyka oraz alerty MIN/MAX.

Rezultatem rozprawy jest metodycznie uporządkowany model wspomagania decyzji w gospodarce paliwowej OG oraz opracowanie prototypu narzędzia, które może stanowić podstawę do dalszej integracji z systemami teleinformatycznymi logistyki wojskowej. W kolejnym etapie może być rozbudowywany o mechanizmy optymalizacji wielokryterialnej oraz uczenia ze wzmocnieniem. Celem utylitarnym rozprawy jest zapewnienie odporności energetycznej w obszarze dystrybucji paliwa OG na rzecz działających wojsk.

W ujęciu systemowym rozprawa wpisuje się w wizję przedstawioną w publikacji autora [2], zgodnie z którą zarządzanie logistyką Sił Zbrojnych RP powinno w ramach wsparcia procesu decyzyjnego docelowo wykorzystywać AI jako warstwę analityczno-decyzyjną nad zintegrowanymi danymi logistycznymi. Podstawą realizacji tej wizji stanowi baza danych i procesy ewidencyjne w oparciu o ZWSI RON, umożliwiające skalowanie podejścia z poziomu OG na kolejne poziomy zarządzania i inne obszary funkcjonalne logistyki wojskowej (energia, amunicja, części zamienne, transport).

**Słowa kluczowe:** logistyka wojskowa, gospodarka paliwowa, system wspomagania decyzji, predykcja, sieci neuronowe, regularyzacja bayesowska, analiza scenariuszowa.

## 7.2 Abstract (EN)

The utilitarian character of the dissertation consists in developing a logistics decision support system (LSWD; Logistic Decision Support System—LDSS) intended to support the planning and control of fuel management in the Polish Armed Forces. The research conducted in the dissertation concerns analyses of the functioning of the economic branch (OG) as the primary node for supplying energy in the form of liquid fuels, as well as for inventory accounting, storage, and resource distribution, which is responsible for maintaining fuel stock levels within the mandated range (MIN/MAX). Under conditions of high demand volatility, infrastructure constraints, and time pressure, commanders' and logistics services' decisions require support in the form of tools enabling forecasting and rapid assessment of action variants.

The aim of the dissertation is to design and verify a solution that combines a neural-network-based predictive model with decision-variant logic, taking into account alarm states regarding the risk of MIN/MAX threshold violations. In the research part, a comparison was carried out of a multilayer perceptron (MLP) trained with four algorithms (BFGS, Bayesian regularization—BR, Levenberg—Marquardt—LM, and resilient backpropagation—RP) for three hidden-layer sizes (10, 20, and 50 neurons). The quality of the algorithms was assessed using analyses based on the following measures: regression / goodness-of-fit, root mean squared error (RMSE), and mean squared error (MSE).

On the basis of the highest-rated configuration (MLP—BR), a prototype of LSWD was developed in the MATLAB environment and integrated with an Excel spreadsheet as the data layer. The prototype provides the decision-maker with a user interface (based on the MATLAB GUI) in which they enter situational and resource parameters (e.g., intensity of activities, personnel availability, equipment serviceability, environmental factors) as well as demand-load parameters (number of units and priorities). The system generates a fuel stock forecast over a multi-week horizon and three action variants—optimistic, optimal, and pessimistic—indicating risk weeks and MIN/MAX alerts.

The result of the dissertation is a methodically structured decision-support model for OG fuel management and a prototype tool that may form the basis for further integration with military logistics ICT systems and, at a later stage, for expansion with multi-criteria optimization mechanisms and reinforcement learning. The utilitarian objective of the dissertation is to ensure energy resilience in OG fuel distribution for operating forces.

From a systems perspective, the dissertation fits into the vision presented in the author's publication [2], according to which the management of Armed Forces logistics should ultimately use AI as an analytical—decision layer over integrated logistics data. The basis for implementing this vision is a database and recording processes based on ZWSI RON, enabling the approach to be scaled from the OG level to subsequent management levels and to other areas of logistics (energy, ammunition, spare parts, transport).

**Keywords:** military logistics; fuel management; decision support system; forecasting; neural networks; Bayesian regularization; scenario analysis.

## **8. UZASADNIENIE PODJĘTEJ TEMATYKI ORAZ WPROWADZENIE**

Zapewnienie bezpieczeństwa energetycznego wojsk – w szczególności w postaci paliwa płynnego – jest warunkiem koniecznym do utrzymania zdolności operacyjnych w czasie pokoju, kryzysu i wojny [4]. Z punktu widzenia dowodzenia oznacza to potrzebę utrzymania zdolności do ciągłego zasilania pododdziałów i jednostek w paliwo w warunkach zmiennego popytu, ograniczeń infrastrukturalnych i zdolności transportowych oraz presji czasowej. Paliwo stanowi zasób krytyczny, gdyż jego niedobór ogranicza mobilność i gotowość bojową, a nadmiar – w warunkach ograniczonych pojemności magazynowych – generuje ryzyko związane z procedurami, logistyką oraz bezpieczeństwem.

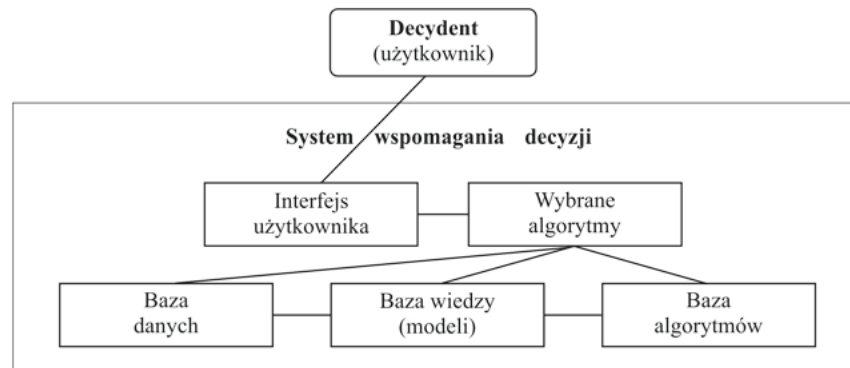
Współczesne środowisko operacyjne charakteryzuje się rozproszeniem działań, intensyfikacją wymiany informacji i rosnącą liczbą ograniczeń (proceduralnych, infrastrukturalnych oraz zasobowych). W logistyce energii wyraźnie wzrasta znaczenie szybkości analizy danych i zdolności do przewidywania stanów krytycznych (niedoboru lub nadmiaru zapasu). W praktyce oddział gospodarczy odpowiada jednocześnie za utrzymanie rezerw, za obsługę wydawania paliwa, planowanie uzupełnień oraz za raportowanie stanu.

Biorąc powyższe pod uwagę, zapewnienie powyższych wymagań można osiągnąć poprzez automatyzację wsparcia procesów decyzyjnych. Opracowanie środowiska programistycznego na potrzeby wzmocnienia procesów decyzyjnych na poszczególnych poziomach zabezpieczania logistycznego Sił Zbrojnych RP pozwoli na reagowanie w czasie rzeczywistym (*on-line*) na zmieniającą się sytuację operacyjną w obszarze odpowiedzialności elementów systemu logistycznego. Gromadzone i aktualizowane na bieżąco dane (ZWSI RON), parametry środowiska naturalnego oraz wskaźniki operacyjne pozwolą na zaimplementowanie algorytmów uczenia maszynowego do istniejących systemów informatycznych resortu obrony narodowej.

### **8.1 Wizja docelowa: systemowe wspomaganie decyzji w logistyce SZ RP**

Kluczowa wizja, do której odnosi się niniejsza rozprawa, została sformułowana w publikacji [2] i dotyczy budowy wieloszczeblowego systemu wspomagania decyzji w logistyce Sił Zbrojnych RP, w którym sztuczna inteligencja (AI) stanowi rdzeń

analityczny wspierający planowanie, realizację i kontrolę działań logistycznych zarówno w czasie pokoju, kryzysu, jak i wojny. Ogólne założenia systemu wspomaganie decyzji przedstawiono na rysunku 1, gdzie interfejs użytkownika to moduł Graphical User Interface (GUI) o nazwie Logistic Data Supply System (LDSS).




Rysunek 1. Ogólny schemat systemu wspomaganie decyzji wg A.P. Wierzbickiego (publikacja [2], Rys. 2).

W ujęciu docelowym nie chodzi o pojedynczy moduł predykcyjny, lecz o spójny ekosystem narzędzi decyzyjnych, działających w jednym środowisku informacyjnym i obsługujących wszystkie obszary logistyki (m.in. paliwo/energia, amunicja, części zamienne, środki medyczne, transport, infrastruktura, usługi). Warunkiem koniecznym takiego podejścia jest istnienie i ciągły rozwój zintegrowanej bazy danych logistycznych oraz mechanizmów wymiany informacji [2]. W realiach SZ RP fundamentem tego rozwiązania jest baza danych i procesy ewidencyjno-sprawozdawcze rozwijane w oparciu o ZWSI RON. Algorytmy AI mogą w tym kontekście pełnić rolę „warstwy inteligentnej” nad istniejącą infrastrukturą danych: automatyzować ocenę sytuacji logistycznej, wykrywać ryzyka (np. zagrożenia ciągłości dostaw), generować warianty działania (3W), wspierać alokację zasobów i priorytetyzację obsługi oraz zapewniać audytowalność podejmowanych przez decydenta decyzji.

Niniejsze badania – skoncentrowane na gospodarce paliwowej w oddziale gospodarczym (OG) – traktowane są jako studium przypadku i poligon metodyczny dla szerszej koncepcji zawartej w publikacji [2]. Na rysunku 2 przedstawiono schemat koncepcyjny procesu decyzyjnego w zakresie dystrybucji paliw na poszczególnych poziomach zabezpieczenia logistycznego SZ RP.

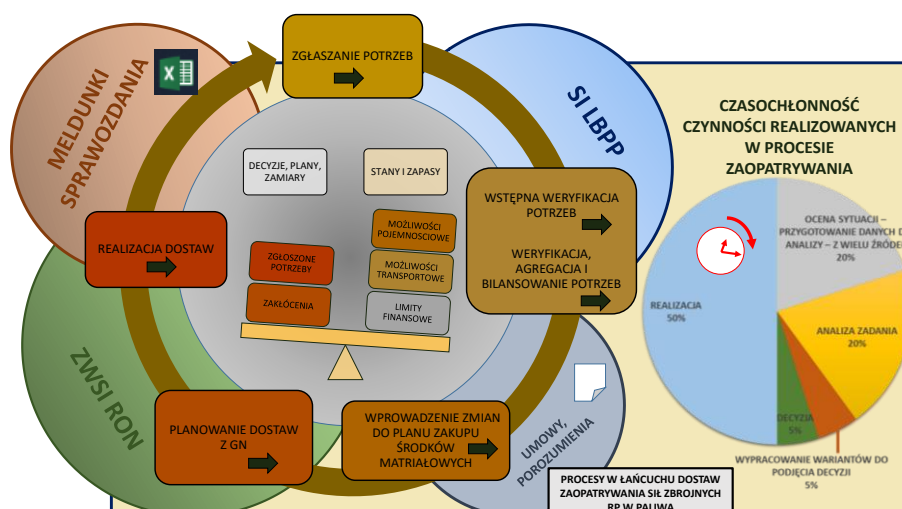
## Model wspomagania procesu decyzyjnego na potrzeby zapewnienia energii dla Sił Zbrojnych na podstawie zarządzania paliwem



Rysunek 2. Schemat systemu logistyki paliwa w rejonie OG–NOG z punktami decyzyjnymi D1...n (publikacja [2], Rys. 18).

Poziom OG oraz paliwo/energia stanowią wybrany fragment szerokiego obszaru kompetencyjnego logistyki wojskowej. Wypracowane podejście (predykcja MLP-BR, wariantowanie 3W, alerty MIN/MAX, zapis iteracji i raportowanie) ma charakter aplikacyjny, może zostać uogólnione na inne klasy zasobów i inne poziomy zarządzania, pod warunkiem zapewnienia odpowiednich danych i integracji z systemami resortowymi.


Z analiz przedstawionych w publikacjach [2] i [6] wynika, że istotną barierą sprawności działania jest rozproszenie danych w różnych systemach informatycznych oraz brak pełnej integracji narzędzi informatycznych (rys. 3).



Rysunek 3. Rozproszenie źródeł danych i czas przygotowania danych w procesie zarządzania paliwem (publikacja [2], Rys. 4).

W konsekwencji osoby funkcyjne poświęcają zbyt dużo czasu na proces przygotowania danych (pozyskiwanie, gromadzenie, konsolidacja i weryfikacja), a nie na proces analizy i podjęcia decyzji dotyczącej bezpieczeństwa zasobów energetycznych. Zjawisko to nasila się w sytuacjach losowych (zakłócenia dostaw, pilne potrzeby), w których użytkownik aby szybko i skutecznie podjąć właściwą decyzję potrzebuje krótkoterminowej prognozy i wyników analizy porównawczej wariantów działania.

W publikacji [3] zaproponowano podejście, w którym problem dystrybucji paliw jest traktowany jako wieloetapowy proces decyzyjny opisany w formie wielokryterialnego modelu procesu decyzyjnego (WMPD). Kolejne kroki procesu decyzyjnego w gospodarce paliwowej przedstawiono na rys. 4.



Rysunek 4. Kroki procesu decyzyjnego w gospodarce paliwowej (publikacja [3], Rys. 1)

Z perspektywy celu przyjętego w rozprawie oznacza to, że podstawową funkcją narzędzia wspomagania decyzji nie jest jedynie prezentacja danych historycznych, lecz zdolność do prognozowania oraz możliwość generowania wariantów decyzji w ujęciu operacyjnym.

Szczególą wartość w tym kontekście ma zastosowanie metod uczenia maszynowego, a zwłaszcza sieci neuronowych, które mogą aproksymować nieliniowe zależności pomiędzy uwarunkowaniami realizacji procesu (intensywność działań, zasoby, pogoda, obciążenie popytowe), a stanem paliwa. Włączenie predykcji do narzędzia wspomagania decyzji umożliwia wczesne ostrzeżenie o ryzyku naruszeń MIN/MAX oraz zaplanowanie działań korygujących.

## 9. OKREŚLENIE PROBLEMU BADAWCZEGO, TEZY ORAZ ZADAŃ BADAWCZYCH

### 9.1 Problem badawczy

**Główny problem badawczy** rozprawy można sformułować następująco:

W jaki sposób zaprojektować logistyczny system wspomagania decyzji dla gospodarki paliwowej w oddziale gospodarczym, który – przy ograniczonej dostępności danych i wysokiej zmienności operacyjnej – zapewni stabilną predykcję krótkoterminową oraz wygeneruje użyteczne warianty działania (optymistyczny, optymalny, pesymistyczny), umożliwiając kontrolę ryzyka naruszeń progów MIN/MAX?

Tak ujęty główny problem badawczy zawiera w sobie następujące **problemy szczegółowe**: (i) modelowanie procesu i identyfikację zmiennych, (ii) dobór i walidację metody predykcji o wysokiej zdolności generalizacji, (iii) implementację narzędzia o wysokiej użyteczności dla decydenta.

W praktyce oznacza to konieczność powiązania prognozy ilościowej z interpretacją operacyjną (ryzyko, zapewnienie ciągłości dostaw, alerty) oraz z możliwością wprowadzania przez użytkownika parametrów sytuacyjnych, których nie można w pełni odtworzyć wyłącznie na podstawie danych historycznych.

### 9.2 Teza badawcza

Teza główna rozprawy brzmi:

Zastosowanie perceptronu wielowarstwowego (MLP) uczonego metodą regularyzacji bayesowskiej (BR) jako rdzenia predykcyjnego w logistycznym systemie wspomagania decyzji zapewnia stabilną generalizację i niskie błędy predykcji w zadaniu prognozowania stanu paliwa w oddziale gospodarczym, a połączenie predykcji z analizą scenariuszową i parametryzacją warunków operacyjnych przez decydenta zwiększa użyteczność wyników w procesie decyzyjnym.

Teza wynika z badań porównawczych przedstawionych w publikacji [1], w których regularyzacja bayesowska wykazała przewagę jakościową w całym zakresie liczby neuronów, a w szczególności dla większej złożoności modelu (50 neuronów).

### 9.3 Zadania badawcze

W celu weryfikacji tezy oraz osiągnięcia celu głównego sformułowano następujące zadania badawcze:

Z1. Analiza procesu gospodarowania paliwem w OG oraz identyfikacja zmiennych decyzyjnych i uwarunkowań wpływających na poziom zapasu.

Z2. Opracowanie struktury danych (krok tygodniowy) oraz przygotowanie zbioru historycznego do uczenia i walidacji.

Z3. Dobór i porównanie konfiguracji MLP oraz algorytmów uczenia (BFGS/BR/LM/RP) z wykorzystaniem miar R, RMSE i MSE.

Z4. Opracowanie logiki scenariuszowej (trzy warianty) powiązanej z parametrami operacyjnymi, zasobowymi i popytowymi.

Z5. Implementacja prototypu LSWD w środowisku MATLAB/Excel: interfejs użytkownika (GUI), alerty poziomów MIN/MAX, zapisy iteracji, raportowanie.

Z6. Walidacja funkcjonalna prototypu: testy scenariuszowe, testy graniczne oraz analiza wrażliwości.


## 10. METODY BADAWCZE WYKORZYSTANE DO REALIZACJI ROZPRAWY DOKTORSKIEJ

Metody badań zastosowane w rozprawie obejmują połączenie podejścia systemowego, empirycznego i inżynierskiego. W części koncepcyjnej zastosowano analizę systemową i modelowanie procesu decyzyjnego, w tym identyfikację faz i kroków procesu podejmowania decyzji oraz opis roli informacji i interfejsu użytkownika. W części empirycznej przeprowadzono badania porównawcze modeli uczenia maszynowego dla zadania regresji, z wykorzystaniem klasycznych miar jakości dopasowania i błędu. W części inżynierskiej zaprojektowano i zaimplementowano prototyp LSWD, integrujący predykcję, wariantowanie, alertowanie i raportowanie.

W badaniach predykcyjnych zastosowano perceptron wielowarstwowy (MLP) z jedną warstwą ukrytą. Model sieci neuronowej do predykcji przedstawiono na rysunku 5.

Dla zapewnienia porównywalności wyników przyjęto trzy warianty liczby neuronów w warstwie ukrytej: 10, 20 i 50. Każdy z modeli uczono i oceniano w czterech wariantach algorytmicznych: BFGS (quasi-Newton), regularyzacja bayesowska (BR), Levenberg–Marquardt (LM) oraz resilient backpropagation (RP). Jakość oceniano wskaźnikiem regresji (dopasowania)  $R^2$  oraz błędami RMSE i MSE.

W implementacji prototypu LSWD zastosowano zasady projektowania interfejsu użytkownika ukierunkowane na efektywność decyzyjną: ograniczenie liczby parametrów widocznych jednocześnie, grupowanie wejść (sytuacja operacyjna, zasoby, środowisko, obciążenie), jednoznaczne komunikaty (alerty) oraz prezentację wyników w postaci wykresu wariantów i raportu. Zastosowano także mechanizm zapisu iteracji do arkusza kalkulacyjnego, który zapewnia audytowalność i możliwość analizy po zakończeniu jego opracowania.



Rysunek 5. Model sieci neuronowej do predykcji (publikacja [1], Fig. 1).

## 10.1 Przygotowanie danych i reżim walidacji predykcji

Ponieważ skuteczność LSWD jest determinowana jakością danych, w badaniach oraz w prototypie przyjęto jawny „reżim walidacji” obejmujący etapy: (1) ujednolicenie kroku czasowego (tydzień jako podstawowe okno decyzyjne), (2) kontrolę kompletności i spójności obserwacji, (3) normalizację zmiennych wejściowych, (4) podział danych na zbiory uczący/walidacyjny/testowy oraz (5) ocenę jakości na standaryzowanych miarach.


Dane historyczne stanowią szereg czasowy stanu magazynu paliwa w OG (Stan\_magazynu) z progami MIN/MAX, agregowany tygodniowo. W publikacji [1] wskazano przykładowy horyzont czasowy na lata 2019–2023 obejmujący 260 tygodni, co odpowiada pięcioletniemu oknu obserwacji (liczonemu „od pierwszego dnia tygodnia”). Dane w prototypie LSWD są wczytywane z Excel i mogą być iteracyjnie uzupełniane w kolejnych wersjach plików danych arkusza (rejestr wersji plików).

Proces kontroli jakości danych został zaprojektowany wielopoziomowo. W pierwszej kolejności skupiono się na identyfikacji braków (np. pustych interwałów tygodniowych) oraz weryfikacji wartości skrajnych pod kątem ich zgodności z fizyczną pojemnością magazynu i poprawnością relacji między progami MIN i MAX. Sposób postępowania z lukami w danych uzależniono od ich skali: w przypadku incydentalnych braków krótkotrwałych zastosowano metodę imputacji konserwatywnej poprzez przeniesienie ostatniej znanej wartości. Z kolei przy brakach o charakterze długofalowym zdecydowano o wyłączeniu całego segmentu z procesu uczenia modelu. Problem wartości odstających rozwiązano poprzez zastosowanie

winsoryzacji danych (redukcję danych skrajnych) lub weryfikację źródłową (zależnie od dostępności danych wejściowych).

Podział danych na zbiory realizowany jest zgodnie z praktyką przyjętą w [1]: 70% próbek jako zbiór uczący, 15% jako walidacyjny (w tym kontrola uogólniania i wczesne zatrzymanie), 15% jako testowy do niezależnej oceny. W celu zwiększenia dokładności predykcji, zastosowano 150 - 800 epok (iteracji) oraz porównywano stabilność wyników między wybranymi algorytmami uczenia maszynowego.

Normalizacja wejść: zmienne o różnych skalach (np. stan magazynu w jednostkach logistycznych oraz wskaźniki 0–1 wprowadzane przez decydenta) są sprowadzane do zakresu [0,1] metodą min-max, przy czym dla zmiennej „Stan\_magazynu” granice wynikają z MIN/MAX lub z obserwowanych wartości historycznych. Temperatura jest kodowana jako zmienna ciągła po przeskalowaniu do [0,1] w zadanym przedziale operacyjnym (np.  $-20^{\circ}\text{C} \dots +40^{\circ}\text{C}$ ), co pozwala zachować zgodność z pozostałymi wskaźnikami sytuacyjnymi (rys. 6).



Rysunek 6. Wpływ temperatury i wilgotności – zależności korelacyjne (publikacja [1], Fig. 10).

Ocena jakości modelu prowadzona jest jednocześnie na kilku miarach: (i)  $R^2$  – współczynnik dopasowania, (ii) RMSE – błąd średniokwadratowy w jednostce zmiennej, (iii) MSE – błąd średniokwadratowy jako miara karząca duże odchylenia. Wybór konfiguracji sieci oparto nie tylko na minimum błędów, ale także na odporności na przeuczenie oraz stabilności przy zwiększaniu liczby neuronów warstwy ukrytej.

Zgodnie z [1] największą stabilność uogólniania uzyskano dla algorytmu regularyzacji bayesowskiej (BR).


Prognoza wielokrokowa (horyzont  $H$ ) realizowana jest iteracyjnie: prognoza z kroku  $t+1$  staje się wejściem dla  $t+2$  itd. Podejście to jest proste implementacyjnie, lecz uwrażliwia wyniki na kumulację błędów. Dlatego w LSWD prognoza jest zawsze prezentowana wraz z trzema wariantami oraz z analizą ryzyka naruszeń MIN/MAX, co przesuwają środek ciężkości z „dokładności punktowej” na „użyteczność decyzyjną” (wczesne ostrzeżenie i planowanie działań korygujących).

## **11. OBIEKTY BADAWCZE ORAZ PROGRAM REALIZACJI BADAŃ**

### **11.1 Obiekt badawczy i krok czasowy**

Obiektem badawczym jest proces utrzymania i regulacji zapasu paliwa w oddziale gospodarczym (OG) w rejonie odpowiedzialności logistycznej. Z perspektywy modelowania przyjęto dyskretny krok czasowy odpowiadający cyklowi planistycznemu wynoszący tydzień. Wybór kroku tygodniowego jest uzasadniony zarówno z punktu widzenia dostępności danych ewidencyjnych, jak i z perspektywy praktyki planowania i raportowania. Przyjęta długość kroku umożliwia agregację operacji wydawania i przyjmowania, a jednocześnie jest wystarczająco krótka, aby wskazywać tygodnie krytyczne wymagające reakcji.

Kluczowym parametrem stanu w analizowanym modelu jest wolumen paliwa zgromadzony w magazynie (Stan\_magazynu), którego przebieg w czasie (na przykładzie danych historycznych za okres 2019-2023) przedstawiono na rysunku 7. Wartość ta jest ściśle limitowana przez parametry MIN i MAX, które w systemie decyzyjnym wyznaczają analizowany przedział. O ile próg dolny (MIN) należy interpretować jako bufor bezpieczeństwa niezbędny do zachowania ciągłości procesów oraz utrzymanie nakazanych normami wojskowymi zapasów, o tyle próg górny (MAX) stanowi odzwierciedlenie technicznych barier pojemnościowych oraz obowiązujących procedur magazynowych. Naruszenie progów jest interpretowane jako zdarzenie krytyczne, a utrzymanie stanu w przedziale [MIN, MAX] jako warunek poprawności prowadzenia gospodarki paliwowej.



Rysunek 7. Dane historyczne stanu paliwa – przykład szeregu czasowego (publikacja [1], Fig. 2).

Na potrzeby dysertacji przeanalizowano ok. 14 000 rekordów danych z systemu ZWSI RON w okresie od 2019 – 2023 roku. Dane zgrupowano do 260 tygodniowych okresów historycznych, które podlegały dalszej analizie.

## 11.2 Struktura danych i zmienne wejściowe

Konstrukcja modelu opiera się na danych historycznych blisko 14 tys. rekordów zestawionych w 260 interwałach tygodniowych, obejmujących lata 2019–2023. W procesie analitycznym uwzględniono nie tylko surowe dane ilościowe, takie jak bilanse przyjęć i wydań paliwa, ale również szereg parametrów determinujących przebieg procesów logistycznych (szczegóły zaprezentowano w tabeli 2). Z punktu widzenia skuteczności predykcji, szczególnie istotnym jest uwzględnienie bieżącej intensywności działań (obciążenie operacyjne) oraz faktycznej wydajności zasobów, w tym dostępności personelu i sprawności technicznej sprzętu. Wpływ na model mają także zmienne środowiskowe, m.in. temperatura, oraz specyfika popytu definiowana przez liczbę i priorytet zaopatrywanych jednostek.

Część parametrów ma charakter „prognostyczny”, to znaczy w chwili podejmowania decyzji stanowi ocenę sytuacji na przyszły tydzień, a nie jest wyłącznie odczytem danych historycznych. Z tego powodu prototyp LSWD przewiduje wprowadzanie tych wartości przez decydenta, co umożliwia analizę scenariuszową i testowanie wariantów działania.

Tabela 2. Kategorie zmiennych modelu (opracowanie własne)

Kategoria	Przykładowe zmienne	Znaczenie decyzyjne
Stan i ograniczenia magazynu OG	Stan_magazynu MIN, MAX	Warunek bezpieczeństwa i pojemności; podstawa alertów
Aktywność	Intensywność działań Czas wydawania Rodzaj operacji	Determinant tempa zużycia i obciążenia procesu
Zasoby	Dostępność personelu, Sprawność sprzętu	Wpływ na zdolność realizacji i ryzyko opóźnień
Środowisko	Temperatura Wilgotność Wiatr	Czynnik korygujący; wpływ pośredni i sezonowy
Obciążenie OG	Liczba jednostek Rodzaje jednostek	Modelowanie struktury odbiorców i preferencji obsługi

### 11.3 Program realizacji badań – przebieg

Program realizacji badań miał charakter sekwencyjny i obejmował cztery główne fazy:

Faza I – modelowanie koncepcyjne procesu decyzyjnego i systemu dystrybucji paliw.

Na podstawie analizy literatury i praktyki zidentyfikowano kroki procesu decyzyjnego, miejsca generowania informacji oraz katalog wskaźników opisujących sytuację logistyczną. Efektem fazy było zdefiniowanie ram WMPD oraz wskazanie potrzeby wariantowania decyzji w odniesieniu do progów MIN/MAX. Faza ta stanowi fundament teoretyczny rozprawy i wskazuje, jakie informacje są krytyczne dla jakości decyzji.

Faza II – przygotowanie danych i badania porównawcze modeli sieci neuronowych.

Opracowano strukturę danych, przeprowadzono przygotowanie zbioru (spójność, obsługa braków, normalizacja), a następnie wykonano serię eksperymentów uczenia MLP dla różnych konfiguracji neuronów i algorytmów uczenia. Faza zakończyła się wyborem konfiguracji referencyjnej (MLP-BR) na podstawie miar jakości.

Faza III – projekt i implementacja prototypu LSWD w MATLAB. Zaimplementowano moduły: wczytywanie danych, predykcję wielokrokową, logikę scenariuszową, interfejs użytkownika, alertowanie, raportowanie oraz zapis iteracji.

Faza IV – walidacja funkcjonalna i analiza wrażliwości. Wykonano testy scenariuszowe, których celem było sprawdzenie zgodności zachowania systemu z logiką operacyjną, rozróżnialności wariantów, poprawności alertów oraz spójności mechanizmu zapisu iteracji. Wykonano również ocenę jakościową użyteczności interfejsu użytkownika w kontekście szybkości uzyskania wyniku i jego merytorycznej interpretacji.

## 12. WYNIKI BADAŃ (NA PODSTAWIE PUBLIKACJI)

### 12.1 Porównanie algorytmów uczenia MLP i dobór konfiguracji referencyjnej

Kluczowym etapem badań była weryfikacja, czy i w jakim stopniu dobór algorytmu uczenia wpływa na stabilność predykcji stanu paliwa. W publikacji [1] porównano cztery algorytmy uczenia (BFGS, BR, LM i RP) dla perceptronu wielowarstwowego z jedną warstwą ukrytą i trzema rozmiarami warstwy (10, 20 i 50 neuronów). Ocenę przeprowadzono na podstawie miar: współczynnik dopasowania  $R^2$ , błąd RMSE oraz MSE (rys. 8) wraz z histogramami błędów (rys. 9) oraz zmianami  $R^2$  i RMSE w funkcji liczby neuronów (rys.10).


Wyniki porównania wykazały, że regularyzacja bayesowska (BR) uzyskała najwyższą jakość dopasowania przy jednoczesnym zachowaniu wysokiej zdolności generalizacji. W szczególności dla sieci o 50 neuronach BR noteuje bardzo niskie wartości błędu MSE rzędu  $10^{-6}$  przy  $R \approx 1$  (tabela 3). Jednocześnie dla tej samej złożoności modelu metoda Levenberga–Marquardta (LM) wykazała istotną degradację jakości (gwałtowny wzrost RMSE i MSE), co jest spójne z ryzykiem przeuczenia i niestabilności uczenia przy dużej liczbie wag.

Z perspektywy projektowania systemu wspomagania decyzji w warunkach ograniczonego zbioru danych i zmienności środowiska operacyjnego przewaga BR ma wymiar praktyczny: mechanizm regularyzacji ogranicza wrażliwość modelu na obserwacje odstające i redukuje „uczenie na pamięć”, dzięki czemu prognozy są bardziej stabilne dla nowych danych. W związku z tym w dalszych pracach wdrożeniowych przyjęto konfigurację MLP-BR jako rdzeń predykcyjny prototypu LSWD.


Tabela 3. Wyniki porównania jakości uczenia (na podstawie Tabeli 1 z publikacji [1]).

Liczba neuronów	BFGS (RMSE/MSE/R)	BR (RMSE/MSE/R)	LM (RMSE/MSE/R)	RP (RMSE/MSE/R)
10	2,14·10 <sup>3</sup> / 6,14·10 <sup>6</sup> / 0,98	0,21 / 1,13·10 <sup>-4</sup> / 1,00	1,65 / 7,03 / 1,00	2,84·10 <sup>3</sup> / 1,9·10 <sup>7</sup> / 0,97
20	2,4·10 <sup>3</sup> / 1,18·10 <sup>7</sup> / 0,98	27,5 / 2,6·10 <sup>-6</sup> / 0,99	0,36 / 0,38 / 1,00	5,58·10 <sup>3</sup> / 8,12·10 <sup>7</sup> / 0,92
50	5,11·10 <sup>3</sup> / 6,76·10 <sup>7</sup> / 0,96	11,04 / 1,3·10 <sup>-6</sup> / 1,00	2,1·10 <sup>3</sup> / 1,3·10 <sup>8</sup> / 0,99	1,02·10 <sup>4</sup> / 1,6·10 <sup>8</sup> / 0,87

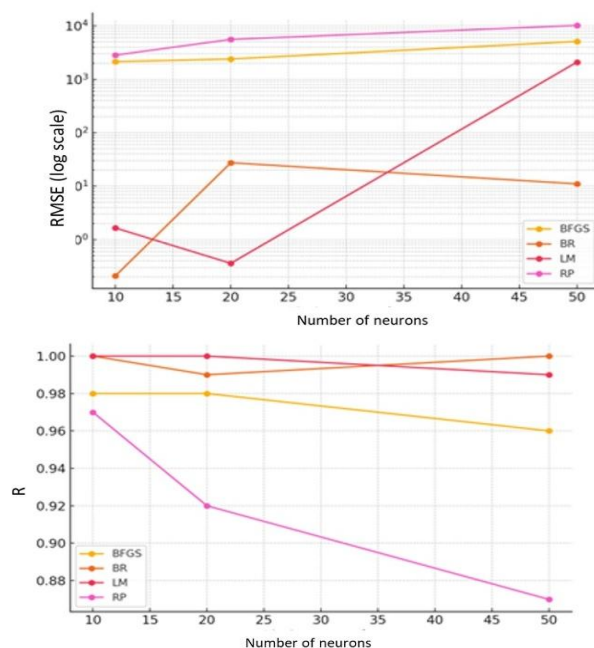
Model wspomagania procesu decyzyjnego na potrzeby zapewnienia energii dla Sił Zbrojnych na podstawie zarządzania paliwem



Rysunek 8. Porównanie dopasowania oraz MSE dla algorytmów uczenia (publikacja [1], Fig. 7).



Rysunek 9. Histogramy błędów regresji dla BFGS/BR/LM/RP (publikacja [1], Fig. 8)



Rysunek 10. Zmiany R i RMSE w funkcji liczby neuronów (publikacja [1], Fig. 9).

## 12.2 Modele wielokryterialne i rola informacji w procesie decyzyjnym

W publikacjach [3], [4], [5] i [6] problem wspomagania decyzji w logistyce energii przedstawiono jako zagadnienie wielowymiarowe, w którym decyzje muszą uwzględniać zarówno przepływy materiałowe (dostawy, dystrybucję, magazynowanie), jak i przepływy informacyjne (raportowanie, świadomość sytuacyjną, ocenę ryzyka). W szczególności wskazano na potrzebę budowy wielokryterialnego modelu procesu decyzyjnego (WMPD), w którym możliwe jest wyznaczanie wariantów działania prowadzących do utrzymania optymalnego poziomu paliwa.

Istotnym elementem tej koncepcji jest powiązanie „zdarzenia” z „reakcją” systemu logistycznego. Oznacza to, że system wspomagania decyzji nie powinien ograniczać się do prezentacji danych historycznych, lecz przewidywać skutki planowanej decyzji i wskazywać działania korygujące. System opiera się na pętli ciągłego doskonalenia, w tym kontekście sieć neuronowa jest traktowana jako komponent funkcjonalny większego systemu: ma mapować zależności pomiędzy warunkami operacyjnymi i zasobowymi a stanem paliwa, a następnie umożliwiać generowanie kilku wariantów „what-if” w oparciu o parametry wprowadzane przez decydenta.

W publikacji [2] zwrócono uwagę, że skuteczność wdrożenia narzędzia AI w logistyce zależy także od jakości interfejsu człowiek-maszyna. Nawet rozbudowane

systemy mogą nie być wykorzystywane w pełni, jeśli interfejs (GUI) jest nieintuicyjny lub nie wspiera decydenta w szybkim formułowaniu i testowaniu wariantów. W konsekwencji w rozprawie przyjęto, że prototyp LSWD powinien łączyć predykcję z prezentacją wyników oraz mechanizmem raportowania i archiwizacji decyzji.

### **13. BADANIA I WYNIKI IMPLEMENTACYJNE PROTOTYPU LSWD/LDSS (WYNIKI NIEPUBLIKOWANE)**

Niniejszy rozdział stanowi zasadnicze rozwinięcie badań i rezultatów, które nie były dotychczas publikowane. W oparciu o konfigurację predykcyjną wybraną w publikacji [1] (MLP-BR jako konfiguracja referencyjna) opracowano prototyp logistycznego systemu wspomagania decyzji (LSWD; ang. LDSS) w środowisku MATLAB z wykorzystaniem arkusza kalkulacyjnego MS Excel jako warstwy danych.

Celem prototypu było przejście od „modelu predykcyjnego” do „narzędzia decyzyjnego”, tj. rozwiązania, które może być używane operacyjnie do: (i) szybkiej oceny konsekwencji przyjętych założeń, (ii) analizy ryzyka naruszenia progów MIN/MAX w horyzoncie kilku tygodni, (iii) porównania trzech wariantów działania oraz (iv) prowadzenia audytu decyzji poprzez zapis iteracji i raportowanie.

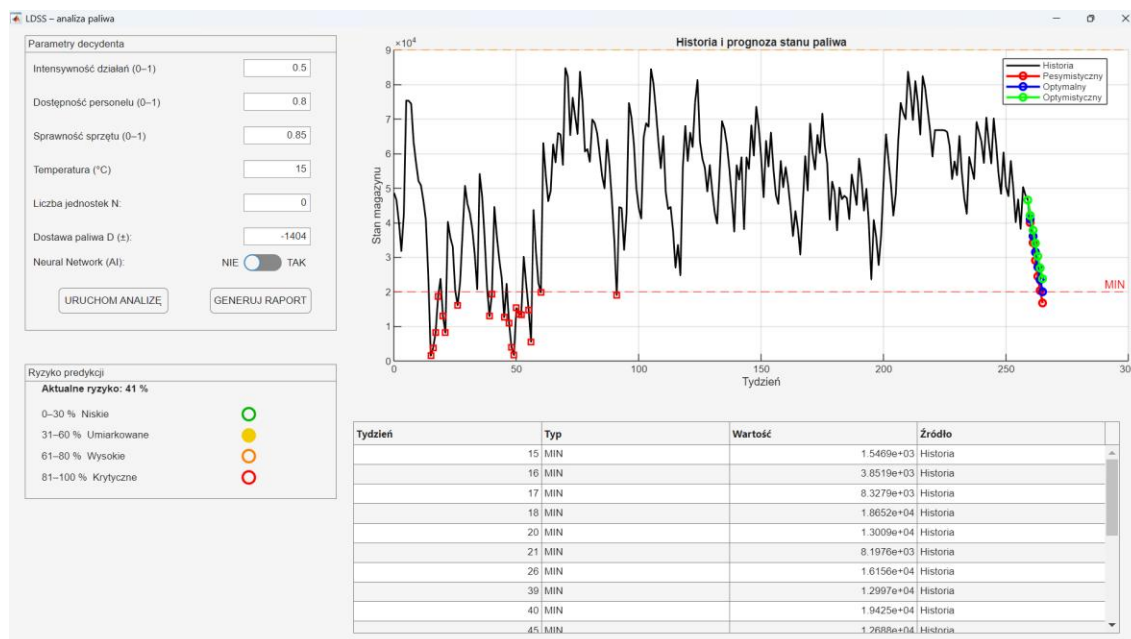
#### **13.1 Założenia funkcjonalne i użytkowe prototypu**

Projekt prototypu oparto o założenia: jednoznaczny cel MIN/MAX, krok tygodniowy, parametryzacja przez decydenta, wariantowanie w oparciu o trzy warianty, alertowanie, audytowalność i raportowanie. Prototyp jest ukierunkowany na zastosowanie w warunkach presji czasu, dlatego wyniki są prezentowane w postaci jednego wykresu z trzema krzywymi oraz krótkich komunikatów tekstowych o ryzyku i alertach.

#### **13.2 Parametry wprowadzane w GUI**

Projekt interfejsu graficznego (GUI), przedstawiony na rysunku 11, umożliwia użytkownikowi wprowadzanie zmiennych w dwóch formatach: jako wartości w znormalizowanej skali 0–1 oraz w jednostkach naturalnych – temperatura otoczenia. Przyjęta skala 0–1 pozwala na precyzyjne odzwierciedlenie dynamiki procesu, gdzie wzrost intensywności działań przekłada się bezpośrednio na prognozowane zużycie, natomiast wyższe wskaźniki dostępności personelu i sprawności technicznej są interpretowane przez model jako czynniki stabilizujące proces. Z kolei parametry dotyczące obciążeń popytowych i ograniczeń proceduralnych działają


destruktywnie. Ich wysoki poziom sygnalizuje systemowi wzrost ryzyka oraz zwiększoną presję na utrzymanie rezerw magazynowych.



Rys. 11 Interfejs użytkownika systemu LSDS

### 13.3 Logika trzech wariantów działania i rozróżnialność scenariuszy


Wariant optymalny odpowiada wartościom parametrów wprowadzonych przez decydenta. Wariant optymistyczny i pesymistyczny są tworzone przez kontrolowaną zmianę kluczowych czynników determinujących tempo zużycia i efektywność realizacji procesu. Mechanizm wariantowania jest skonstruowany tak, aby był zarówno rozróżnialny matematycznie, jak i interpretowalny operacyjnie – tzn. aby różnice pomiędzy krzywymi wariantów były zauważalne i przekładały się na ryzyko alertu MIN/MAX (rys. 12).



Rys. 12 Wykres predykcji z zaznaczonymi zakresami ilości paliw w magazynie OG MIN 20000 litrów, a MAX 90000 litrów

### 13.4 Alerty MIN/MAX i rekomendacje


Alerty wyznacza się poprzez porównanie prognozy z progami MIN i MAX w każdym tygodniu przyjętego okresu badań. Szczególnie istotny jest alert w wariancie optymalnym – traktowany jako sygnał konieczności działań korygujących. Alert wyłącznie w wariancie pesymistycznym wskazuje ryzyko warunkowe (zależne od eskalacji działań lub pogorszenia zasobów). Alert MAX sygnalizuje ryzyko przekroczenia pojemności magazynu lub naruszeń procedur. Dla efektywnego zobrazowania stanów alarmowych poziomu paliwa na wykresie historii i prognozy stanu paliwa zaproponowanego interfejsu decydenta alerty występujące w poszczególnych tygodniach wyróżniono w postaci czerwonych kwadratów (rys. 13).



Rys. 13. Alerty przekroczenia min poziomu paliwa dla OG zaznaczone w postaci czerwonych kwadratów

### 13.5 Zapis iteracji i raportowanie: audytowalność decyzji

Każde uruchomienie analizy skutkuje zapisem wyników do nowego pliku w arkuszu MS Excel z oznaczeniem daty i numeru wersji (v1, v2, ...), co umożliwia archiwizację kolejnych iteracji decyzji w tym samym dniu. Zapis obejmuje parametry wejściowe, wyniki prognoz, informacje o alertach oraz metadane (rys.14). Prototyp generuje również raport w oknie i umożliwia jego eksport do PDF, co pozwala na dołączenie wyniku analizy do dokumentacji planistycznej.



Rysunek 14. Przykładowy raport decyzyjny LSWD generowany do PDF

### 13.6 Walidacja funkcjonalna i testy scenariuszowe

Walidacja prototypu obejmowała testy graniczne (skrajne wartości 0–1), testy obciążenia popytowego (0–6 jednostek) oraz testy spójności wariantów. Oczekiwano, że wzrost intensywności działań i obciążenia obniża prognozę, natomiast wzrost dostępności zasobów stabilizuje proces i redukuje ryzyko alertu MIN. Wyniki testów potwierdziły zgodność logiki wariantowania i alertowania z przyjętymi założeniami.

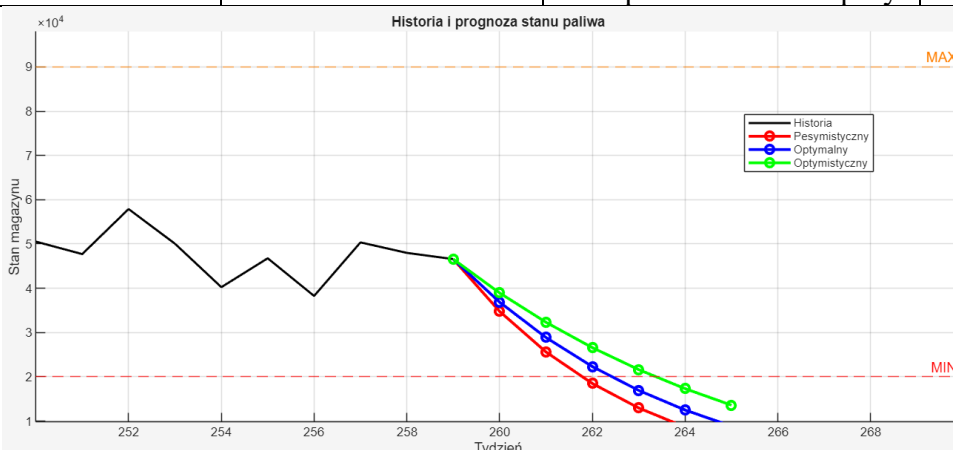
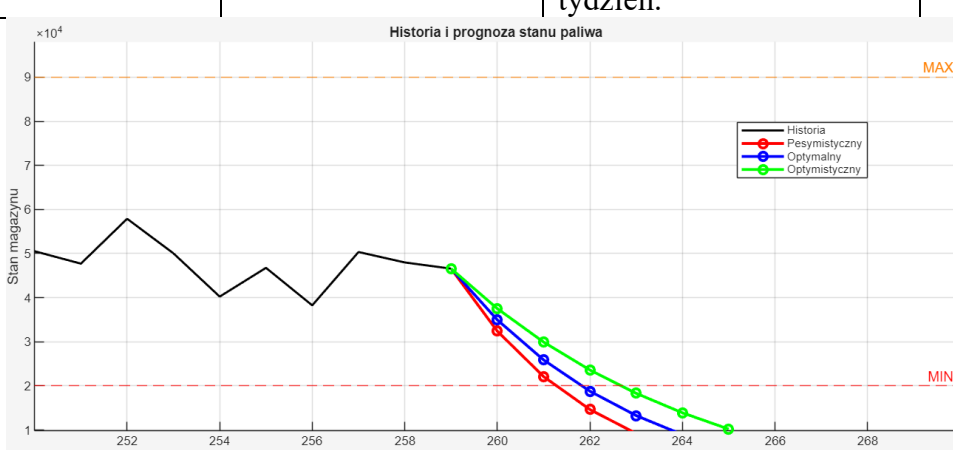
Walidację prototypu przeprowadzono w logice zbliżonej do testów akceptacyjnych (UAT) w systemach wspomagania decyzji: zdefiniowano scenariusze wejściowe, oczekiwany kierunek wpływu na prognozę oraz kryteria zaliczenia. Scenariusze obejmowały zarówno przypadki typowe (planowanie tygodnia

szkoleniowego), jak i graniczne (ryzyko zejścia poniżej MIN lub przekroczenia MAX) (tab. 4).

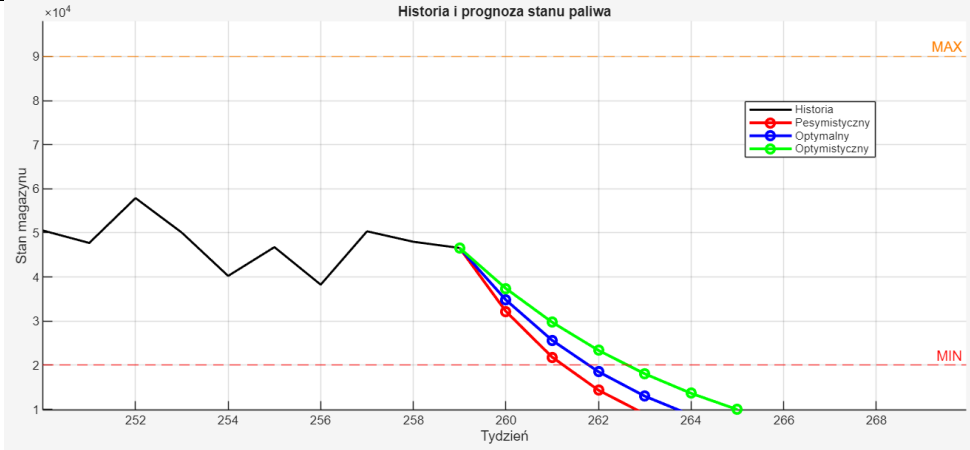
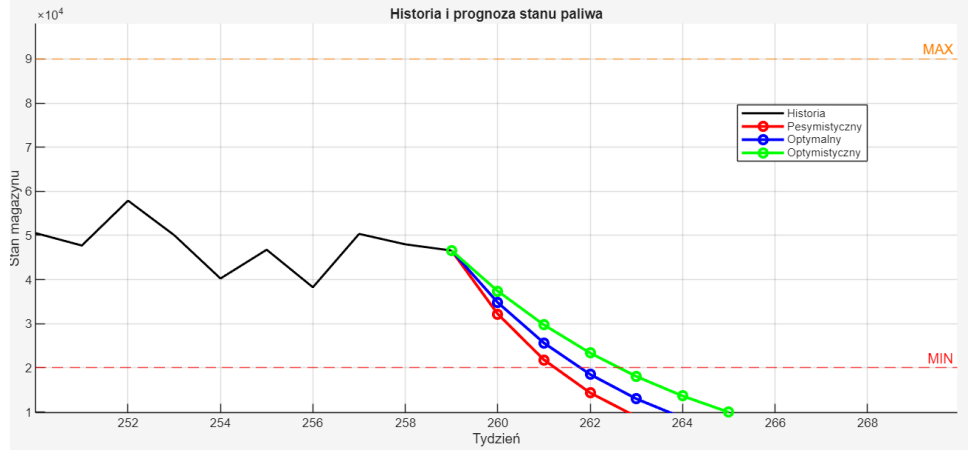
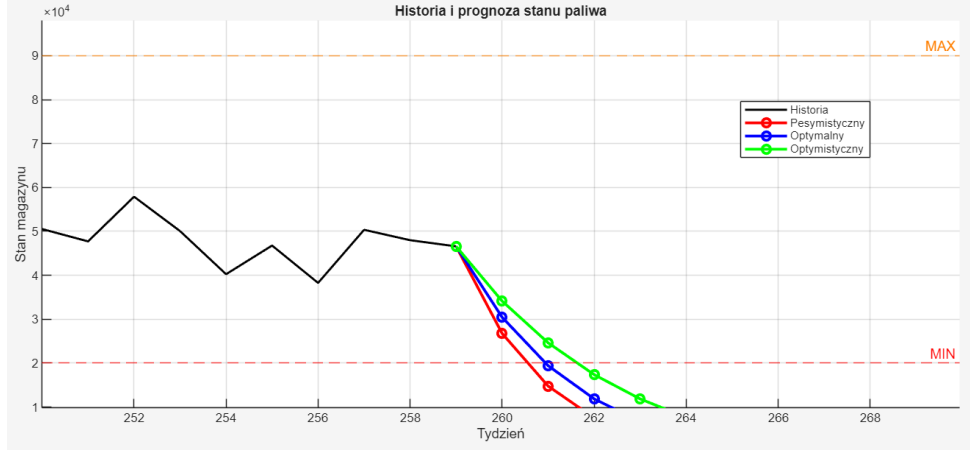
Kryteria zaliczenia testów scenariuszowych w LSWD obejmowały m.in.: (i) różnialność wariantów 3W na wykresie (krzywe niepokrywające się), (ii) zgodność znaku wpływu wskaźników sytuacyjnych z logiką operacyjną (np. większa intensywność działań → większe zużycie → niższy stan paliwa), (iii) poprawne wyzwalanie alertów MIN/MAX, (iv) poprawny zapis iteracji do pliku Excel z wersjonowaniem daty i numeru v1/v2... oraz (v) generowanie raportu i możliwość eksportu do PDF.

Model wspomagania procesu decyzyjnego na potrzeby zapewnienia energii dla Sił Zbrojnych na podstawie zarządzania paliwem

Tabela 4. Przykładowa macierz scenariuszy testowych prototypu LSWD (opracowanie własne).

ID	Cel testu	Parametry (I/P/S/T)	Otrzymany efekt	Wynik jakościowy
S1	Bazowy tydzień planistyczny	I=0,5; P=0,8; S=0,8; T=15 <sup>0</sup> C N=3 D=0	Warianty 3W rozdzielone (alert MIN – 10 dni różnicy dla skrajnych W); brak dostaw paliwa obniża zapasy.	Zgodne
				
S2	Wzrost intensywności działań	I=0,9; P=0,8; S=0,8; T=15 <sup>0</sup> C N=3 D=0	Prognoza obniżenia poziomu paliwa; możliwy alert MIN dla W pesymistycznego wcześniej o ok tygodzień.	Zgodne
				
S3	Ograniczone dostępności personelu	I=0,6; P=0,3; S=0,8; T=15 <sup>0</sup> C N=3 D=0	Zużycie na poziomie S1 ale niższa efektywność powoduje większy spadek prognoz poziomu paliwa.	Zgodne


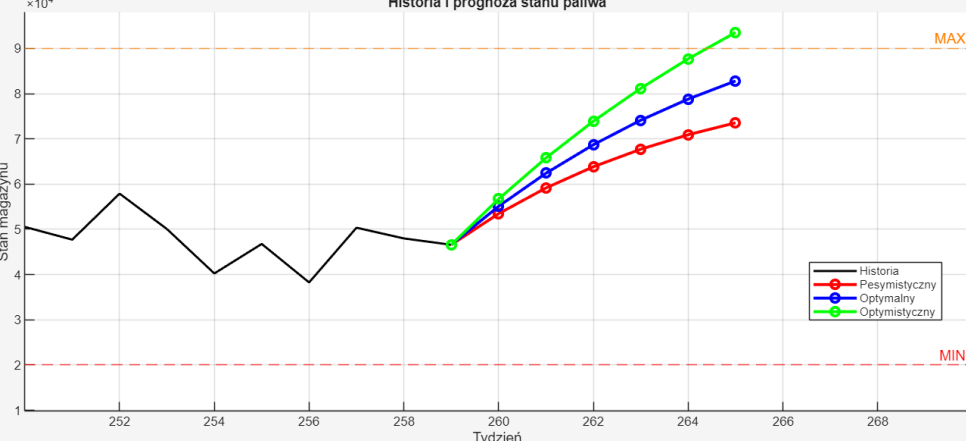
## Model wspomaganie procesu decyzyjnego na potrzeby zapewnienia energii dla Sił Zbrojnych na podstawie zarządzania paliwem

	 <p>Historia i prognoza stanu paliwa</p> <p>Y-axis: Stan magazynu (x10<sup>4</sup>)</p> <p>X-axis: Tydzień</p> <p>Legend: Historia (black line), Pesymistyczny (red line with circles), Optymalny (blue line with circles), Optymistyczny (green line with circles)</p> <p>Alerts: MAX (orange dashed line at 9), MIN (red dashed line at 2)</p>	<p><math>I=0,6</math>; <math>P=0,8</math>; <math>S=0,3</math>;  <math>T=15^{\circ}\text{C}</math>  <math>N=3</math>  <math>D=0</math></p>	<p>Prognoza obniżenia stanu magazynu; większe ryzyko alert MIN</p>	<p>Zgodne</p>
<p>S4</p>	<p>Obniżenie poziomu sprawności sprzętu</p>	<p><math>I=0,6</math>; <math>P=0,8</math>; <math>S=0,3</math>;  <math>T=15^{\circ}\text{C}</math>  <math>N=3</math>  <math>D=0</math></p>	<p>Prognoza obniżenia stanu magazynu; większe ryzyko alert MIN</p>	<p>Zgodne</p>
	 <p>Historia i prognoza stanu paliwa</p> <p>Y-axis: Stan magazynu (x10<sup>4</sup>)</p> <p>X-axis: Tydzień</p> <p>Legend: Historia (black line), Pesymistyczny (red line with circles), Optymalny (blue line with circles), Optymistyczny (green line with circles)</p> <p>Alerts: MAX (orange dashed line at 9), MIN (red dashed line at 2)</p>	<p><math>I=0,6</math>; <math>P=0,8</math>; <math>S=0,8</math>;  <math>T=-15^{\circ}\text{C}</math>  <math>N=3</math>  <math>D=0</math></p>	<p>Nieznaczne obniżenie stanu magazynu (modyfikator środowiskowy)</p>	<p>Zgodne</p>
<p>S5</p>	<p>Warunki zimowe (temperatura niska)</p>	<p><math>I=0,6</math>; <math>P=0,8</math>; <math>S=0,8</math>;  <math>T=-15^{\circ}\text{C}</math>  <math>N=3</math>  <math>D=0</math></p>	<p>Nieznaczne obniżenie stanu magazynu (modyfikator środowiskowy)</p>	<p>Zgodne</p>
	 <p>Historia i prognoza stanu paliwa</p> <p>Y-axis: Stan magazynu (x10<sup>4</sup>)</p> <p>X-axis: Tydzień</p> <p>Legend: Historia (black line), Pesymistyczny (red line with circles), Optymalny (blue line with circles), Optymistyczny (green line with circles)</p> <p>Alerts: MAX (orange dashed line at 9), MIN (red dashed line at 2)</p>	<p><math>I=0,6</math>; <math>P=0,8</math>; <math>S=0,8</math>;  <math>T=30^{\circ}\text{C}</math>  <math>N=3</math></p>	<p>Nieznaczna zmiana; stabilność modelu</p>	<p>Zgodne</p>
<p>S6</p>	<p>Warunki letnie (temperatura wysoka)</p>	<p><math>I=0,6</math>; <math>P=0,8</math>; <math>S=0,8</math>;  <math>T=30^{\circ}\text{C}</math>  <math>N=3</math></p>	<p>Nieznaczna zmiana; stabilność modelu</p>	<p>Zgodne</p>

# Model wspomagania procesu decyzyjnego na potrzeby zapewnienia energii dla Sił Zbrojnych na podstawie zarządzania paliwem

		D=0		
S7	Duże obciążenie: 5 jednostek	$I=0,7$ ; $P=0,8$ ; $S=0,8$ ; $T=15^{\circ}C$ $N=5$ $D=0$	Prognoza obniżenia stanu magazynu vs S1 (gdzie $N=3$ ); wyraźniejsze różnice 3W	Zgodne
S8	Brak jednostek w tygodniu	$I=0,3$ ; $P=0,9$ ; $S=0,9$ ; $T=15^{\circ}C$ $N=0$ $D=0$	Znikome obciążenie wynikające z jedynie podtrzymywania zdolności spowalnia proces dojścia do alert MIN.	Zgodne

## Model wspomaganie procesu decyzyjnego na potrzeby zapewnienia energii dla Sił Zbrojnych na podstawie zarządzania paliwem

S9	Test alertu MAX. Brak obciążenia przy założeniu znacznych dostaw paliwa.	I=0,2; P=0,9; S=0,9; T=15°C N=0 D=15 000	Brak obciążenia, niewielka intensywność działań przy maksymalnych dostawach paliwa skutkują dośnięciem do Alert MAX.	Zgodne
				
S10	Test alertu MAX dla zasilania w paliwo i N=3	I=0,2; P=0,9; S=0,9; T=15°C N=3 D=15 000	Tendencja wzrostowa prognozy do Alert MAX lecz w łagodniejszym przebiegu niż w S9 spowodowanym obciążeniem 3 jednostkami	Zgodne
				

Dla przedstawionych w tabeli 4 scenariuszy od S1 do S8 nie wprowadzano parametru dostawy paliwa, co skutkowało, choć z różną intensywnością, obniżaniem stanu magazynowego OG do osiągnięcia alert MIN. Dla decydenta jest to kluczowa informacja do podjęcia decyzji o zapotrzebowaniu dostaw paliwa w właściwym czasie i ilości zapewniając uniknięcie obniżenia stanu magazynu poniżej przyjętego minimum.

Scenariusze S9 i S10 miały na celu sprawdzenie zadziałania badanego układu pod kątem osiągnięcia maksymalnych dopuszczalnych stanów magazynowych czyli dojścia do stanu alert MAX. Proponowane przez algorytm dwa skrajne warianty nazywane „pesymistyczny” i „optymistyczny” nie koniecznie w całym swym przebiegu będą tak traktowane przez decydenta. Należy sądzić że w miarę zbliżania się ich charakterystyk do maksymalnego przyjętego poziomu zapasów paliwa w OG, to ich postrzeganie jako bardziej sprzyjające będzie odwrotne do przyjętego nazewnictwa wariantów (optymistyczny, pesymistyczny).

W ramach walidacji prototypu w celu sprawdzenia prawidłowego działania algorytmu dla każdego scenariusza S zostały wygenerowane raporty pdf (rys. 14)

### **13.7 Ograniczenia prototypu i ryzyka wdrożeniowe**

Choć prototyp LSWD potwierdził wykonalność przyjętych założeń, należy wskazać ograniczenia i ryzyka, które są typowe dla wdrożeń rozwiązań AI w logistyce wojskowej i które powinny zostać zaadresowane na etapie badań przedwdrożeniowych:

- Ograniczona liczba danych i zmienność operacyjna: przy krótkich szeregach czasowych rośnie podatność na zmiany rozkładu (ang. concept drift). Wymagane jest okresowe douczanie modelu oraz monitoring jakości.
- Wrażliwość prototypu LSWD na jakość danych wejściowych: błędne MIN/MAX, braki tygodni lub niejednoznaczna agregacja mogą generować fałszywe alerty. Konieczne jest formalne określenie reguł walidacji i odpowiedzialności za dane.
- Interpretowalność rekomendacji: mimo że warianty 3W są intuicyjne, decyzje oparte na modelu powinny być wspierane wyjaśnieniami (np. wkład wskaźników sytuacyjnych) i zapisem śladu audytowego.
- Bezpieczeństwo informacji: rzeczywiste dane o zapasach i aktywności jednostek mogą mieć charakter wrażliwy; wymagane są mechanizmy anonimizacji/pseudonimizacji oraz kontrola dostępu [1]. Ograniczenie to znika w sytuacji przejścia do badań wdrożeniowych już w środowisku niejawnym.

- Integracja z systemami resortowymi: pełna użyteczność wymaga integracji z SI ZWSI RON i innymi źródłami, co pociąga za sobą ryzyko zapewnienia interoperacyjności i kosztów utrzymania.
- Czynniki ludzkie i odpowiedzialność: LSWD jest narzędziem wspierającym, a nie zastępującym decydenta; konieczne są procedury weryfikacji rekomendacji, szkolenia użytkowników oraz uświadomienie decydującym ich odpowiedzialności za skutki podjętych decyzji.
- Zastosowanie sieci neuronowych w procesie optymalizacji procesów decyzyjnych może być bardzo efektywne w praktycznym zastosowaniu. Należy jednak mieć na uwadze ryzyka jakie ze sobą niesie w przypadku przyjęcia niewłaściwej struktury i rozmiaru sieci neuronowej oraz liczby cykli uczenia co może doprowadzić do efektu przeuczenia sieci i wzrostu błędów uczenia [5].

## 14. WKŁAD WŁASNY I ELEMENTY NOWOŚCI

Wkład własny autora obejmuje formalizację problemu gospodarowania paliwem w OG w postaci układu z progami MIN/MAX, dobór i uzasadnienie konfiguracji predykcyjnej o wysokiej stabilności generalizacji (MLP-BR), opracowanie logiki wariantowania trzech scenariuszy powiązanej z parametryzacją przez decydenta, implementację prototypu LSWD w środowiskach MATLAB/Excel oraz przygotowanie procedury walidacji funkcjonalnej. Nowość rozwiązania wynika z integracji predykcji, wariantowania, alertowania, raportowania i uporządkowanego zapisu poszczególnych wersji iteracji w jednym narzędziu, co umożliwia praktyczne zastosowanie w pętli decyzyjnej.

Wkład aplikacyjny należy interpretować również w perspektywie docelowej architektury z [2]: zaproponowany prototyp LSWD stanowi moduł, który może zostać osadzony jako komponent „warstwy inteligentnej” nad danymi w wojskowej bazie danych (ZWSI RON) i rozwijany w kierunku wielopoziomowego wsparcia decyzji (od OG do poziomów nadrzędnych) oraz włączony w spójny system zarządzania logistyką we wszystkich domenach.

## 15. WNIOSKI I KIERUNKI DALSZYCH BADAŃ

Na podstawie przeprowadzonego procesu badawczego sformułowano następujące wnioski:

1. W zadaniu predykcji poziomu paliwa dla OG perceptron wielowarstwowy (MLP) uczony z wykorzystaniem regularyzacji bayesowskiej zapewnia najwyższą stabilność generalizacji i najniższe wartości MSE w porównaniu do BFGS, LM i RP.
2. Dla większych sieci (50 neuronów) obserwuje się istotne ryzyko pogorszenia jakości uczenia metodą LM, co uzasadnia dobór algorytmu uczenia z mechanizmem kontroli złożoności modelu.
3. Predykcja stanu paliwa staje się użyteczna decyzyjnie po powiązaniu z analizą wariantów (3W) oraz z systemem alertów MIN/MAX, co pozwala na zarządzanie ryzykiem i przygotowanie alternatywnego planu.
4. Parametryzacja sytuacji przez decydenta (intensywność, zasoby, obciążenie jednostkami i priorytety) jest konieczna, ponieważ część informacji o przyszłym tygodniu ma charakter prognostyczny i nie wynika wprost z danych historycznych.
5. Zapis iteracji i raportowanie tworzą audytowalny ślad decyzyjny, kluczowy dla budowania zaufania do narzędzi AI w logistyce wojskowej.

Dalsze badania powinny objąć rozszerzenie danych (większa ilość parametrów wejściowych interfejsu użytkownika), analizę odporności na zmianę rozkładu (ang. concept drift) oraz integrację z modułami optymalizacji wielokryterialnej i uczenia ze wzmocnieniem dla automatyzacji generowania wariantów działania przy zachowaniu nadrzędnej roli decydenta.

W ujęciu strategicznym niniejsza praca przybliży realizację koncepcji systemowego wspomaganie decyzji logistycznych przedstawionej w [2]. Udowodniono wykonalność podejścia modułowego: predykcja + wariantowanie + alertowanie + audyt. Kolejnym krokiem jest skalowanie rozwiązania na inne obszary logistyki oraz wpięcie modułów analitycznych w jednolitą architekturę danych opartą o ZWSI RON. Dzięki temu możliwe będzie budowanie wspólnego obrazu sytuacji logistycznej i spójnych rekomendacji na wszystkich poziomach zarządzania, w warunkach pokoju, kryzysu lub wojny.

## 16. WYKAZ PUBLIKACJI STANOWIĄCA PODSTAWĘ ROZPRAWY DOKTORSKIEJ

- [1] Kępczyński A., *Application of machine learning in the process of commander decision support in the military fuel distribution system*, Archives of Thermodynamics, Vol. 46(2025), No. 4, 201–214; doi: 10.24425/ather.2025.156850
- [2] Kępczyński A., *Model wspomagania procesu decyzyjnego na potrzeby zapewnienia energii dla Sił Zbrojnych. Zarządzanie zasobami paliw w SZ*, Warszawa: Wydawnictwo ITWL 2024, rozdział w monografii
- [3] Prokopowicz W., Kępczyński A., *Zastosowanie sieci neuronowych do modelowania procesów decyzyjnych w wojskowym systemie dystrybucji paliw*, Warszawa: Wydawnictwo ITWL, 2024, rozdział w monografii
- [4] Łukowski D., Kępczyński A., *Transformacja energetyczna – wyzwania dla sił zbrojnych*, Warszawa: Wydawnictwo ITWL, 2024, rozdział w monografii
- [5] Kępczyński A., Stępień S., *Optymalizacja i wspomaganie AI w logistyce wojskowej*, Warszawa: Wydawnictwo ITWL, 2024
- [6] Kępczyński A., Lisowski G., Prokopowicz W., Stępień S., *Metody adaptacyjne w logistyce energii wojsk*, Zmiany w procesie kształcenia specjalistów służby czołgowo-samochodowej oraz wybrane zagadnienia dotyczące służby pp, 20-28. Warszawa: Wydawnictwo AWiR AKCES SUKCES-SPORT, 2023

[2,3,4,5] Monografia: *Perspektywy logistyki wojskowej i cywilnej w kontekście zapewnienia odporności Siłom Zbrojnym* (konferencja Bydgoszcz) 2024, Tom 1.

## 17. LITERATURA

- Abadicio, M., (2019), Artificial Intelligence for Military Logistics – Current Applications, Źródło internet: <https://emerj.com/ai-sector-overviews/artificial-intelligence-military-logistics/> wejście 12.02.2024r.
- AI-Enabled Military Logistics Optimization, <https://aimlprogramming.com/download/pdf/ai-driven-military-logistics-optimization-1711076231.pdf>
- Alasmari, T., & Alzahrani, A. (2025). Saudi Arabia's shifts towards green and sustainable logistics: Bibliometric and machine learning-based insights and forecasts. *Journal of Cleaner Production*. <https://doi.org/10.1016/j.jclepro.2025.145577>
- Allied Joint Doctrine for NATO Asset Visibility - AJP-4.11. 21.02.2011r.
- Andrych-Zalewska et al (2023) Impact of the Internal Combustion Engine Thermal State on Fuel Consumption and Emissions during Cold Start. <https://www.mdpi.com/1996-1073/16/4/1937>
- Atallah R. F., Assi C. M. and Khabbaz M. J., 2022, Scheduling the Operation of a Connected Vehicular Network Using Deep Reinforcement Learning, Elsevier Science Publishers B. V. Netherlands, nr 33
- Bach F., 2017, Breaking the curse of dimensionality with convex neural networks, *Journal of Machine Learning Research*, JMLR.org, nr 18, s. 1-53
- Bielaczyc et al (2011) *The effect of a low ambient temperature on the cold-start emissions and fuel consumption of passenger cars*. <https://www.researchgate.net/publication/258177726>
- British Army; British Army Approach to Battlefield Electrification; <https://www.army.mod.uk/media/17010/british-army-approach-to-battlefield-electrification.pdf>
- Burden, F. R., & Winkler, D. A. (2008). Bayesian regularization of neural networks. *Methods in Molecular Biology*, 458, 25–44. <https://doi.org/10.1007/978-1-60327-101-1-3>
- Burke S., (2011), Energy for the Warfighter: the DoD Operational Energy Strategy, Assistant Secretary of Defense, Operational Energy Plans and Programs, U.S. Department of Defense
- Burke S., (2012), Operational Energy Strategy: Implementation Plan, Assistant Secretary of Defense, Operational Energy Plans and Programs, U.S. Department of Defense; [https://www.acq.osd.mil/eie/Downloads/OE/20120306\\_OE\\_Strategy\\_Implementation\\_Plan.pdf](https://www.acq.osd.mil/eie/Downloads/OE/20120306_OE_Strategy_Implementation_Plan.pdf)
- Cheng S., Wang Z., Yang B., Nakano K., 2022, Convolutional Neural Network-Based Intelligent Decision-Making for Automated Vehicles, *IFAC-PapersOnLine*, nr 55, s. 509–514
- Chong E., Żak S., (2001), An Introduction to Optimization, John Wiley & Sons
- Decyzja nr 8/MON z dnia 20.01.2012 r. w sprawie dopuszczenia do eksploatacji Zintegrowanego Wieloszczeblowego Systemu Informatycznego Resortu Obrony Narodowej (ZWSI RON) w jednostkach budżetowych resortu obrony narodowej.
- Doktryna Logistyczna Sił Zbrojnych RP D-4(B) Szkol. 965/2019.

- Deep Learning and Neural Networks: Decision-Making Implications, H. Taherdoost, <https://www.mdpi.com/journal/symmetry>, (dostęp 10.03.2024 r.)
- Duque S., Mauricio E., Giraldo S. i inni, 2022, Community energy storage operation via reinforcement learning with eligibility traces, *Electric Power Systems Research*, nr 212
- Eichenseer, P., Hans, L., & Winkler, H. (2024). A data-driven machine learning model for forecasting delivery positions in logistics for workforce planning. *Smart Computing and Applications*. <https://doi.org/10.1016/j.sca.2024.100099>
- Energy & the Military: Convergence of Security, Economic and Environmental Decisionmaking <https://www.eprg.group.cam.ac.uk/wp-content/uploads/2017/11/1717-Text.pdf>, wejście 13.01.2024.
- Future of army logistics exploiting ai overcoming challenges and charting the course ahead wejście: 20.02.2024.
- Ficoń, K. (2006). *Badania operacyjne stosowane. Modele i aplikacje*. Warszawa: Wydawnictwo BEL STUDIO.
- Ficoń K., Krasnodębski G. (2018), Nowoczesne technologie logistyczne jako źródło dodatkowych wartości w łańcuchu dostaw, *Systemy Logistyczne Wojsk* nr 48/2018
- Fletcher, R. (1970). A new approach to variable metric algorithms. *The Computer Journal*, 13(3), 317–322. <https://doi.org/10.1093/comjnl/13.3.317>
- François-Lavet V., Fonteneau R., Ernst D., (2018), An Introduction to Deep Reinforcement Learning, *Foundations and Trends in Machine Learning*, nr 11, s. 219–354
- Groß, A., Friedland, J., & Schwenker, F. (2008). Learning to play Tetris applying reinforcement learning methods. University of Ulm – Institute of Neural Information Processing, Ulm, Germany.
- Hagan, M. T., & Menhaj, M. B. (1994). Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks*, 5(6), 989–993, <https://doi.org/10.1109/72.329697>
- Instrukcja o gospodarce materiałowej służby materiałów pędnych i smarów (DU4.21.3), MON/IWspSZ. Warszawa 2019.
- Jałowiec T. (2021), Logistyka wojskowa – od nauk wojskowych do nauk o zarządzaniu i jakości, *Systemy Logistyczne Wojsk*, Zeszyt 55
- Kaelbling, L., Littman P., Michael. L., Moore, A. W. (1996). Reinforcement learning: A survey. *Journal of Artificial Intelligence Research*, 4, 237–285
- Kaliszewski I. *Wielokryterialne podejmowanie decyzji*. Wydawnictwo Naukowo Techniczne, Warszawa 2008
- Kayri, M. (2016). Predictive abilities of Bayesian regularization and Levenberg–Marquardt algorithms in artificial neural networks: A comparative empirical study on social data. *Mathematical and Computational Applications*. <https://www.researchgate.net/publication/303522181>
- Kępczyński A., *Application of machine learning in the process of commander decision support in the military fuel distribution system*, *Archives of Thermodynamics*, Vol. 46(2025), No. 4, 201–214; doi: 10.24425/ather.2025.156850

- Kępczyński, A. (2024). Model wspomaganie procesu decyzyjnego na potrzeby zapewnienia energii Siłom Zbrojnym. W: *Perspektywy logistyki wojskowej i cywilnej w kontekście zapewnienia odporności Siłom Zbrojnym* (konferencja), Bydgoszcz
- Kępczyński, A., Stępień, S. (2024). Optymalizacja i wspomaganie AI w logistyce wojskowej. W: *Perspektywy logistyki wojskowej i cywilnej w kontekście zapewnienia odporności Siłom Zbrojnym* (konferencja), Bydgoszcz
- Kępczyński A., Prokopowicz W., Stępień S., Aerostaty w obronie infrastruktury energetycznej, *Nauka dla obronności: Siły powietrzne w obronie energetycznej infrastruktury krytycznej*. Warszawa: Wydawnictwo Instytutu Technicznego Wojsk Lotniczych, 2023.
- Kępczyński A., Lisowski G., Prokopowicz W., Stępień S., Metody adaptacyjne w logistyce energii wojsk, W: *Zmiany w procesie kształcenia specjalistów służby czołgowo-samochodowej oraz wybrane zagadnienia dotyczące służby* s. 20-28. Warszawa: Wydawnictwo AWiR AKCES SUKCES-SPORT, 2023
- Kidd, R. (2012), Army Energy and Sustainability Program, U.S. Army, presentation, <https://www.asaie.army.mil/Public/ES/doc/2-General%20Presentation.pdf>
- Komisja Europejska, Energia Zielony Ład; [https://commission.europa.eu/strategy-and-policy/priorities-2019-2024/european-green-deal/energy-and-green-deal\\_pl](https://commission.europa.eu/strategy-and-policy/priorities-2019-2024/european-green-deal/energy-and-green-deal_pl)
- Kress M. (2002), OPERATIONAL LOGISTICS The Art and Science of Sustaining Military Operations, Springer Science + Business Media New York
- Kwiatkowski L., 2011, Podejmowanie decyzji. 5 kroków do lepszych wyników, Wydawnictwo MT Biznes Sp. z o.o., Warszawa
- Lacroix E. B. (2023) Future of Army Logistics | Exploiting AI, Overcoming Challenges, and Charting the Course Ahead, Źródło Internet: <https://www.army.mil/article/267692/>
- Lee S., Moore, D., (2023), US Army's Electric Tanks on Hold as Battery Technology Develops, <https://news.bloomberglaw.com/environment-andenergy/us-armys-electric-tanks-on-hold-as-battery-technology-develops>
- Li S., Reinforcement Learning for Sequential Decision and Optimal Control (First ed.). 2023, Springer, Verlag
- Li J., Yin G., Wang X., Yan W., 2022, Automated decision making in highway pavement preventive maintenance based on deep learning, *Automation in Construction*, Elsevier B.V., nr 135
- Liang, Y. Y., Shahabuddin, M., Ahmed, S. F., Tan, J. X., & Ali, S. M. (2025). Optimizing sustainable aviation fuel supply chains: Challenges, mitigation strategies and modeling advances. *Fuel*. <https://doi.org/10.1016/j.fuel.2025.135972>
- Łukowski D., Znaczenie surowców energetycznych i źródeł energii w Siłach Zbrojnych, *Nauka dla obronności i środowiska*, Wydawnictwo ITWL, 2020
- Łukowski D., Kępczyński A., Transformacja energetyczna – wyzwania dla sił zbrojnych, Warszawa: Wydawnictwo ITWL, 2024, rozdział w monografii
- Marciniak M., Jakusz T., Sieciocentryczność, czyli optymalizacja wykorzystania posiadanego potencjału. *Nowa Technika Wojskowa* 10/2019

- Machi V., (2022), Vehicle makers court Europe's militaries with hybrid, electric rides; <https://www.defensenews.com/global/europe/2022/06/25/vehicle-makers-court-europes-militaries-with-hybrid-electric-rides/>
- Maze, R. (2022), AUSA; Power Hungry: Feeding growing requirements for energy on the battlefield; <https://www.ausa.org/articles/power-hungry-feeding-growing-requirements-energy-battlefield>
- Metale ziem rzadkich. Te państwa mają największe złoża na świecie. <https://for-sal.pl/biznes/przemysl/artykuly/8637418,metale-ziem-rzadkich-najwieksze-zloza-na-swiecie.html>
- Models and Tools for Logistics Analysis, STO TECHNICAL REPORT, TRSAS-132, July 2020 [www.bbn.gov.pl/pl/wydarzenia](http://www.bbn.gov.pl/pl/wydarzenia)
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., Graves, A., Riedmiller, M., Fidjeland, A. K., & Ostrovski, G. (2015). Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529–533.
- NATO 2030: United for a New Era, Analysis and Recommendations of the Reflection Group Appointed by the NATO Secretary General, 25 November 2020; [https://www.nato.int/nato\\_static\\_fl2014/assets/pdf/2020/12/pdf/201201-Reflection-Group-Final-Report-Uni.pdf](https://www.nato.int/nato_static_fl2014/assets/pdf/2020/12/pdf/201201-Reflection-Group-Final-Report-Uni.pdf)
- NATO Decision-Making in the Age of Big Data and Artificial Intelligence, Editors: Sonia Lucarelli; Alessandro Marrone; and Francesco Niccolò Moro, 2021 NATO HQ - Boulevard Léopold III, 1110 Brussels – Belgium
- Neural Network Toolbox User's Guide, The MathWorks, Inc., 1992 – 2004, [http://cda.psych.uiuc.edu/matlab\\_pdf/nnet.pdf](http://cda.psych.uiuc.edu/matlab_pdf/nnet.pdf)
- Newton, E. (2023), How does the U.S. Military Rely on Renewable Energy, <https://www.renewableenergymagazine.com/emily-newton/how-does-the-us-military-rely-20230222>
- Nguyen, S., Gadel, M., Wang, K., Li, J., Zhang, X., Kong, S.-C., Fu, X., & Qin, Z. (2025). Maritime decarbonization through machine learning: A critical systematic review of fuel and power prediction models. *Cleaner Logistics and Supply Chain* <https://doi.org/10.1016/j.clscn.2025.100210>
- Nowakowski T., Niezawodność systemów logistycznych, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2011
- Otterlo van M., Wiering M., 2012, Reinforcement Learning and Markov Decision Processes, Springer, Berlin, Heidelberg
- Parlament Europejski; Fit for 55: deal on new EU rules for cleaner maritime fuels; <https://www.europarl.europa.eu/news/pl/press-room/20230320IPR77909/fit-for-55-deal-on-new-eu-rules-for-cleaner-maritime-fuels>
- Pawlisiak M., System logistyczny Sił Zbrojnych Rzeczypospolitej Polskiej. Teoria i praktyka. Toruń 2021 Wydawnictwo Adam Marszałek
- Peters J., Vijayakumar S., Schaal S., Reinforcement Learning for Humanoid Robotic, International Conference on Humanoid Robots, , <https://homepages.inf.ed.ac.uk/svijayak/publications>, (dostęp 17.03.2024)
- Plasan North America, Dod's push to electrify the battlefield is creating electricity demand problem sit is not solving;

- <https://breakingdefense.com/2022/08/dodspush-to-electrify-the-battlefield-is-creating-electricity-demand-problems-it-is-not-solving/>
- Powering the U.S. Army of the future (2021), A Consensus Study Report of the National Academies of Sciences, Engineering, Medicine; The National Academies Press; Washington DC; <http://nap.nationalacademies.org/26052>
- Powierża L., Elementy inżynierii systemów. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 1997
- Prokopowicz, W., & Kępczyński, A. (2024). Zastosowanie sieci neuronowych do modelowania procesów decyzyjnych w wojskowym systemie dystrybucji paliw. W: Perspektywy logistyki wojskowej i cywilnej w kontekście zapewnienia odporności Siłom Zbrojnym (konferencja), Bydgoszcz.
- Przemieniecki, J., (2000), Mathematical Methods in Defense Analyses, American Institute of Aeronautics and Astronautics
- Russell J., Norvig P., 2011, Artificial intelligence: a modern approach (Third ed.). Upper Saddle River, New Jersey
- Riedmiller, M., & Braun, H. (1993). A direct adaptive method for faster backpropagation learning: The RPROP algorithm. Proceedings of the *IEEE International Conference on Neural Networks*, 1, 586–591.  
<https://doi.org/10.1109/ICNN.1993.298623>
- Saber, Al-Barwari, Talabany, (2013) *Effect of Ambient Air Temperature on Specific Fuel Consumption of Naturally Aspirated Diesel Engine*. Journal of Science and Engineering Vol. 1 (1), 2013, 1-7. <https://www.scribd.com/document/133228366/>
- Samaras, C., Nuttall, W., J., Bazilian, M., (2019), Energy and the military: converge of security, economic, and environmental decision making. Energy Strategy Reviews, Volume 26
- Sariev, E. (2020). Bayesian regularized artificial neural networks for the estimation of the probability of default. *Quantitative Finance*.  
<https://doi.org/10.1080/14697688.2019.1633014>
- Schmidt A., 1996, A Modular Neural Network Architecture with Additional Generalization Abilities for High Dimensional Input Vectors, Manchester Metropolitan University, Department of Computing, Manchester
- Shaiju, A.J., Petersen I.R., (2008), Formulas for discrete time LQR, LQG, LEQG and minimax LQG optimal control problems. IFAC Proceedings Volumes. Elsevier. 41 (2): 8773–8778, doi:10.3182/20080706-5-KR-1001.01483.
- SI LOGFAS (Logistic Function Area Services) wprowadzony decyzją MON w 2017r. (DU-4.11.1).
- Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., Van Den Driessche, G., Schrittwieser, J., Antonoglou, I., Panneershelvam, V., Lanctot, M., et al. 2016, Mastering the game of go with deep neural networks and tree search, Nature, Macmillan Publishers Limited, NY, nr 529, s. 484–489
- Simple Reinforcement Learning with Tensorflow Part 8: Asynchronous Actor-Critic Agents (A3C), Juliani A., <https://medium.com/emergent-future/simple-reinforcement-learning-with-tensorflow-part-8-asynchronous-actor-critic-agents-a3c-c88f72a5e9f2>, (dostęp 17.03.2024)

- Stevens, M., & Pradhan, S. (2016). Playing Tetris with deep reinforcement learning. Stanford University. [https://cs231n.stanford.edu/reports/2016/pdfs/121\\_Report.pdf](https://cs231n.stanford.edu/reports/2016/pdfs/121_Report.pdf)
- Sutton S., Barto A. G., 2012, Reinforcement Learning: An Introduction, The MIT Press Cambridge, Massachusetts London
- System informatyczny LOGFAS. Zasady funkcjonowania w resorcie obrony narodowej, DU-4.11.1(A) Logis 54/2024.
- Trung Luu Q, Q-Learning vs. Deep Q-Learning vs. Deep Q-Network, <https://www.baeldung.com/cs/qlearning-vs-deep-q-learning-vs-deep-q-network>, (dostęp 10.03.2024)
- U.S. Energy Information Administration, 2013, Few Transportation Fuels Surpass the Energy Densities of Gasoline and Diesel, <https://www.eia.gov/to-dayinenergy/detail.php?id=9991>
- Xuefei H., Seung HH., i inni, 2017, Demand Response Management for Industrial Facilities: A Deep Reinforcement Learning Approach, School of Computer Science and Engineering, Tianjin University of Technology, Tianjin, China 2 Department of Electronic Engineering, Hanyang University, Ansan, Republic of Korea
- Yaiprasert, C., & Hidayanto, A. N. (2023). AI-powered ensemble machine learning to optimize cost strategies in logistics business. *International Journal of Industrial and Manufacturing Engineering*. <https://doi.org/10.1016/j.ijime.2023.100209>
- Wierzbicki A.P., Teoria i praktyka wspomaganie decyzji, Wydawnictwa Uniwersytetu Warszawskiego, Warszawa 2018
- Williams R., 1987, A class of gradient-estimating algorithms for reinforcement learning in neural networks, Proceedings of the IEEE First International Conference on Neural Networks, Kluwer Academic Publishers, Boston, s. 230
- Zhou, J., Yang, C., Liu, D., Wang, Y., Zhong, Z., & Wu, Y. (2025). A three-stage geospatial network optimal location decision model for urban green logistics centers from a sustainable perspective. *Sustainable Cities and Society*. <https://doi.org/10.1016/j.scs.2025.106481>

## 18. WYKAZ DOROBKU NAUKOWEGO, ORGANIZACYJNEGO I INNYCH OSIĄGNIĘĆ

1. International Conference on Cleaner Energy Transition (ICCET 2024), *Energy transformation – challenges to armed forces*, Kraków, 21-23.10.2024r. **Wystąpienie**
2. International Armament Congress, *Inspektorate for Armed Forces Support – tasks and mission*, Kraków, 21-25.10.2024r. **Wystąpienie**
3. Korean ASEAN International Forum on Logistics, *Polish Armed Forces, restructuring and development – logistic challenges*, Korea Płd, 2-6.10.2024r. **Wystąpienie**
4. Konferencja Naukowo-Techniczna nt. „Perspektywy logistyki wojskowej i cywilnej w kontekście zapewnienia odporności energetycznej Siłom Zbrojnym”, *Model wspomagania procesu decyzyjnego na potrzeby zapewnienia energii dla Sił Zbrojnych*, Bydgoszcz, 12-14.06.2024r. **Wystąpienie. Współorganizator, członek Komitetu Inicjującego, Autor/współautor artykułów**
5. I Kongres Naukowy Logistyki Wojskowej - **współprzewodniczący Komitetu Naukowego**. Podejmowana problematyka rozpatrywana w oparciu o prezentację wyników badań zespołu autorskiego publikacji *System Logistyczny Sił Zbrojnych Rzeczypospolitej Polskiej – Raport 2024*. **Redaktorami naukowymi** raportu są: Szymon Mitkow, Marek Bodziany, Tomasz Jałowiec, **Artur Kępczyński**, Andrzej Lis, Bartłomiej Pączek, Mariusz Skulimowski i Krzysztof Urban, Warszawa, 6.06.2024r.
6. Symposium nt. Transformacja i modernizacja Sił Zbrojnych RP – kierunki i wyzwania dla logistyki wojskowej. **Honorowy patronat i współprzewodnictwo** (organizacja i udział: ASzWoj, WAT, AWL, LAW, AMW i IWspSZ), Bydgoszcz, 15.03.2024r.
7. Symposium Naukowe nt. „Kształcenie kadr w korpusie osobowym logistyki na potrzeby Sił Zbrojnych RP – aktualne wymagania i perspektywy” **Współprzewodnictwo w części dyskusyjnej**, Dęblin 8.12.2023r.
8. Konferencja ARMTECH w Juracie - **członek Rady Naukowo-Programowej**. Organizator WITU, 18-20.09.2023r.

9. Debata Strategiczna Biura Bezpieczeństwa Narodowego podczas XXXI Międzynarodowego Salonu Przemysłu Obronnego. nt. Logistyka Polskich Sił Zbrojnych. – **udział ekspercki w panelu dyskusyjnym**, Kielce, 7.09.2023r.
10. XIV KONFECRENCJA NAUKOWA LOGISTYKI STOSOWANEJ. Technologie podwójnego zastosowania w obszarze logistyki wojskowej i cywilnej. Teoria i praktyka. KNLS'23 organizowany przez WAT i ITS , **Członek Komitetu Naukowego**, Toruń, 30.05–1.06 2023r.
11. V edycja Defence24 DAY 2023 – **udział ekspercki w panelu dyskusyjnym** zatytułowanym: „Wojna na Ukrainie – wnioski dla rozwoju i modernizacji Sił Zbrojnych”, 24-25 maja 2023r.
12. Międzynarodowa konferencja „Redefinicja łańcuchów logistycznych w świetle nowej polityki transportowej TEN-T”. Centrum Nauki Kopernik w Warszawie. **Udział ekspercki w panelu dyskusyjnym** nt. „Znaczenie transportu kolejowego dla sprawnych łańcuchów logistycznych w korytarzach sieci TEN-T”, 14 lutego 2023r.
13. XII Konferencja Naukowa Logistyki Stosowanej. **Wystąpienie podczas panelu wojskowego** nt. terytorialnego systemu zabezpieczenia logistycznego w latach dwudziestych XXI wieku, Wojskowa Akademia Techniczna (WAT), 26.11.2021r.

## **19. PUBLIKACJE STANOWIĄ PODSTAWĘ MERYTO- RYCZNĄ ROZPRAWY DOKTORSKIEJ**

**PUBLIKACJA [1]**

- [1]. Kępczyński A., Application of machine learning in the process of commander decision support in the military fuel distribution system, Archives of Thermodynamics, Vol. 46(2025), No. 4, 201–214; doi: 10.24425/ather.2025.156850

# Application of machine learning in the process of commander decision support in the military fuel distribution system

Artur Kępczyński

General Command of the Armed Force, Polish Armed Forces  
Author email: artur.kep90@gmail.com

Received: 01.09.2025; revised: 03.12.2025; accepted: 30.12.2025

## Abstract

Providing energy to troops requires maintaining optimal fuel levels across all management stages, especially within Garrison Support Units and Regional Logistic Bases. The article examines the fuel distribution system supported by a program that predicts commanders' actions using input data from subordinate units. To aid decision-making, Garrison Support Units implemented neural network variants to model logistical activities, training, peacetime operations, or combat, and segment fuel supply accordingly. The Neural Network Toolbox from MATLAB (MathWorks) was used for computations. The study presents the Garrison Support Units operational assumptions, the role of commanders as agents, and factors affecting fuel distribution. It also outlines the development of the Logistic Decision Support System dashboard, which enables entering decision variables, neural network coefficients, and weights to forecast fuel consumption and plan future operations based on environmental and operational data. The article includes MATLAB simulation results, analysing neural network algorithms and neuron counts per layer to determine the most effective configuration for decision-making optimisation. Results show that the Bayesian regularisation algorithm achieved the lowest mean square error across all data sets and the highest prediction accuracy measured by the root mean squared error. The regression coefficient confirmed a strong correlation between predicted and actual outcomes, demonstrating the Bayesian regularisation algorithm's effectiveness in supporting logistical fuel management decisions.

**Keywords:** Machine learning, Root mean squared error; Bayesian regularisation

Vol. 46(2025), No. 4, 201–214; doi: 10.24425/ather.2025.156850

Cite this manuscript as: Kępczyński, A. (2025). Application of machine learning in the process of commander decision support in the military fuel distribution system. *Archives of Thermodynamics*, 46(4), 201–213.

## 1. Introduction

The increasing complexity of fuel supply chains and the pressure for resilience, efficiency and environmental sustainability mean that artificial intelligence and machine learning (ML) methods are rapidly being adopted in logistics (including military). In the literature of recent years, there has been a clear shift from classic optimisation problems to predictive analytics, integration of heterogeneous data, and models supporting short-term

operational decisions. This is particularly important in the context of the military fuel distribution system, where the commander's decisions are burdened by demand uncertainty, infrastructure constraints, and spatio-temporal dynamics. The concept of a modular Logistic Decision Support System (LDSS) adopted in this paper, based on multilayer neural networks and the selection of learning algorithms such as Bayesian regularisation, Levenberg-Marquardt (LM), Broyden-Fletcher-Goldfarb-Shanno (BFGS) quasi-Newton, or resilient backpropaga-

## Nomenclature

BR – Bayesian regularisation  
 GSU – Garrison Support Unit  
 LDSS – Logistic Decision Support System  
 MATLAB – Matrix Laboratory

ML – machine learning  
 MSE – mean square error  
 R – regression coefficient  
 RLB – Regional Logistic Base  
 RMSE – root mean squared error

tion (RP), remains consistent with the directions observed in research from practical implementations of short-term prediction to critical reviews of data quality, standardisation and model reliability.

The article aims to research the application of an artificial intelligence algorithm to support decision-making processes in the management of fuel resources, based on the adopted model of elements of the military logistics system. When starting the research, previous publications [1–4] characterised the logistics space within a selected scope. The need to develop solutions supporting the decision-making process of the commander (decision-maker) based on machine learning algorithms was indicated, including Broyden–Fletcher–Goldfarb–Shanno quasi-Newton, Levenberg–Marquardt, Bayesian regularisation and the resilient backpropagation algorithm.

The innovative nature of the article is manifested, among other things, by the fact that variables that have not been collected in the IT logistics system so far are indicated, as well as the method of developing the architecture of the LDSS program for implementation. The author indicated a number of dependent variables that he detected while working with the data that were analysed, namely the indicated fuel level in the Garrison Support Unit (GSU), the intensity of operations, field data, meteorological data or variables illustrating the capabilities of GSU.

The proposed model of support for the decision-making process in the fuel distribution system is based on a neural network, for which the basic input parameters and initial states of the system have been indicated, limited only to fuel distribution. The model of the modular multi-layered one-way neural network (MNN) seems to be the solution with a small and acceptable error to provide courses of action for the management staff in the indicated positions of the military logistics system. Nevertheless, in order for the indicated information technology (IT) solution to be effective, the artificial intelligence (AI) system must be taught through the experience of decision-makers and historical data, in order to present several optimal variants of fuel resource management. Finally, the thesis in which the reinforcement learning (RL) model improves the quality and accelerates the process of developing an appropriate variant of the decision-maker's action was analysed.

Bibliometric studies of logistics in Saudi Arabia [5] synthetically show the global shift towards sustainable logistics, machine learning, and the integration of technology (AI, blockchain) into traditional supply chain paradigms. The authors, analysing over 7.6 thousand publications, identify the growing importance of chain resilience and international cooperation as an accelerator of innovation. These conclusions are relevant for military logistics: the development of predictive and decision-making capabilities in the fuel system requires combining clas-

sic procedures with machine learning (ML) models and connecting multi-domain data (operational, environmental, infrastructural), which directly corresponds to the concept adopted in this paper of extending the input vectors of the network to include meteorological, terrain and operational factors.

A strong practical trend is represented by the work of Eichenseer et al. [6], in which a data-driven ML model for a five-day forecast of the number of "delivery positions" for workforce planning in logistics was developed and validated. The model, tested in the company, exceeded both practical expert forecasts and auto ML systems, especially in the short term. The value of models tailored to the specifics of the process (custom ML) in relation to universal tools is a key here from the perspective of the military GSU. This approach reinforces the decision to use a specialised multilayer perceptron (MLP) architecture in LDSS and to select training algorithms for generalisation stability with limited samples and strong operational variability. A five working days forecast horizon (week) seems to be a natural "decision window" for fuel distribution planning and personnel dispatch.

For this article, several literature items were analysed, where, among others, Nguyen et al. [7] present a critical review of ML models for estimating propulsion power and fuel consumption of marine vessels, an area inherently related to fuel and energy (power) prediction (FEP) and exposed to environmental disturbances. The authors emphasise the need for "data-centric AI": standardisation of metrics (beyond mere accuracy), benchmarks, and policies for maintaining trustworthiness in models. For military applications, this means the need to:

- a) unambiguous definition of quality measures (root mean squared error/mean square error (RMSE/MSE), regression coefficient (R), but also resistance to regime changes and out-of-distribution),
- b) monitoring of procedures and re-training,
- c) documenting data and model decisions (auditability), which in this article is reflected in the adopted set of metrics and comparisons of BR/LM/BFGS/RP algorithms and the conclusion about the advantage of research and development (R&D) in terms of generalisation.

The cost and decision perspective in commercial logistics was developed by Yaiprasert and Hidayanto [8], who used ensembles of ML methods to explore cost strategies on simulated data. Despite the synthetic nature of the collection, the paper shows two lessons useful for LDSS:

- a) ensembles increase predictive resilience to data variance and heterogeneity in operational conditions,
- b) It is possible to use simulations to "seal" sparse regions of the state space, which is important when real data (e.g., intensity of activities, procedural constraints) are not yet fully collected in departmental systems.

This approach can complement a trained MLP network with a simulation component or an MLP + ensemble hybrid for critical inventory thresholds.

Zhou et al. [9], on the other hand, propose a three-stage geoinformation model, geospatial information system (GIS), multiple-criteria decision making / multiple-criteria decision analysis (MCDM), or social network analysis (SNA) network, for the selection of locations for urban green logistics centres. Despite the civilian context, the construction of the method (combining environmental, economic, technological, and social criteria with network analysis) is analogous to the needs of military planning for the deployment of depots and GSU in operational space.

Finally, a broad overview of sustainable aviation fuel (SAF) supply chains by Liang et al. [10] highlights that the energy transition in transportation requires a combination of mathematical programming, ML and multi-criteria optimisation. The identified barriers: cost, complexity of multi-stage production, instability of raw material supply and regulatory discrepancies, translate into military implications:

- a) the need to take alternative fuels scenarios into account in planning (compatibility, availability, chain risk),
- b) expansion of the decision-making module with multi-criteria functions (cost-risk-environmental footprint-operational readiness),
- c) tracking policies and standards, which support the approach to building an LDSS decision-making dashboard with weights and ratios reflecting operational priorities.

In conclusion, the literature confirms the three pillars adopted in this work. First, short-term prediction on operational data (Eichenseer et al. [6]) is a key component of resource planning and should be the core of the GSU commander's support module; the choice of training algorithms with good generalisation with limited samples (Bayesian regularisation) is methodologically justified and, in our experiments brings the best compromise of accuracy/robustness, which has been demonstrated empirically. Secondly, the integration of spatial and multi-criteria data (Zhou et al. [9]) indicates that the extension of LDSS to include the GIS/MCDM/SNA component will support decisions on inventory manoeuvre and supply priorities under conditions of infrastructural and environmental constraints. Third, the trend towards sustainability and resilience (Alasmari and Alzahrani [5], Liang et al. [10]) requires that decision-making tools take into account both performance metrics (RMSE, MSE, R) and chain risk and environmental impact criteria, while maintaining the principles of "data-centric AI" and model transparency (Nguyen et al. [7]). In this context, the LDSS module, which is being developed and is based on MLP and enriched with regularisation, validation and monitoring mechanisms, is a way to authenticate operational recommendations for the GSU decision-maker, in accordance with the literature.

## 2. Description of the research problem

The research focused on mapping the logistics space with which agents can interact with the indication of states and transitions between individual layers of the network dedicated to the selected GSU. The agent is the commander of the selected GSU

(in our solution, we assume only one decision-making level for simplicity). He observes the changing situation of fuel security in a given area of responsibility, introducing GSU into the states through actions (decisions). The operational situation in a given area of responsibility complements the environment of operations. Actions that can be taken by the decision-maker are: receiving, dispensing, or withholding the dispensing of fuel.

The decision-maker performs actions to maintain the fuel at the required level in the unit's tanks. The agent has limited transportation resources, is constrained by the load capacity of the supplied units, and must also deliver fuel within the timeframe specified in the demand of a given military unit. The time in the proposed model is discrete, and a training set based on data from five years of GSU operation was used for prediction. Then, 70% of the data was used for training the network; 15% of all data was used to validate the network for generalisation and to stop the training process before overfitting occurred, and a further 15% was used as a test set to independently assess the network's ability to generalise.

The time is discrete, and one week of fuel management in the GSU has been taken as the time step. The prediction of fuel distribution and decision-maker actions was set ten months ahead. The purpose of the program in the MATLAB environment is to train the neural network in such a way that it is able to reduce the mean square error of the deviation of real values from those predicted in the network training process as much as possible. For the purpose of studying the degree of mapping of the prediction results of the GSU input variables, the parameters of the neural network were introduced, such as the number of neurons in the network layers and the function according to which the training was conducted. As a parameter that was predicted, it was a series of fuel level data in the GSU. In subsequent tests for the LDSS commander's desktop, the number of predicted parameters (e.g. intensity of operations, number of available personnel, availability of equipment, etc.) should be increased simultaneously on the basis of the input data. The neural network learning process involves appropriately adjusting the weights between neuronal connections in the network layers to minimise errors and improve the quality of predictions. Reducing prediction errors can be achieved by using a feedback loop (Fig. 1) backpropagation, i.e. comparison of the obtained results with the desired values. The error calculated in this way leads to a weight correction to minimise this error in subsequent steps (iterations). These processes take place in the so-called epochs, and each epoch is a single passage through the entire set of learning data. The most important steps in the network training process are: initialisation of weights, feed forward, error calculation, backpropagation, updating of weights, and repeating the process in steps from 2 to 5 over many epochs. Thanks to these measures, the network becomes more and more accurate ("learns"), and its predictions are closer to the actual results. Finally, there is a process of completing learning after reaching a certain criterion, e.g. after reaching a satisfactory level of accuracy, in our case of mapping the prediction results, the parameters of the neural network were changed, such as: internal delays, feedback delay, number of epochs, the function according to which the training was carried out, and the size of hidden lay-

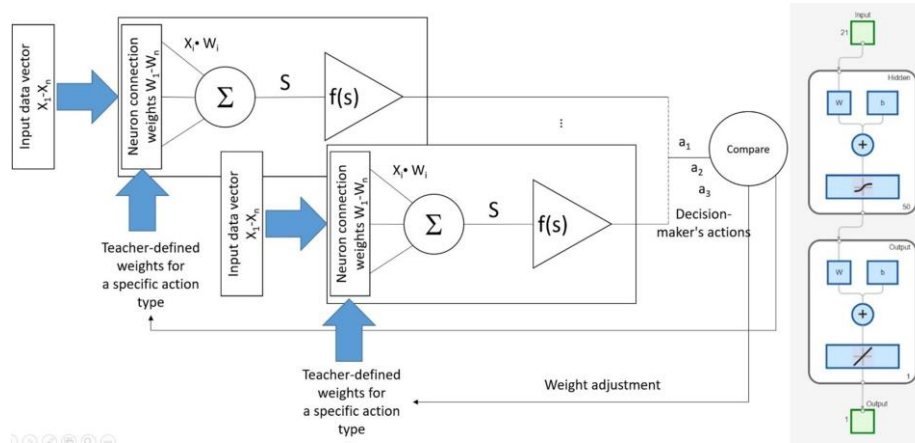


Fig. 1. Neural network model to predict fuel consumption for the selected GSU. The function according to which the network was trained was: Bayesian regularisation, Levenberg-Marquardt, BFGS quasi-Newton and resilient backpropagation.

ers. Below is a brief description of four algorithms used in the study.

### 2.1. Bayesian regularisation

A modification of a classical algorithm with feedback propagation that optimises both model fit and complexity by regularising weights. In this algorithm, the error function has two components – a matching error (MSE) and a penalty for heavy weights. The weights and regularisation parameter are estimated using Bayesian methods. It is known for high resistance to overfitting and excellent generalisation, especially with a large number of neurons, without needing separate cross-validation. However, it requires longer training times than non-regularised methods. This approach is chosen as a benchmark for the quality of generalisation. It is particularly effective when using many neurons and dealing with the risk of overtraining, which is important in studies with a network of 50 neurons in the hidden layer. It offers automatic selection of the regularisation parameter and reduces manual hyperparameter tuning [11].

### 2.2. Levenberg–Marquardt

An optimisation algorithm that is a hybrid of the Gauss–Newton method and gradient fall adjusts the learning step by switching seamlessly between the fast Gauss–Newtonian confluence (near the minimum) and the stability of the gradient method (far from the minimum). Its advantages are very fast convergence for small and medium-sized networks and high accuracy with a small number of neurons. High memory requirements. For large networks, it can become unstable or very slow. Widely recognised as the fastest algorithm for training small and medium-sized MLP networks. It handles regression problems and achieves low error in a small number of epochs very well. Ideal for comparison with BR in terms of trade-off of learning time vs. accuracy [12].

### 2.3. BFGS quasi–Newton

An advanced optimisation algorithm that approximates the inverse Hessian matrix (second-order derivatives) without fully

calculating it. Updates the Hessian approximation in each iteration, using gradient and weight changes. Its advantages include faster convergence than a pure straight gradient and good results for medium-sized networks and well-conditioned problems. However, it may lose efficiency with very large networks. High memory requirements. It was chosen as a classic, robust optimisation algorithm, allowing us to assess how it performs against newer and more adaptive methods [13].

### 2.4. Resilient backpropagation

A variation of backpropagation that ignores the size of a gradient based only on its character. A very stable algorithm in conditions where the gradient is scaled badly. Good for problems with large differences in input values. It does not use the gradient size information, so it can reach very low error values more slowly. A simple but effective gradient sign method. It is in contrast to methods that require calculations of the Hessian matrix or regularisation. In studies, it acts as a benchmark of stability at different numbers of neurons [14].

An important gap highlighted by the review authors (Nguyen et al. [7]) is the insufficient standardisation of data and benchmarks, and the lack of widely accepted measures of model confidence. In military conditions, this gap is reinforced by the limited availability of structured data on the intensity of operations, procedural constraints, or environmental parameters, which has also been identified in this study, and directly motivates the expansion of the range of collected input variables (21+ features) and the procedure for dividing the sets into training/validation/test. In addition, the literature indicates the potential for reinforcement learning (RL) for problems in which decisions and rewards are spaced over time; combined with an MLP network trained on historical data, RL can support fuel dispensing/halt-ing/receiving tactics, balancing exploration and exploitation in a dynamic environment, a direction that has been outlined as the next stage in LDSS development.

In light of the above, the GSU commander's decision support model proposed in the paper using the MLP architecture, BR/LM/BFGS/RP algorithms, an extended set of input features, and a dashboard module with weights and coefficients is in line

with the best practices identified in the literature, and responds to the key challenges:

- a) short-term prediction of demand and inventory levels,
- b) integration of multi-domain data (operational, environmental, infrastructural),
- c) transparency and standardisation of model evaluation,
- d) possibility of further hybridisation with RL and ensemble methods for resistance to data variability.

The states of the GSU logistics system were determined on the basis of historical observations from 2019–2023. It was assumed that the logistics system worked optimally and the agents acted in accordance with the adopted strategy. The number of times GSU was in a situation where the fuel level for GSU was adequate (Fig. 2) and was counted week by week.

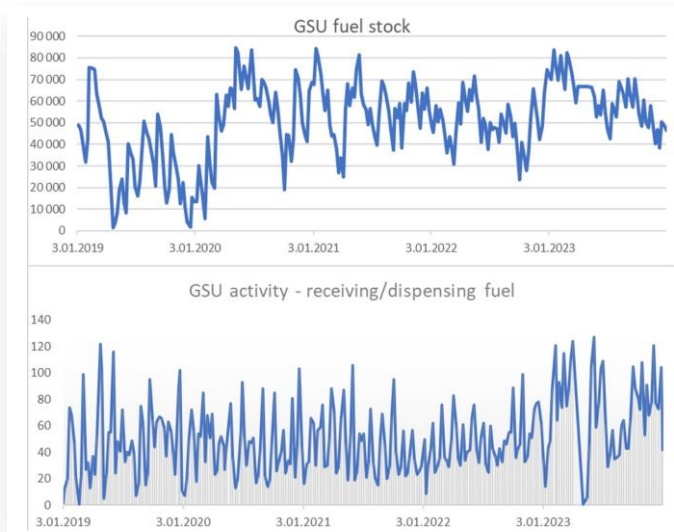


Fig. 2. Historical data on the state of diesel fuel levels and activity (fuel receiving/dispensing) in GSU in 2019–2023, every week (260 weeks – as of the first day of the week).

Using the collected historical data, it is possible to analyse changes in fuel levels for a selected fuel composition, GSU depot or a single storage facility. Changes in fuel levels reflect

many factors, such as the number and size of units supplied in a given area, their operational and training activity, or the ability to maintain and restore stocks. Therefore, the detailed information contained in the database of the Integrated Multi-Level IT System of the Ministry of National Defence (ZWSI RON – "Zintegrowany Wieloszczeblowy System Informatyczny Resortu Obrony Narodowej") on the change in the level of fuel stocks in the actual area and time for specific military units (MU) may constitute sensitive military data. While maintaining the overt nature of the study for analytical research, an "artificial" model was adopted, built from existing elements of the system, but in fact coming from various unrelated fuel supply regions. This model consists of a superior fuel depot in the Regional Logistic Base (RLB), GSU and three supplied MUs of different sizes: brigade, regiment and battalion (Fig. 3).

The task of GSU is to dispense fuel to MU in the amount and time in accordance with the demand. Of course, there are many factors affecting the quality and certainty of this task [1]. However, the basic element determining success or failure from the perspective of GSU is maintaining an appropriate level of fuel in the warehouses. Taking into account the specificity of peacetime military logistics, going below a certain minimum level should be considered a failure, even if this resource could still secure the reported needs of MU. This is related to the operational need to maintain the necessary reserves. Due to the need to manoeuvre the fuel resource between the internal GSU storage facilities, it is advisable not to exceed the specified maximum level of fuel storage capacity. Exceeding this level should be considered a failure, even if the storage capacity has not been fully used. We consider all activities leading to maintaining the state between the minimum and the maximum as a success.

To sum up, the neural network is designed to learn from historical data, taking into account the input data entered by the decision-maker in LDSS for the assumed number of weeks, how the GSU processes are carried out, and to present a prediction of the unit behaviour in terms of fuel distribution based on the decisions that the decision-maker will make for a given period of time.

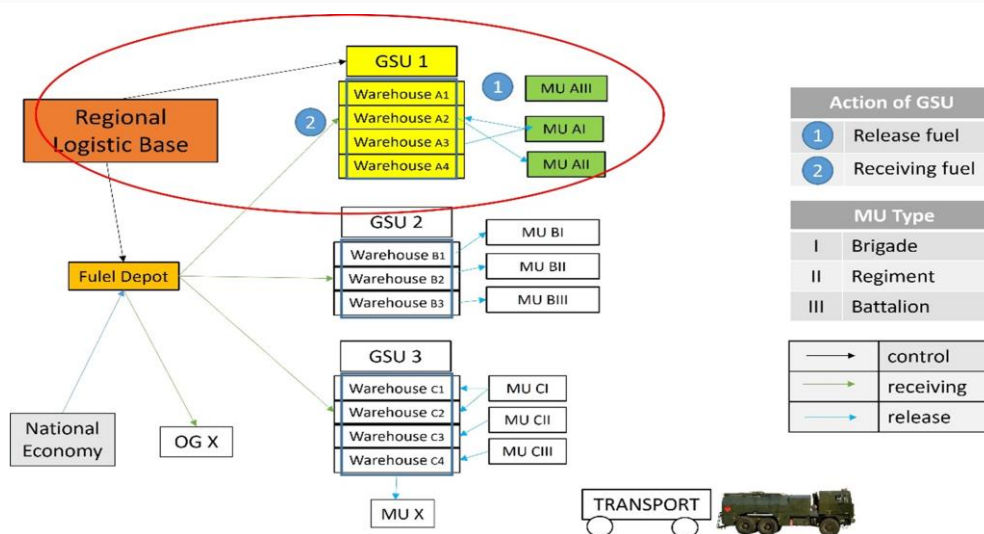


Fig. 3. The process of dispensing and receiving fuel by GSU.

The analysis covered data from selected MUs and GSU warehouses, which have been artificially linked by logistical relationships, but are a reliable model of the fuel supply system for research purposes. The probability of the initial state obtained thanks to the aggregation of historical data guarantees that, for the last five years, day by day, the tasks of supplying fuel have been performed in accordance with the adopted logistics policy of the troops. The operating environment affected the logistics system and caused successes and failures in procurement. The Logistics Decision Support System (LDSS) is a predictive module that, based on historical data and operational assumptions, e.g. exercises and policy, will allow for predicting the level of GSU fuel through the prism of the actions assumed at a given time and the operational situation. The system, based on the assumed coefficients, is to show how the decision-maker will lead GSU in the future.

The minimum and maximum level of maintaining fuel stocks was adopted, which made it possible to assess fuel inventory levels and determine the probability of the logistics system for a given week. The behaviour of the GSU decision-maker is influenced by logistical space-time – a complex concept that is superimposed by many factors, including the dynamics of actions, manoeuvres of forces, surprise and dispersion. Military logistics must keep up with the changes in this environment, and the commanders of logistics subunits must make decisions in a short time by analysing large amounts of data.

Providing fuel in the theatre of military operations is only one of the elements of the military logistics system. For the purposes of creating a decision-making model, we assume that securing the fuel needs of the operating MU requires several logistics processes based on the resources available in the operational space over time (based on GSU's resources as well as allied and civilian resources). According to this, it is necessary to overcome the logistic space-time [15] to ensure the appropriate level of fuels in time ( $T$ ) in the indicated locations ( $X$ ) with input data such as:

- a) Environmental:
  - temperature,
  - humidity,
  - the amount of rainfall in a given area,
  - characteristics of the terrain,
  - season,
  - altitude.
- b) Structural:
  - accessibility of land, sea, and airspace with landing strips,
  - transmission line capacity (fuel tonnage over time),
  - storage capability: equipment parameters, tonnage, dispensing capacity, and filling and distribution time.
- c) Operational (space, time, resources, and information):
  - duration of the operation,
  - the number of main equipment, infrastructure, and soldiers in the area of responsibility,
  - the dynamics of activities,
  - loss factor [1].

Based on the area of the logistics operation, we can distinguish the general function of the space-time of the operation [15].

There are several phases of the decision-making process. At the outset, it is necessary to identify the decision-making situation, which should be characterised by all factors that affect the decision-maker's verdict. Then, we will formulate the decision-making problem that the decision-maker faces. We must include a definition of: a decision-maker; decision options; factors limiting the decision-making space, and the reasons shaping the assessment of decision-making options. The first phases of a decision problem are mainly descriptive and are based on the coefficients and weights of the input variables of the neural network.

With the help of network inputs, you can determine the elements of a set of acceptable decision options, as well as indicate optimal options. Finally, you need to determine different subsets of the set of options: acceptable, satisfactory and optimal, and make a decision on this basis. The determination of different subsets of the set of options is based on the use of, among others, single- and multi-criteria optimisation methods. The Logistics Decision Support System – LDSS is to be a computerised system that supports decision-making in the area of logistics at the appropriate decision-making level of the military logistics system.

### 3. Neural network selection and the learning process

For the purpose of predicting the actions to be carried out by the decision-maker, a model of energy consumption prediction based on neural networks was used. The MATLAB software was used for this purpose. It includes, among other things, the Neural Network Toolbox library, which enables the construction and use of neural networks for forecasting. For this purpose, you can use ready-made tools, or use the basic command line.

To build a neural network, you need to follow these steps:

- collect data,
- create a network,
- configure the network,
- initialise scales,
- test the network,
- use the network for prediction.

We assume that the artificial neural network will generate the GSU fuel level signal taking into account the above conditions, with 260 lines of historical data set containing 21 input variables such as time, intensity of activities in the GSU operating area, including the number of fuel acceptance/dispensing operations, availability of equipment, number of personnel in the GSU system, variable specifying procedural restrictions (regulations, instructions), type of terrain, meteorological data (wind speed, temperature, humidity, variable that determines who is the recipient (size of the unit, e.g. brigade, regiment, battalion), time of fuel dispensation, execution of the movement of the GSU fuel resource, state of the GSU warehouse.

The prediction assumes the determination of 10 consecutive values of fuel levels in the GSU for the decision-maker or other

data (intensity of activities, dispensing or suspension of fuel dispensing, etc.) necessary to decide for the next 10 weeks of GSU action planning.

An array of input and output data containing 21 input variables and n-waveforms of output parameters necessary to predict the operation of GSU, which in the MATLAB environment will be used for prediction using a multilayer one-way network (multilayer perceptron).

The supervised learning method was used in the research, in which the network parameters are selected on the basis of a comparison of the values at the network output with the set values for the recorded, actual level of fuel dispensed in GSU. Training in this case consists of minimising the error function depending on the differences between the set values and the actual network output for training data.

A variant of the network with one layer of hidden neurons for different numbers of neurons was studied. It was assumed that there would be 10, 20 and 50 neurons in the hidden layer.

Four learning algorithms were adopted for the task, including three second-order algorithms:

- BFGS quasi-Newton (BFG),
- Levenberg-Marquardt (LM),
- Bayesian regularisation (BR),
- resilient backpropagation algorithm (RP).

Sigmoid neuronal activation functions in the latent layer were used.

The program randomly divided the data into three sets:

- 70% – a training set,
- 15% – a set used to validate a network in terms of its ability to generalise and stop the learning process before the phenomenon of overtraining occurs,
- 15% – a test set to perform an independent test of the network's ability to generalise.

The results were evaluated using:

- regression coefficient ( $R^2$ ) measuring the correlation between the exit signal and the given target (the closer the value to 1, the better the result);
- MSE determining the quality of processing for all sets used in the study;
- RMSE mean squared error, indicating the accuracy of the forecast in a given model.

The terms dispensing or adoption cover specific decision-making processes leading to such "final" actions.

We assume that an artificial neural network model based on the algorithm of a neural network of learning with a teacher (Fig. 1) is designed to indicate, based on historical data, whether the decision-maker should perform one of three types of actions: dispense fuel, suspend dispensing fuel, or accept fuel. At the input of the neural network, to predict the decision-maker's actions, we need to collect specific data in IT systems, which are elements of the input vector of the model [1].

To train the neural network to predict fuel level changes at GSU, a group of environmental, operational and infrastructural variables were used. According to the assumptions of the LDSS system, it should be assumed that the decision-maker will introduce indicated groups of variables into the program, which will be used to create a matrix of validation data in order to predict

how the fuel level parameter in GSU will behave. An artificial intelligence algorithm will indicate a different distribution of GSU fuel levels based on historical data and the relationship between the layers of the network. The decision-maker, thanks to the illustration as in Fig. 4 or thanks to the indicators of differences between the levels assessed by the decision-maker and the one indicated by the network, will allow the decision-maker to react or take action on refuelling in a given week.

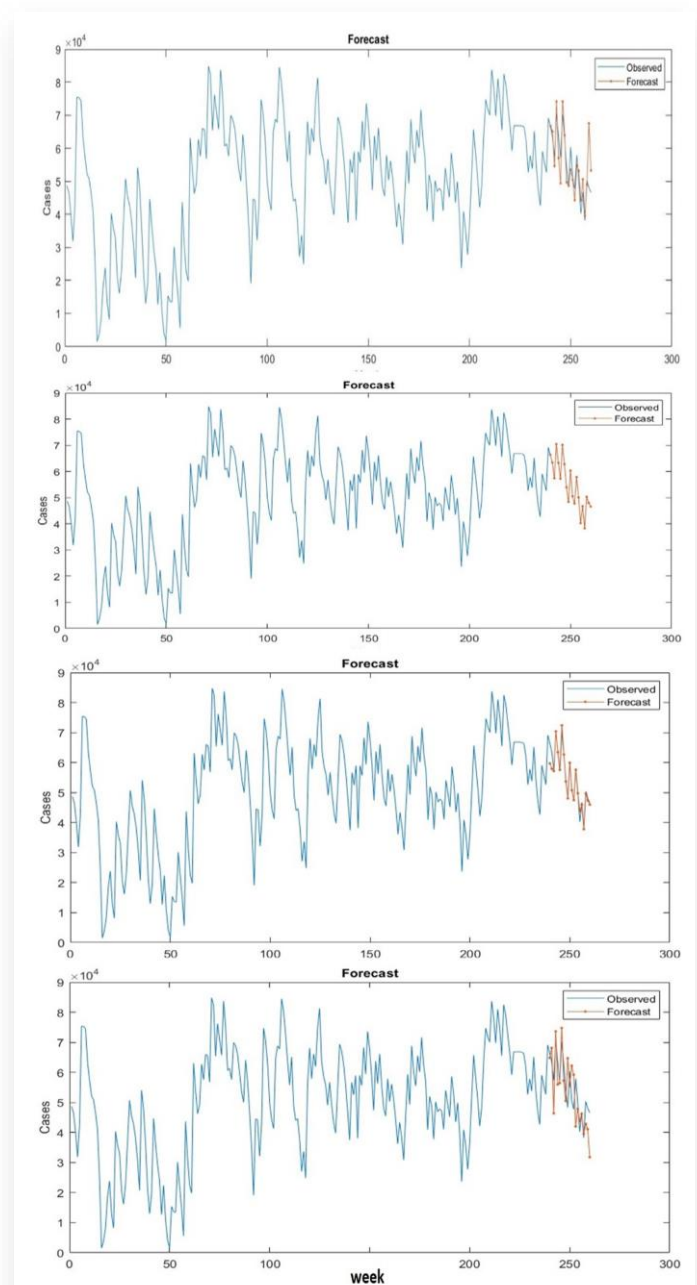


Fig. 4. Comparison of the fit plots of the simulated and measured results and the mean squared error for the study using a multilayer unidirectional network with 50 neurons using the BFG, BR, LM and RP algorithms.

A similar analysis can be carried out for other GSU parameters, such as the number of personnel (200–300 people), the intensity of activities, which consequently translates into changes in the fuel level in GSU. There are dependencies between the variables, thanks to which we can determine dependent var-

ibles, such as the time of fuel dispensing from the GSU, which depends on the intensity of activities (the number of fuel trading operations per week was 0–127), the number of available personnel (accepted in the study in the range of 200–300 people) and the amount of fuel dispensed (historical data). In this case, the decision-maker will receive information whether his calculations are correct. In addition, it will be possible to determine from historical data whether an increased intensity of activities should be expected in a given week beyond that assumed by the decision-maker.

Figure 4 should be interpreted in such a way as to look for

differences between the indications of the GSU parameter from the prediction and the validation set. The regression error in this case will indicate whether these values differ so significantly that the network is trained to provide the right variants of action for the decision-maker.

Below, the results of research using the BFG, BR, LM and RP algorithms for a multilayer neural network with one hidden layer and 50 neurons are presented in the form of graphs in Figs. 5–8. Similar data analyses were carried out for networks with 10 and 20 neurons, but in this configuration, the differences in results for individual algorithms are most representative.

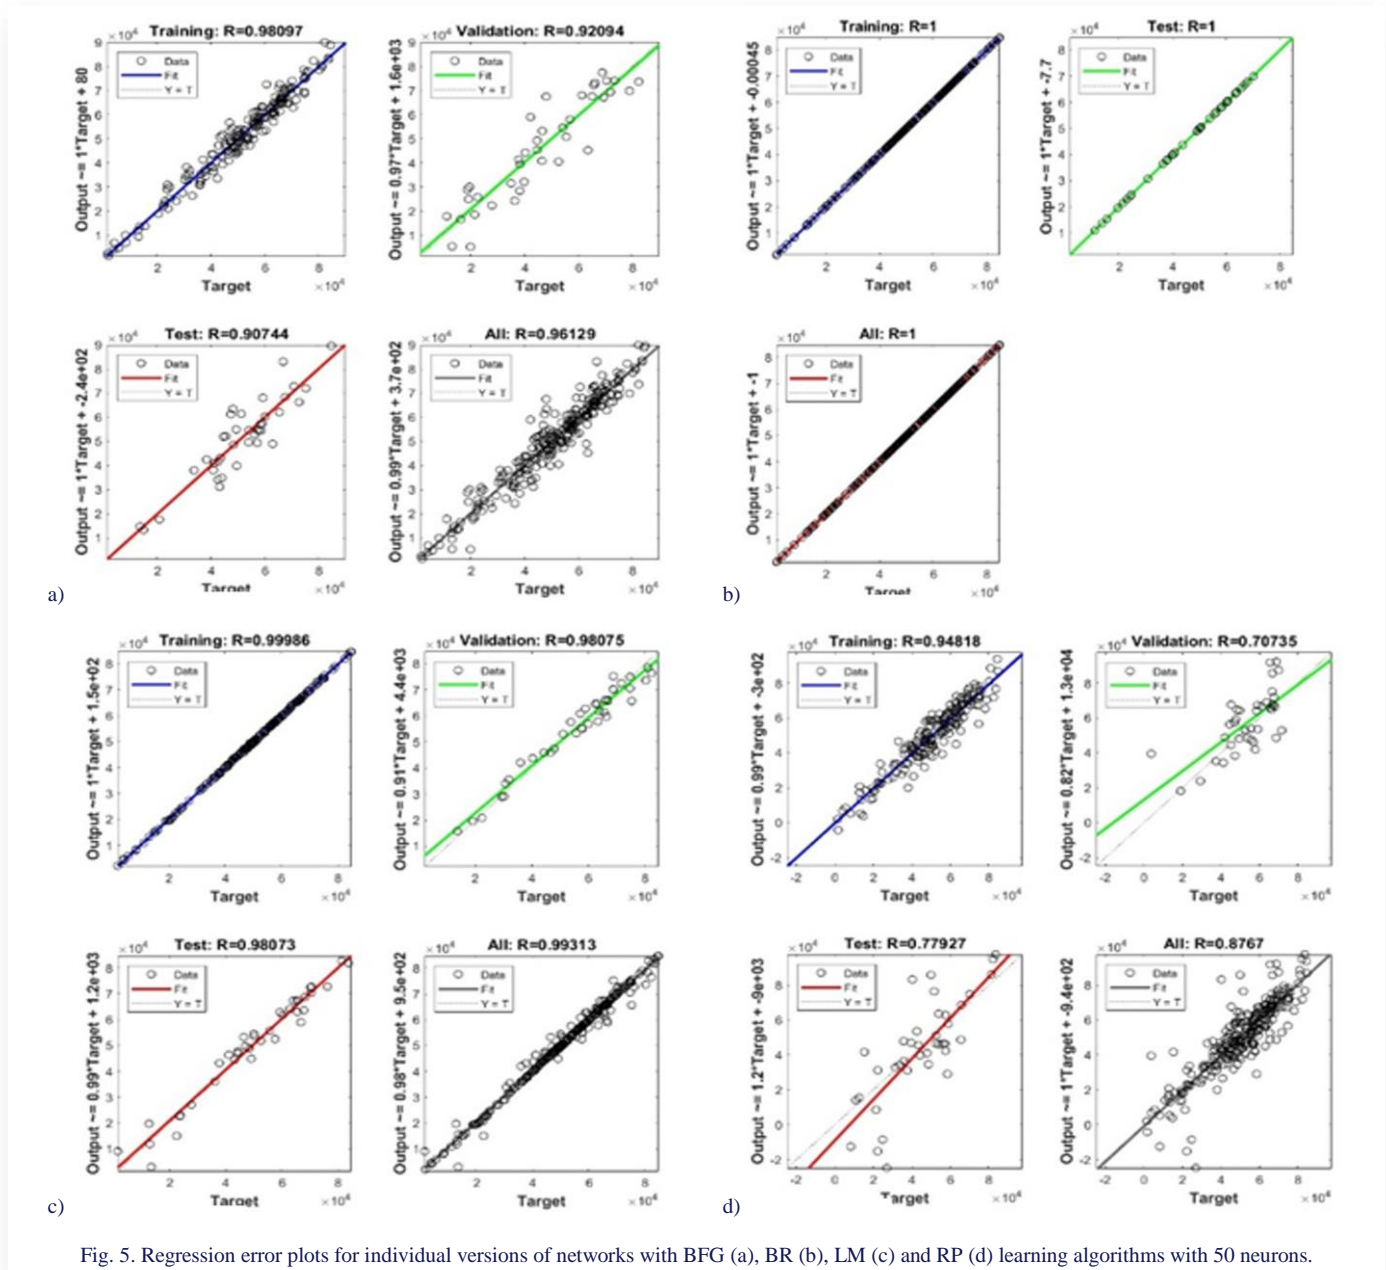


Fig. 5. Regression error plots for individual versions of networks with BFG (a), BR (b), LM (c) and RP (d) learning algorithms with 50 neurons.

In the results obtained, the BR algorithm obtained the best parameters mainly due to the specificity of its operation:

1. Regularisation mechanism minimises overlearning:
  - BR modifies the error function to simultaneously minimise the matching error and the complexity of the network scales.

- This way, the network does not learn training data "by heart", but generalises better to test and validation data.
  - effect: the highest R coefficient (0.999) and the lowest MSE in validation.
2. Learning stability with a large number of neurons:

- In the configuration (50 neurons, 1 layer), the network has a very large number of weights → a high risk of overtraining with classical methods.
  - BR copes with this better than BFG, LM or RP, because it automatically adjusts the degree of regularisation based on the data.
3. Data noise immunity:
- Because there is a "penalty" component for too high weights in the target function, the BR-trained network does not over-adjust to single outliers. In practice, this

translates into the highest number of zero-error hits in the test.

4. Better fit in regression problems:
- BR is particularly effective in continuous regression because it not only optimises the MSE error, but also improves the input-output correlation.
  - The results show that the differences between LM, BFG and BR are the largest in the validation MSE, suggesting that BR is better at predicting values for data that the network has not seen before.




Fig. 6. Evaluation of the quality of validation for a multilayer neural network with one hidden layer and 50 neurons, using the BFG, BR, LM and RP algorithms.

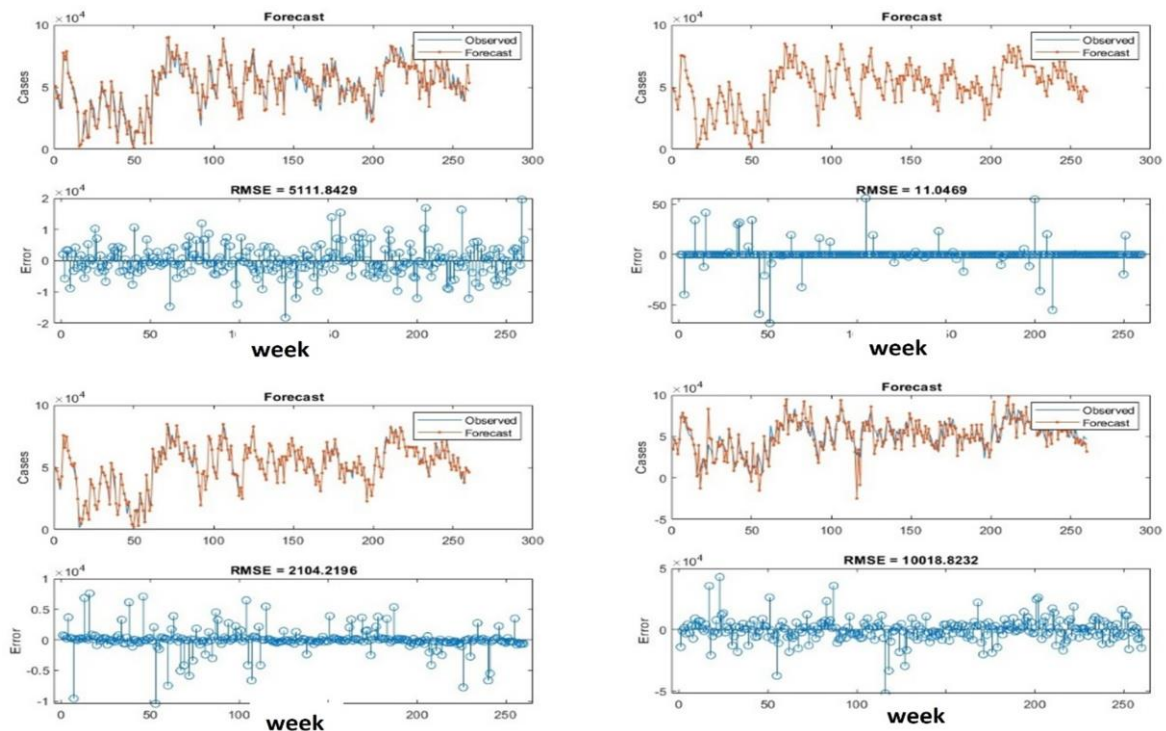


Fig. 7. Comparison of the fit plots of the simulated and measured results and the mean squared error for the study using a multilayer unidirectional network with 50 neurons, using the BFG, BR, LM and RP algorithms.




Fig. 8. Regression error histograms for consecutive neural networks with 50 neurons using the BFG, BR, LM and RP algorithms.

### 4. Summary

BR performed best for the network with 50 neurons, as its built-in regularisation mechanism reduced overtraining and increased generalisation. This is especially important with large numbers of neurons and potentially complex inputs.

The results obtained for different neural network structures and learning algorithms are summarised in Table 1. Based on the conducted research, Fig. 9 depicts formulated trend conclusions from data for 10, 20 and 50 neurons in BFGS, BR, LM and RP algorithms:

1. Accuracy of fit (R):
  - Highest R (1.0),
  - BR and LM with 10 neurons (perfect match),
  - LM maintains R = 1.0 also with 20 neurons,
  - BR with 50 neurons still R ≈ 1.0,
  - BFGS – stable around 0.98 with 10 and 20 neurons, a slight drop to 0.96 with 50 neurons,
  - RP – a marked decrease with the number of neurons: 0.97 → 0.92 → 0.87.

Conclusion: BR and LM are very accurate on small and medium-sized networks; with larger networks, BR maintains an advantage over LM and other algorithms.

2. Mean squared error (RMSE and MSE):

- BR – extremely low MSE in each case (in the order of  $10^{-4} - 10^{-6}$ ), which suggests high stability and lack of overlearning,
- LM – with 10 and 20 neurons, low RMSE (1.65 and 0.36), but with 50 neurons, a significant increase in RMSE ( $2.1 \cdot 10^3$ ) and MSE ( $1.3 \cdot 10^8$ ), which may suggest a problem with fitting or overlearning,
- BFGS – increasing RMSE and MSE with the number of neurons,
- RP – high RMSE and MSE in any scenario, deteriorates with larger networks.

Conclusion: BR has a definite qualitative advantage, LM is good for smaller networks, and BFGS and RP lose accuracy as neurons grow.

3. Influence of the number of neurons:
  - BR – virtually independent of the number of neurons in terms of fit quality ( $R \approx 1.0$ , low MSE),
  - LM – great up to 20 neurons, but at 50 neurons, there is a degradation in quality,
  - BFGS – moderately stable up to 20 neurons, later larger errors,
  - RP – quality decreases significantly as neurons grow, which may indicate a problem with weight propagation in large networks.

Table 1. Results for three networks and four learning algorithms (the best fit data for the BR algorithm is marked in green).

Algorithm	BFGS quasi_Newton			Bayesian regularisation			Levenberg-Marquardt			Resilient backpropagation		
	RMSE	MSE	R	RMSE	MSE	R	RMSE	MSE	R	RMSE	MSE	R
10 neurons	$2,14 \cdot 10^3$	$6,14 \cdot 10^6$	0,98	0,21	$1,13 \cdot 10^{-4}$	1	1,65	7,03	1	$2,84 \cdot 10^3$	$1,9 \cdot 10^7$	0,97
20 neurons	$2,4 \cdot 10^3$	$1,18 \cdot 10^7$	0,98	27,5	$2,6 \cdot 10^{-6}$	0,99	0,36	0,38	1	$5,58 \cdot 10^3$	$8,12 \cdot 10^7$	0,92
50 neurons	$5,11 \cdot 10^3$	$6,76 \cdot 10^7$	0,96	11,04	$1,3 \cdot 10^{-6}$	1	$2,1 \cdot 10^3$	$1,3 \cdot 10^8$	0,99	$1,02 \cdot 10^4$	$1,6 \cdot 10^8$	0,87




Fig. 9. Change in R and RMSE for the studied algorithms depending on the number of neurons.

The main consumer of fuel in the adopted model of the supply region by GSU are vehicles and devices based on the operation of internal combustion engines. An analysis of the available

scientific literature [16–18] in recent years indicates a significant influence of air temperature and humidity on the fuel consumption of internal combustion engines. This relationship was the reason for including these parameters in the database to be studied. The research analyses the collected data in terms of the impact of temperature and humidity on fuel consumption in GSU. In order to determine the relationship between fuel consumption in a logistics unit and weather conditions, a correlation and regression analysis was performed, using variables: ambient temperature, relative humidity and intensity of activities measured as the number of fuel extraction operations (Fig. 10). The direct relationship was assessed using the Pearson correlation coefficient and the linear regression model.

The results clearly indicate that fuel consumption strongly depends on the intensity of operations of military units in the area of responsibility of GSU, which is confirmed by a positive correlation ( $\gamma \approx 0.51$ ). This means that an increase in the number of fuel withdrawal operations is significantly linked to an increase in fuel consumption.

On the other hand, the correlations between fuel consumption and temperature ( $r \approx -0.05$ ) and humidity ( $r \approx 0.03$ ) are close to zero, indicating that there is no direct linear relationship between the variables in question. Adding temperature and humidity to the regression model did not increase its explanatory power ( $R^2 \approx 0.26$ ), and the coefficients assigned to them turned out to be statistically insignificant ( $p > 0.5$ ). This means that the impact of meteorological parameters on fuel consumption is not due to direct impact, but may be a secondary effect depending on planning and seasonality of activities.




Fig. 10. Influence of air temperature and humidity on the fuel consumption in GSU

Fuel consumption in the tested model unit does not directly depend on air temperature or humidity, but is strongly correlated with the intensity of logistics activities. Weather conditions may indirectly affect consumption by modifying training activities, but they are not an independent factor determining fuel consumption. Even the use of the non-linear random forest model did not allow for a satisfactory quality forecast of fuel consumption based on meteorological data. The most important predictor remains the intensity of fuel withdrawal operations, which indicates that the demand for fuel is determined mainly by training and operational activities. Weather factors, on the other hand, can play an indirect role – they affect the planning of exercises and military operations, but they are not an independent determinant of the level of consumption.

## 5. Conclusions

In order to create software supporting the decision of the GSU decision-maker in the future, neural networks based on the most commonly used algorithms were trained. The Levenberg-Marquardt and Bayesian regularisation algorithms within the framework of approximation tasks are considered to be the best in obtaining MSE from all the algorithms used [16]. It should be noted that the Levenberg-Marquardt algorithm, which in many studies shows its advantage over other algorithms, turned out to be less useful in this case. LM is considered the fastest, not too complex, and is used almost exclusively for training a medium-sized unidirectional network with a single neuron at the output layer. Unfortunately, the amount of data collected for the purpose of training the network to predict activities in GSU was small, mainly because so far the ZWSI RON system (Integrated Multi-Level IT System of the Ministry of National Defense) has not collected data such as the intensity of activities in the area of the GSU's operation, the type of terrain, the availability of equipment, the variable that determines the limitations related to procedures (regulations), meteorological data (wind speed, temperature, humidity) probability of moving the GSU fuel resource. The scale of the amount of data that must be implemented into the military logistics information system is significant; however, the presented article is intended to indicate the need to take actions that will lead to the expansion of the number of collected parameters of the military logistics system. In this case, probably too small a dataset to train and a decidedly small network size did not allow for fully showing the advantages of this algorithm, including its speed.

The use of the Bayesian regularisation algorithm turned out to be the most effective method in terms of prediction ability, much better than the Levenberg-Marquardt algorithm, which is slightly inferior to this algorithm. Such a favourable result for R&D was influenced by, among others, greater resistance to learning, less cross-validation [17], and better flexibility and quality of generalisation [18].

In the case of BFGS algorithms, the quasi-Newton algorithm is considered to be a more complex algorithm, but its properties are perfect for small networks, due to the complexity of the calculations it performs. The results confirmed this by placing the algorithm in third place in the study.

The resilient RP backpropagation algorithm, despite the advantage of eliminating errors in the training set, did not guarantee good results in the obtained prediction.

It turned out that the quality of learning using this algorithm, given the relatively small size of the network used for the research, gives worse results than other methods.

To sum up, it should be stated that a multilayer unidirectional perceptron with a sigmoid function of neuronal activation in the hidden layer and with the use of the Bayesian regularisation learning algorithm can be successfully used to predict fuel management in GSU.

Proper construction of a database for GSU and entering geolocation and meteorological data into the ZWSI RON system will significantly improve the ability of the neural network to generalise, and thus fit into the decision-making model in GSU by creating tools for the development of a logistic decision support system – LDSS.

Regardless of the above, during the study of the problem of optimisation of prediction using machine learning algorithms, it can be noted that the next step in optimising this type of software, mainly in terms of the quality and speed of prediction, are reinforcement learning (RL) algorithms. Based on research conducted on RL algorithms in, e.g. the game "Tetris" [19,20], the key factor in reinforcement learning is the time delay between the action and the reward. Based on the literature on the use of RL algorithms in computer games, it should be stated that the worst performance is achieved by networks trained to predict actions several dozen steps away from the next reward. It can be said that the longer the interval between the action and the reward, the game requires a much more deliberate strategy, and the shorter the pause, the more the game is reactive to the changing situation of the operating environment. RL-based learning occurs much faster [21] in reflex-based games than in games that require a lot of strategy, which makes sense and is in line with the author's research. The results show that using AI to combine an agent neural network trained on historical GSU data and a strategy-based RL algorithm is a very beneficial approach in terms of improving decision-making efficiency. Reinforcement learning differs from supervised learning in that it does not require the presentation of labelled input/output pairs and does not require direct correction of suboptimal actions. Instead, we focus on finding a balance between exploring unknown solutions and the decision-maker's experience to maximise the long-term reward, whose feedback may be incomplete or delayed [22].

Taking into account the above, the use of a neural network to predict activities in a business branch turned out to be very useful and allows decision-makers to make decisions for the next weeks of GSU's operation with the indication of variables to be predicted. On the other hand, supplementing the analysis with RL algorithms in the future will allow us to further optimise this process and significantly speed it up. The use of the proposed machine learning methods is aimed at developing a logistics decision support system – LDSS in the future, which will be designed to support decision-making processes in the area of logistics at the appropriate decision-making level of the Armed Forces logistics system.

The method of predicting fuel consumption of the logistics system in GSU described in the article can be successfully used to determine other thermodynamic parameters, such as the pressure at the inlet to the turbine of a jet engine, the distribution of air flow on the steam turbine blade depending on the parameters of the external environment, as well as to predict fuel consumption in power plants or other energy generation systems. Thanks to the use of backpropagation, and comparison of the obtained results with the desired values and continuous calculation of the error, the network leads to weight correction to minimise error in subsequent steps (iterations). These processes take place in the so-called epochs, and each epoch is a single passage through the entire set of learning data. The method described in the article can be used by readers for their own research and lead to many interesting solutions to research problems in the field of thermodynamics.

## References

- [1] Kępczyński, A. (2024). A model of supporting the decision-making process for the needs of providing energy to the Armed Forces. *Perspectives of military and civilian logistics in the context of ensuring resilience to the Armed Force*, 12–14 June, Bydgoszcz, Poland (in Polish).
- [2] Prokopowicz, W., & Kępczyński, A. (2024). Application of neural networks to model decision-making processes in a military fuel distribution system. *Perspectives of military and civilian logistics in the context of ensuring resilience to the Armed Force*, 12–14 June, Bydgoszcz, Poland (in Polish).
- [3] Kępczyński, A., & Stępień, S. (2024). Optimization and AI support in military logistics. *Perspectives of military and civilian logistics in the context of ensuring resilience to the Armed Force*, 12–14 June, Bydgoszcz, Poland (in Polish).
- [4] Kępczyński, A., Lisowski, G., Prokopowicz, W., & Stępień, S. (2023). Adaptive methods in the logistics of military energy. In: *Science for Defense and the Environment* (pp. 20–28). ITWL Publishing House, Warsaw (in Polish).
- [5] Alasmari, T., & Alzahrani, A. (2025). Saudi Arabia's shifts towards green and sustainable logistics: Bibliometric and machine learning-based insights and forecasts. *Journal of Cleaner Production*, 509, 145577. doi: 10.1016/j.jclepro.2025.145577
- [6] Eichenseer, P., Hans, L., & Winkler, H. (2024). A data-driven machine learning model for forecasting delivery positions in logistics for workforce planning. *Smart Computing and Applications*, 9, 100099. doi: 10.1016/j.sca.2024.100099
- [7] Nguyen, S., Gadel, M., Wang, K., Li, J., Zhang, X., Kong, S.-C., Fu, X., & Qin, Z. (2025). Maritime decarbonization through machine learning: A critical systematic review of fuel and power prediction models. *Cleaner Logistics and Supply Chain*, 14, 100210. doi: 10.1016/j.clscn.2025.100210
- [8] Yaiprasert, C., & Hidayanto, A.N. (2023). AI-powered ensemble machine learning to optimize cost strategies in logistics business. *International Journal of Industrial and Manufacturing Engineering*, 4(1), 100209. doi: 10.1016/j.ijime.2023.100209
- [9] Zhou, J., Yang, C., Liu, D., Wang, Y., Zhong, Z., & Wu, Y. (2025). A three-stage geospatial network optimal location decision model for urban green logistics centers from a sustainable perspective. *Sustainable Cities and Society*, 128, 106481. doi: 10.1016/j.scs.2025.106481
- [10] Liang, Y.Y., Shahabuddin, M., Ahmed, S.F., Tan, J.X., & Ali, S.M. (2025). Optimizing sustainable aviation fuel supply chains: Challenges, mitigation strategies and modeling advances. *Fuel*, 402, 135972. doi: 10.1016/j.fuel.2025.135972
- [11] Burden, F.R., & Winkler, D.A. (2008). Bayesian regularization of neural networks. *Methods in Molecular Biology*, 458, 25–44. doi: 10.1007/978-1-60327-101-1\_3
- [12] Hagan, M.T., & Menhaj, M.B. (1994). Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks*, 5(6), 989–993. doi: 10.1109/72.329697
- [13] Fletcher, R. (1970). A new approach to variable metric algorithms. *The Computer Journal*, 13(3), 317–322. doi: 10.1093/comjnl/13.3.317
- [14] Riedmiller, M., & Braun, H. (1993). A direct adaptive method for faster backpropagation learning: The RPROP algorithm. *IEEE International Conference on Neural Networks*, 586–591. 28 March–01 April, San Francisco, USA. doi: 10.1109/ICNN.1993.298623
- [15] Ficoń, K. (2006). *Applied Operational Research. Models and applications*. BEL STUDIO Publishing House, Warsaw (in Polish).
- [16] Saber, H.A., Al-Barwari, R.R.I., & Talabany, Z.J. (2013). Effect of Ambient Air Temperature on Specific Fuel Consumption of Naturally Aspirated Diesel Engine. *Journal of Science and Engineering*, 1(1), 1–7. <https://www.scribd.com/document/133228366/> [accessed 22 Nov. 2025].
- [17] Bielaczyc, P.A., Szczotka, A., & Woodburn, J. (2011). The effect of a low ambient temperature on the cold-start emissions and fuel consumption of passenger cars. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 225(9), 1253–1264. doi: 10.1177/0954407011406613
- [18] Andrych-Zalewska, M., Chłopek, Z., Merkisz, J., & Pielecha, J. (2023). Impact of the Internal Combustion Engine Thermal State during Start-Up on the Exhaust Emissions in the Homologation Test. *Energies*, 16(4), 1937. doi: 10.3390/en16041937
- [19] Kayri, M. (2016). Predictive abilities of Bayesian regularization and Levenberg–Marquardt algorithms in artificial neural networks: A comparative empirical study on social data. *Mathematical and Computational Applications*, 21(2). doi: 10.3390/mca21020020
- [20] Burden, F., & Winkler, D. (2008). Bayesian regularization of neural networks. In D. J. Livingstone (Ed.), *Artificial Neural Networks: Methods in Molecular Biology*, 458. Humana Press. doi: 10.1007/978-1-60327-101-1\_3
- [21] Sariiev, E., & Germano, G. (2020). Bayesian regularized artificial neural networks for the estimation of the probability of default. *Quantitative Finance*, 20(2), 311–328. doi: 10.1080/14697688.2019.1633014
- [22] Groß, A., Friedland, J., & Schwenker, F. (2008). Learning to play Tetris applying reinforcement learning methods. *16th European Symposium on Artificial Neural Networks*, 23–25 April, Bruges, Belgium.
- [23] Stevens, M., & Pradhan, S. (2016). Playing Tetris with deep reinforcement learning. Stanford University. [https://cs231n.stanford.edu/reports/2016/pdfs/121\\_Report.pdf](https://cs231n.stanford.edu/reports/2016/pdfs/121_Report.pdf) [accessed 22 Nov. 2025].
- [24] Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A.A., Veness, J., Bellemare, M.G., Graves, A., Riedmiller, M., Fidjeland, A.K., Ostrovski, G., Petersen, S., Beattie, Ch., Sadik, A., Antonoglou, I., King, H., Kumaran, D., Wierstra, D., Legg, S., & Hassabis, D. (2015). Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529–533. doi: 10.1038/nature14236
- [25] Kaelbling, L.P., Littman, M.L., & Moore, A.W. (1996). Reinforcement learning: A survey. *Journal of Artificial Intelligence Research*, 4, 237–285.

**PUBLIKACJA [2]**

- [2]. Kępczyński A., *Model wspomagania procesu decyzyjnego na potrzeby zapewnienia energii dla Sił Zbrojnych. Zarządzanie zasobami paliw w SZ*, rozdział w monografii *Perspektywy logistyki wojskowej i cywilnej w kontekście zapewnienia odporności Siłom Zbrojnym* (konferencja Bydgoszcz), Warszawa: Wydawnictwo ITWL 2024, Tom 1.

Artur KĘPCZYŃSKI\*

## **MODEL WSPOMAGANIA PROCESU DECYZYJNEGO NA POTRZEBY ZAPEWNIENIA ENERGII DLA SIŁ ZBROJNYCH. ZARZĄDZANIE ZASOBAMI PALIW W SZ**

Zapewnienie odpowiedniego poziomu energii dla współczesnych wojsk ocenia się jako kluczowy czynnik w utrzymaniu przez wojsko zdolności do działania. Choć energię na potrzeby militarne można postrzegać w różny sposób to wciąż paliwa (węglowodory) pozostają jej najważniejszym źródłem. Artykuł poświęcony jest problematyce wspomagania procesu decyzyjnego zabezpieczenia logistycznego wojsk w obszarze zarządzania zasobami energii na przykładzie paliwa. Potrzebę zajęcia się tą problematyką z perspektywy szeroko rozumianej logistyki Sił Zbrojnych RP należy upatrywać w intensywnym rozwoju technologii informatycznych (IT), dynamicznie rozrastających się bazach danych wymagających zaawansowanych narzędzi analitycznych (Big data) oraz niemal powszechnie już wykorzystywanej sztucznej inteligencji (AI) w zarządzaniu/dowodzeniu. W efekcie tego funkcjonowanie nowoczesnych wojsk operacyjnych odbywa się w środowisku sieciocentrycznym, nasyconym zautomatyzowanymi środkami dowodzenia. Przekłada się to na konieczność dostosowania standardów zarządzania w logistyce wojskowej. W artykule dokonano syntetycznej analizy obecnego stanu automatyzacji procesów zarządzania zasobami paliw w Siłach Zbrojnych RP oraz przyjętych do realizacji kierunków rozwoju logistycznych systemów informatycznych w najbliższych latach. Zdaniem autora wnioski z analiz aktualnego poziomu automatyzacji wspomagania procesów decyzyjnych w zarządzaniu zasobami paliwa jednoznacznie wskazują na konieczność podjęcia pilnych działań w celu rozbudowy logistycznego systemu informatycznego, zintegrowanego z sieciocentrycznym środowiskiem dowodzenia w Siłach Zbrojnych. Autor przedstawia koncepcyjny model wspomagania procesów decyzyjnych w zarządzaniu zasobami paliwa z zastosowaniem technologii sztucznej inteligencji. W podsumowaniu wskazane są dalsze kierunki prac analityczno-badawczych nakierowanych na dobór odpowiednich typów sieci neuronowych, oraz odpowiedniej struktury modelu algorytmu procesu wspomagania decyzji. Zaproponowane rozwiązania oraz planowane dalsze prace koncepcyjne mają charakter uniwersalny i z powodzeniem będą mogły być zastosowane do zarządzania nie tylko paliwem, ale całym potencjałem logistycznym, zintegrowanym w SI ZWSI RON.

---

\* Inspektorat Wsparcia Sił Zbrojnych.

Słowa kluczowe: sztuczna inteligencja w logistyce wojskowej, wojskowy system logistyczny, model wspomaganie decyzji, sieć neuronowa

## 1. WPROWADZENIE

Energia to jeden z najważniejszych zasobów niezbędnych do funkcjonowania współczesnych sił zbrojnych zarówno w czasie pokoju, kryzysu czy wojny<sup>1</sup>. Problematyka energetyczna w ujęciu wojskowym postrzegana jest jako główny czynnik wpływający na utrzymanie zdolności do działania (stałe utrzymanie w sprawności sił i środków, szkolenie), realizacji zadań bojowych (aktywność operacyjna) oraz tworzenie przewagi poprzez ograniczanie dostępu do zasobów energii stronie przeciwnej (oddziaływanie na infrastrukturę logistyczną i łańcuchy dostaw energii). Znaczenie energii dla wojsk rosło wraz z rozwojem naukowo-technicznym, którego efektem jest zwiększające się dynamicznie nasycenie wojsk coraz bardziej zaawansowanymi technologicznie nowymi rodzajami broni, sprzętu i wyposażenia wymagającymi zasilania w energię. Infrastruktura wojskowa, zarówno stacjonarna jak i mobilna to również poważne źródło potrzeb energetycznych. Pomimo dynamicznie rozwijających się technologii wykorzystywania w nowoczesnej technice wojskowej energii elektrycznej coraz częściej pochodzącej z niekonwencjonalnych autonomicznych odnawialnych źródeł (OZE), to jednak paliwa płynne (węglowodory) wciąż pozostają kluczowym źródłem zasilania wojsk w energię.

Charakter wojen i konfliktów zbrojnych na przestrzeni lat ulega nieustannym zmianom. Jest to wynikiem wielu składowych, wśród których obok aspektów geopolitycznych, ekonomicznych i społecznych to rozwój technologiczny i towarzyszące mu zmiany w strategii i doktrynach wojskowych mają istotne znaczenie w podejściu do problematyki zasilania wojsk w energię<sup>2</sup>. Analizy dotychczasowych konfliktów zbrojnych wyraźnie wskazują, że zużycie paliwa w operacjach wojennych wciąż ma tendencje wzrostowe. Ilość paliwa w przeliczeniu na jednego żołnierza na dobę od II Wojny Światowej wzrosło czterokrotnie w porównaniu do Wojny w Zatoce Perської, podczas gdy w 2006 roku amerykańskie operacje w Iraku i Afganistanie zużywały już szesnaście razy więcej paliwa w przeliczeniu na żołnierza dziennie<sup>3</sup>. Tendencje wzrostowe nie muszą koniecznie wynikać z wprowadzania do operacji militarnych

---

<sup>1</sup> D. Łukowski, Znaczenie surowców energetycznych i źródeł energii w Siłach Zbrojnych, Nauka dla obronności i środowiska, Wydawnictwo ITWL, 2020.

<sup>2</sup> T. Jałowicz, Logistyka wojskowa – od nauk wojskowych do nauk o zarządzaniu i jakości, Systemy Logistyczne Wojsk, Zeszyt 55 (2021).

<sup>3</sup> Energy & the Military: Convergence of Security, Economic and Environmental Decisionmaking <https://www.eprg.group.cam.ac.uk/wp-content/uploads/2017/11/1717-Text.pdf>, wejście 23.03.2024.

zwiększanych ilości żołnierzy i sprzętu wojskowego. Rozwijane obecnie koncepcje prowadzenia walki zmierzają wręcz do minimalizacji użycia potencjału osobowego w bezpośrednich działaniach kinetycznych, wykorzystując nowoczesne technologie oparte na platformach bezzałogowych oraz możliwościach wynikających z dynamicznie rozwijającego się środowiska informatycznego (IT) i sztucznej inteligencji (AI). Rozwiązania te są jednak, póki co energochłonne, co oznacza, że w najbliższym czasie nie możemy oczekiwać redukcji poziomu konsumpcji energetycznej konfliktów zbrojnych.

Zabezpieczenie logistyczne wojsk, w tym szczególnie zapewnienie paliw jako podstawowego źródła energii, zawsze stanowiło wyzwanie operacyjne i istotny czynnik uwzględniany w procesach decyzyjnych sztabów dowództw wojskowych wszystkich szczebli.

Rozwój technologiczny świata sprzyja rozwojowi również logistyki wojskowej, wskazuje nowe rozwiązania problemów logistycznych z którymi w minionych konfliktach zbrojnych borykały się wcześniejsze pokolenia logistyków. Wydawać więc by się mogło, że wraz z rozwojem technicznym w dziedzinie choćby wydajności środków transportu, rozwijanej infrastruktury komunikacyjnej, czy automatyzacji procesów logistycznych wyzwania w dziedzinie zabezpieczenia potrzeb logistycznych sił zbrojnych będą minimalizowane. Okazuje się jednak, że rozwój technologiczny poza oczywistym zwiększaniem zdolności potencjału logistycznego, generuje jednocześnie nowe, często trudne do rozwiązania problemy logistyczne. Dzieje się tak, ponieważ współczesna myśl wojskowa opiera się na osiągnięciu przewagi w potencjalnym konflikcie zbrojnym poprzez wykorzystywanie najnowszych osiągnięć nauki i techniki. Ma to bezpośredni wpływ na wypracowywanie nowych doktryn, strategii czy taktyki skutecznego zastosowania nowoczesnej techniki na użytek wojskowy. Przekłada się to na coraz to wyższe wymagania w obszarze zabezpieczenia logistycznego, w tym również w obszarze dostarczania paliw.

Do najważniejszych czynników mających wpływ na konieczność podnoszenia efektywności procesów decyzyjnych w zarządzaniu wojskowymi zasobami logistycznymi z wykorzystaniem najnowszych technologii informatycznych (IT) i sztucznej inteligencji (AI), należy zaliczyć:

1. **Sieciocentryczność** w zarządzaniu polem walki (Network-Centric Warfare) – dzięki rozwojowi nowoczesnych technologii w obszarze IT i AI możliwe staje się budowanie świadomości operacyjnej w trybie on-line na wszystkich szczeblach dowodzenia równocześnie. W efekcie dąży się do uzyskania przewagi poprzez skracanie czasu reakcji na dynamicznie zmieniającą się sytuację na polu walki. Presja czasu na procesy decyzyjne wymaga utrzymywania ciągłej logistycznej świadomości sytuacyjnej, analizy i natychmiastowych decyzji dotyczących zabezpieczenia logistycznego wojsk;

2. **Technologie „Big data”**, są to bardzo duże zbiory danych, o sporej zmienności i różnorodności, które wymagają nowoczesnych form przetwarzania w celu wspomaganie podejmowania decyzji i optymalizacji procesów. Efektywne wykorzystanie danych wymaga automatyzacji procesów analitycznych;
3. **Nowoczesna technika wojskowa**. Nowe siły zbrojne cechuje duża różnorodność sprzętu i uzbrojenia o bardzo wysokim stopniu zaawansowania technicznego. Utrzymanie sprawności nowoczesnej techniki wojskowej wymaga automatyzacji procesów zabezpieczenia technicznego (monitorowanie i diagnostyka systemów w trybie on-line, precyzyjne zarządzanie dostawami technicznych środków materiałowych z wykorzystaniem zaawansowanych technologii IT producentów);
4. **Bezpieczeństwo potencjału logistycznego**. Współczesne zdolności rozpoznania oraz nowoczesne środki precyzyjnego rażenia o coraz większym zasięgu zmuszają do prowadzenia precyzyjnie zaplanowanych, często skomplikowanych w realizacji operacji zabezpieczenia logistycznego (konieczność rozproszenia zasobów - wiele punktów instalacji logistycznych, skrytość operacji dostaw logistycznych – wiele konwojów o ograniczonej liczbie środków transportowych z wykorzystaniem wielu linii zaopatrzenia, niekoniecznie najkrótszych i najlepiej utrzymanych). Z drugiej zaś strony bezpieczeństwo zasobów wymaga minimalizacji energii (paliw) wymaganej dla sprzętu i uzbrojenia w wysuniętych lokalizacjach narażonych na oddziaływanie przeciwnika. Wymaga to efektywnego zarządzania dostawami paliw.
5. **Globalizacja procesów logistycznych**. Nie da się wyizolować logistyki wojskowej od logistyki cywilnej. Bez względu na stan pokoju, kryzysu czy wojny to logistyka wojskowa będzie ściśle powiązana łańcuchami dostaw z sektorem logistyki cywilnej, często o charakterze globalnym<sup>5</sup>. Wymusza to dostosowywanie procesów decyzyjnych w logistyce wojskowej do standardów obowiązujących w globalnym środowisku logistyki cywilnej (np. w zakresie identyfikacji produktu jak kody kreskowe GS1, tagi, kody radiowe EPC/RFID, technologie zarządzania logistyką on-line, czy wirtualne łańcuchy dostaw). Wymusza to interakcje w technologii AI niemal już powszechnie wykorzystywanej w logistyce cywilnej.

Wyżej wymienione czynniki wymuszają wręcz wykorzystanie AI do wsparcia logistycznych procesów decyzyjnych. Zarządzanie zasobami wojskowymi musi być skorelowane z globalną logistyką cywilną. Mam tu na uwadze czynnik ekonomiczny, uznawany w biznesie za kluczowy oraz mający coraz większe znaczenie aspekt ekologiczny, w szeroko rozumianej aktywności logistycznej określanej jako zrównoważony rozwój.

---

<sup>4</sup> Editors: Sonia Lucarelli; Alessandro Marrone; and Francesco Niccolò Moro “NATO Decision-Making in the Age of Big Data and Artificial Intelligence”, 2021 NATO HQ - Boulevard Léopold III, 1110 Brussels – Belgium.

<sup>5</sup> K. Ficoń, G. Krasnodębski, Nowoczesne technologie logistyczne jako źródło dodatkowych wartości w łańcuchu dostaw, Systemy Logistyczne Wojsk nr 48/2018.

Aktualna sytuacja geopolityczna nie pozostaje bez wpływu na wyzwania stojące przed logistyką wojskową. Utrzymanie w gotowości do działania (zgodnie z przeznaczeniem) współczesnych sił zbrojnych biorąc pod uwagę dynamicznie zmieniające się środowisko bezpieczeństwa, to w logistyce wojskowej oznacza ciągły proces decyzyjny mający za zadanie skutecznie reagować na zmieniające się potrzeby wojsk i potencjalne zagrożenia. Wzmoczona intensywność szkolenia wojsk, rozwijanie nowych zdolności (transformacja ilościowa i jakościowa sił zbrojnych), czy też działania polegające na demonstracji siły (ćwiczenia wojskowe na dużą skalę, manewry wojskiem, tymczasowa dyslokacja), wymagają zaangażowania dużych zasobów logistycznych w krótkim czasie, a więc szybkiej analizy i podejmowania trafnych decyzji. Zapewnienie siłom zbrojnym paliwa o odpowiedniej jakości i ilości, we właściwym czasie i miejscu, wykorzystując optymalnie posiadany potencjał w dynamicznie zmieniającym się środowisku staje się coraz większym wyzwaniem w procesach decyzyjnych stosujących najnowsze narzędzia.

Zasadnym zatem wydaje się teza o konieczności dokonania analizy możliwości wsparcia procesu decyzyjnego (WPD) zabezpieczania sił zbrojnych w paliwo jako podstawowego źródła energii przy zastosowaniu nowoczesnych rozwiązań opartych na technologii sztucznej inteligencji (AI).

## **2. WSPARCIE PROCESU DECYZYJNEGO (WPD) W LOGISTYCE WOJSKOWEJ**

Siły Zbrojne RP to złożona struktura składająca się z elementów kierowania i dowodzenia, wykonawczych, operacyjnych oraz elementów zabezpieczających i wspierających, których najważniejszą część stanowi logistyka wojskowa<sup>6</sup>. Jej zadaniem jest planowanie, przygotowanie oraz użycie środków zaopatrzenia, a także realizacja świadczeń oraz usług specjalistycznych w celu utrzymania wojsk w odpowiedniej gotowości bojowej<sup>7</sup>. Skuteczność tych działań będzie wynikiem właściwych decyzji podjętych przez dowódców/decydentów, często wypracowanych w złożonych procesach decyzyjnych.


Dalsze rozważania nad zagadnieniem wsparcia procesów decyzyjnych w zarządzaniu zasobami paliw wymagają doprecyzowania wykorzystywanych w tym celu pojęć. Zatem przyjmijmy, że decyzją określamy wybór spośród przynajmniej dwóch lub większej liczby możliwości (wariantów). Proces natomiast można zdefiniować jako

---

<sup>6</sup> M. Pawlisiak, System logistyczny Sił Zbrojnych Rzeczypospolitej Polskiej. Teoria i praktyka. Wydawnictwo Adam Marszałek, Toruń 2021.

<sup>7</sup> Doktryna Logistyczna Sił Zbrojnych RP D-4(B) Szkol. 965/2019.

przebieg następujących po sobie powiązanych przyczynowo skutkowych, stanowiących stany, fazy, etapy zmiany rzeczywistości<sup>8</sup>. Pojęcie procesu decyzyjnego w literaturze często przedstawia się jako czteroetapową sekwencję zmian zamkniętą w pętli uczenia się<sup>9</sup>:



Rys. 1. Cztery fazy procesu decyzyjnego [9]

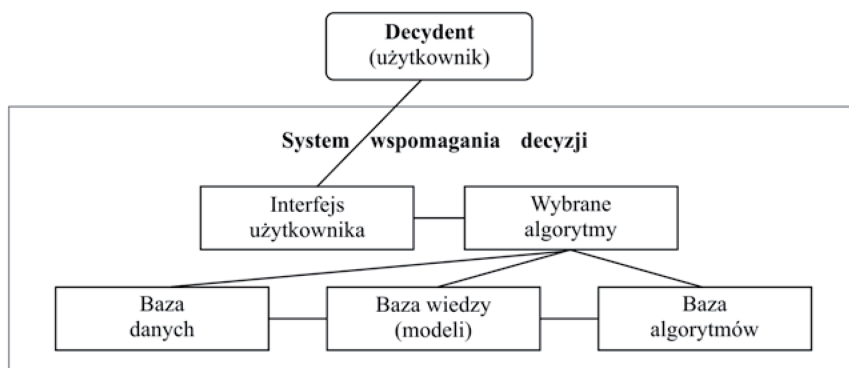
Oczywiście możliwe są inne podziały etapów procesu decyzyjnego, dostosowane do charakteru decyzji, złożoności sytuacji czy przyjętych metod wspomaganie tego procesu. Procesy decyzyjne w dziedzinie logistyki mają zwykle charakter wielokryterialny, czyli jest kilka wskaźników (kryteriów jakości) determinujących ocenę każdego z dopuszczalnych wariantów. Proces decyzyjny polega więc na znalezieniu kompromisu pomiędzy wskaźnikami dla osiągnięcia celu jakim jest wybór optymalnego wariantu. Etap wyboru to swoista interakcja człowiek – maszyna. Współczesne technologie informatyczne oparte na sztucznej inteligencji umożliwiają bardzo zaawansowane poziomy wsparcia procesu decyzyjnego z powodzeniem ograniczając lub wręcz wyłączając rolę człowieka-decydenta<sup>10</sup>. Problem ten szczególnie dotyczy obszaru zastosowań tych rozwiązań w środowisku militarnym. Problematyka ta została poruszona w publikacji NATO poświęconej procesom decyzyjnym w NATO w erze „Big data” i sztucznej inteligencji [4]. Zwrócono uwagę m.in. na zagrożenia wynikające z tendencji do pełnej automatyzacji procesów decyzyjnych, które z jednej strony usprawniają systemy dowodzenia i wsparcia wojsk, a z drugiej wymagają centralizacji i automatyzacji w zakresie analityki przetwarzania danych oraz podejmowania decyzji. Powoduje to poczucie wyobcowania człowieka, brak identyfikacji z realizowanym zadaniem, utratę umiejętności samodzielnego, kreatywnego działania i obniżenie morale, co w przypadku żołnierza w działaniach bojowych jest bardzo ważne. Nie bez znaczenia jest też aspekt etyczny ze względu na charakter podejmowanych decyzji mających bezpośredni wpływ na zdrowie i życie ludzkie. Dlatego też w dalszych rozważaniach nad docelowym modelem zastosowania sztucznej inteligencji do WPD w zarządzaniu nie tylko energią (paliwem), ale całym systemem zabezpieczenia

<sup>8</sup> Powierza L., Elementy inżynierii systemów. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 1997.

<sup>9</sup> Kaliszewski I. Wielokryterialne podejmowanie decyzji. Wydawnictwo Naukowo-Techniczne, Warszawa 2008.

<sup>10</sup> A.P. Wierzbicki, Teoria i praktyka wspomaganie decyzji, Wydawnictwa Uniwersytetu Warszawskiego, Warszawa 2018.

i wsparcia logistycznego SZ RP należy uwzględniać zidentyfikowane już zagrożenia. Szeroka implementacja najnowszych technologii opartych na „Big data” i sztucznej inteligencji wydaje się przesądzona w zarządzaniu logistyką wojskową SZ RP, jednak rozwój ten powinien opierać się na interaktywnym wspomaganiu decyzji, w którym decydent/dowódca jest nadrzędnym elementem systemu z przypisanymi kompetencjami na każdym poziomie dowodzenia i kierowania.



Rys. 2. Ogólny schemat systemu wspomagania decyzji. Źródło: A.P. Wierzbicki [4]

Schemat przedstawiony powyżej (Rys.2) w uproszczeniu określa system wspomagania decyzji jako narzędzie technologii informatycznej wspomagającej decydenta w procesie decyzyjnym wykorzystując bazy danych, wiedzy istotnej dla podejmowania określonej decyzji w formie bazy modeli sytuacji decyzyjnych (rzeczowych i preferencyjnych), a także bazę algorytmów dla przetwarzania i wykorzystania tych danych oraz modeli [4].

Nie bez znaczenia dla przebiegu procesu decyzyjnego jest rola interfejsu użytkownika, który poprzez zastosowane odpowiednich rozwiązań graficznych ma zapewnić przyjazny dla decydenta i efektywny dla procesu poziom interakcji człowiek-maszyna. Z doświadczenia dotychczas wdrażanych w SZ RP logistycznych systemów informatycznych wynika, że ten aspekt był często niedoceniany w projektowaniu narzędzi informatycznych. Skutkuje to w praktyce tym, że pomimo rozbudowy funkcjonalności systemu, dających coraz szersze możliwości analityczne posiadanych danych, ze względu na skomplikowany, mało przyjazny (nie intuicyjny) sposób ich użycia, nie są w pełni stosowane w procesach decyzyjnych, zwłaszcza na niższych szczeblach zarządzania.

### 3. SYSTEMY INFORMATYCZNE W SIŁACH ZBROJNYCH RP WSPIERAJĄCE PROCESY DECYZYJNE W LOGISTYCE WOJSKOWEJ

W SZ RP funkcjonuje kilka systemów informatycznych (SI) wykorzystywanych w różnym stopniu do wsparcia procesów decyzyjnych w obszarze zarządzania zasobami logistycznymi. Dąży się jednak do skupienia wszystkich niezbędnych do zarządzania logistyką funkcjonalności w jednym narzędziu informatycznym specjalnie dedykowanym na potrzeb logistyki wojskowej do pracy w środowisku narodowym - ZWSI RON<sup>11</sup> (*Zintegrowany Wieloszczeblowy System Informatyczny RON*). Drugim obowiązującym systemem informatycznym w obszarze logistyki wojskowej jest SI LOGFAS<sup>12</sup> (ang. *Logistic Functional Area Services*), będący oprogramowaniem sojuszniczym, przeznaczonym do wspierania zarządzania logistyką potrzeb operacyjnych. Systemy te równolegle rozwijane adekwatnie do identyfikowanych potrzeb i pojawiających się nowych rozwiązań technologicznych, wzajemnie zachowując zdolności interoperacyjne stając się podstawowymi narzędziami wspierania procesów decyzyjnych w logistyce wojskowej zarówno w czasie pokoju, wojny, czy też innych stanów pośrednich.

Zgodnie z doktryną NATO AJP-4.11<sup>13</sup> przedstawianie zasobów narodowych, wpływa na jakość wspólnego obrazu operacyjnego (COP – Common Operational Picture) i jest zdolnością niezbędną dla dowódcy (sztabu) do prowadzenia efektywnego procesu decyzyjnego. Zgodnie z Doktryną Logistyczną Sił Zbrojnych RP D-4(B) widzialność zasobów (ang. *asset visibility*), to zdolność do jednoczesnego określania aktualnego położenia w łańcuchu dostaw, a także ilości i statusu jednostek, personelu, sprzętu wojskowego oraz środków zaopatrzenia w trakcie ich operacyjnego wykorzystania. Zapewnienie dowódcy operacji odpowiedniej widzialności zasobów pozwala na identyfikację oddanych do jego dyspozycji środków, a także na określanie priorytetów w zakresie ich dystrybucji i redystrybucji na teatrze działań.

Widzialność zasobów może przyczynić się do poprawy procesów planowania i prowadzenia operacji, a także zarządzania ryzykiem w działaniach sił zbrojnych. Tak więc, widzialność zasobów powinna (w pełni lub częściowo) wspierać proces decyzyjny dowódcy poprzez umożliwienie mu:

1) określania priorytetów wsparcia i zabezpieczenia logistycznego działań z uwzględnieniem aktualnej sytuacji operacyjnej oraz logistycznej;

---

<sup>11</sup> ZWSI RON - Zintegrowany Wieloszczeblowy System Informatyczny wprowadzony do użytku Decyzja nr 8/MON z dnia 20.01.2012 r. w sprawie dopuszczenia do eksploatacji Zintegrowanego Wieloszczeblowego Systemu Informatycznego Resortu Obrony Narodowej (ZWSI RON) w jednostkach budżetowych resortu obrony narodowej.

<sup>12</sup> SI LOGFAS (Logistic Functional Area Services) wprowadzony decyzją MON w 2017 r. (DU-4.11.1).

<sup>13</sup> AJP-4.11 - Allied Joint Doctrine for NATO Asset Visibility. 21.02.2011 r.

- 2) identyfikowania i oceny zasobów będących w jego dyspozycji, a także efektywnego zarządzania nimi;
- 3) podejmowania optymalnych decyzji w sprawie dystrybucji i redystrybucji zasobów na teatrze działań w celu zabezpieczenia pilnych potrzeb;
- 4) usprawnienia procesu planowania działań;
- 5) zwiększenia elastyczności prowadzenia działań;
- 6) efektywnego zarządzania systemem logistycznym rozwiniętym na teatrze działań;
- 7) identyfikowania ograniczeń systemu logistycznego i podejmowania działań zaradczych w tym zakresie.<sup>14</sup>

Zakres widzialności obejmuje zasoby jednostek wojskowych uczestniczących w operacji, zasoby dostarczane na teatr działań, organizację przemieszeń i przewozów, zasoby zgromadzone w potencjale stacjonarnym (zapasy operacyjne i strategiczne), SpW będący w eksploatacji, przechowywaniu lub naprawie oraz zasoby infrastruktury.

W SZ RP widzialność zasobów logistycznych jest organizowana z wykorzystaniem logistycznych systemów informatycznych, w tym modułów funkcjonalnych systemu SI LOGFAS oraz ZWSI RON.

SI LOGFAS jest systemem sojuszniczym wykorzystywanym przez kraje członkowskie podczas prowadzenia działań w ramach NATO. SZ RP są zobowiązane posiadać zdolność wykorzystywania systemu do wspólnych operacji wojskowych w celu zapewnienia widzialności zasobów na teatrze dla dowódcy operacyjnego (w ramach potencjału mobilnego). SI LOGFAS jest również wykorzystywany w SZ RP do operacji narodowych oraz w ramach ćwiczeń i treningów przygotowujących jednostki wojskowe do działania zgodnie z przeznaczeniem.

Zasadniczym elementem SI LOGFAS jest baza danych LOGBASE profili sił i środków jednostek operacyjnych oraz moduł LOGREP (ang. *Logistic Reporting System*) przekazujący meldunki o zmianach ilościowych i jakościowych. Znajomość sił i środków w SI LOGFAS służy do budowy tzw. Rozpoznanego Obrazu Sytuacji Logistycznej (RLP, ang. *Recognised Logistic Picture*). Stany ewidencyjne środków zaopatrzenia i SpW (wraz z informacją o jego sprawności) są prowadzone w bazie LOGBASE za pomocą natowskich kodów pozycji sprawozdawczych RIC (ang. *Reportable Item Code*). Meldunki LOGREP są opracowywane od najniższych szczebli dowodzenia jednostek operacyjnych (batalion) i dalej przekazywane do stanowisk dowodzenia wyższych szczebli (aż do naczelnego dowódcy operacji). Na każdym szczeblu, informacja jest agregowana i służy do wypracowania decyzji o dalszym wysiłku działań.

Dodatkowo należy wyróżnić w SI LOGFAS moduły transportowe ADAMS, EVE i CORSOM, które dostarczają informacji o organizacji i terminach przemieszeń sił

---

<sup>14</sup> System informatyczny LOGFAS. Zasady funkcjonowania w resorcie obrony narodowej, DU-4.11.1(A) Logis 54/2024

i środków oraz przewozach SpW i środków zaopatrzenia – jest to istotna część zobrażenia RLP mająca wpływ na proces decyzyjny. Ewentualne zakłócenia w dostawach do wojsk operacyjnych mogą wpłynąć na decyzje i powodzenie operacji.

ZWSI RON jest systemem wykorzystywanym do zarządzania procesami i zasobami RON w obszarach funkcjonalnych logistyki, finansów i kadr. Choć obszary finansów i kadr są mocno powiązane z logistyką (wspierają zarządzanie zasobami osobowymi i finansami, generują lub zabezpieczają potrzeby wojsk), to nie będą oddzielnie analizowane w tym artykule.

Głównym celem ZWSI RON w podsystemie logistycznym jest efektywne i racjonalne kierowanie narodowym potencjałem logistycznym na wszystkich poziomach zabezpieczenia logistycznego, w tym zarządzanie zasobami logistycznymi w celu ich optymalnego wykorzystania. ZWSI RON w wojskowych oddziałach gospodarczych (WOG/OG) jest wykorzystywany do planowania i realizacji zabezpieczenia materiałowego i technicznego, w tym pozyskiwania zasobów, ich przechowywania i dystrybucji oraz realizacji innych usług logistycznych. W obszarze infrastruktury wojskowej system wspiera komórki infrastruktury WOG/OG w zakresie prowadzenia ewidencji zasobów infrastruktury, bieżącej eksploatacji oraz zarządzania nieruchomościami.<sup>15</sup>

W ZWSI RON zarządzanie zasobami logistyki obejmuje:

- SpW będący już na wyposażeniu jednostek wojskowych;
  - zapasy środków materiałowych i technicznych (w różnych klasach zaopatrzenia) na ewidencji wojskowych oddziałów gospodarczych (WOG/OG);
  - zasoby pozyskane w ramach realizacji planów zaopatrywania Sił Zbrojnych;
  - zasoby pobierane z gospodarki narodowej (świadczenia rzeczowe) w ramach Planu zabezpieczenia potrzeb Sił Zbrojnych realizowanych przez przedsiębiorców w sytuacjach kryzysu i wojny;
  - zasoby pozyskiwane w ramach NATO i UE (np. donacje).
- Korzyści dla logistyki SZ RP z wykorzystania ZWSI RON to:
- zintegrowanie obszarów funkcjonalnych logistyki, finansów i kadr – jedna centralna baza danych prowadzona przez wszystkie wojskowe oddziały gospodarcze;
  - stałe procedury i usprawnienie obiegu dokumentów w procesie zarządzania zasobami rzeczowymi;
  - skrócony czas obsługi kontrahentów (dostawców i odbiorców wojskowych i cywilnych) – szczególnie w obszarach informatyzacji logistyki, gdzie zastosowano nowoczesne techniki zarządzania (kody kreskowe, urządzenia ADC, elektroniczna wymiana danych funkcjonalnie zbliżona do EDI);
  - jednokrotna rejestracja zdarzenia gospodarczego;
  - dostarczenie rzetelnej informacji o stanie posiadanych zasobów poprzez dyktowane raporty i zestawienia;
  - agregacja informacji o posiadanych zasobach na różnych szczeblach organizacyjnych – z uwzględnieniem ról i uprawnień obszarowych i funkcjonalnych;

---

<sup>15</sup>Strona intranetowa Oddziału Logistycznych Systemów Informatycznych i Indeksacji

– pełna kontrola na poszczególnych etapach łańcucha dostaw z ich skutkami księgowymi – tzw. kontroling księgowy i nadzór logistyczny.

Istotnym elementem zapewniającym wykorzystanie ZWSI RON są funkcjonalności wspierające organy logistyki definiujące dane podstawowe, takie jak bazy indeksów zasobów rzeczowych i usług, normy należności, normy eksploatacyjne, przydziały gospodarcze oraz charakterystyki techniczne SpW (modele cyfrowe SpW).

W ZWSI RON identyfikacja zasobów wojska opiera się o Jednolity Indeks Materiałowy (JIM). Każdy typ wyrobu wykorzystywanego przez wojsko w systemach ewidencyjno-sprawozdawczych ma niepowtarzalny kod JIM, do którego można przypisać referencję do innych identyfikatorów krajowych i zagranicznych (NSN NATO, GTIN GS1, ASC MH10, grupy meldunkowe, kody sprawozdawcze).

W ramach integracji systemów ZWSI RON i LOGFAS przyjęto, że w systemie informatycznym JIM będą przechowywane wspólne powiązania kodów JIM i RIC. Również w bazach danych SI LOGFAS są stosowane indeksy JIM pod nazwą NIC (ang. *National Identity Code*). Zapewnienie wzajemnych korelacji indeksów materiałowych w systemach narodowym i sojuszniczym służy widzialności zasobów dowódcy operacji na różnych szczeblach organizacyjnych, w tym do przygotowania raportów / zestawień sił i środków do informowania operacyjnego niezależnie od nacji. ZWSI RON aktualnie obejmuje następujące podsystemy i obszary funkcjonalne logistyki:

- 1) zintegrowana ewidencji wojska – moduły MMSD i FIAA zasobów rzeczowych ZWSI RON;
- 2) podsystem materiałowy – moduł MZŻ służby żywnościowej, moduł PZM służby mundurowej, nowe funkcjonalności dla służby MPS, funkcjonalność limitów środków bojowych w ZWSI RON;
- 3) podsystem techniczny – moduł PWE wsparcia eksploatacji SpW;
- 4) podsystem magazynowy – moduł EWM ZWSI RON dla magazynów wielkopowierzchniowych wysokiego składowania oraz dedykowane funkcjonalności dot. modułu MMSD;
- 5) podsystem infrastruktury wojskowej – moduł PZN infrastruktury wojskowej;
- 6) podsystem medyczny – nowe funkcjonalności dla wojskowej służby zdrowia i WOFiTM Celestynów.

Dodatkowo od 2023 r. w ZWSI RON są budowane nowe obszary funkcjonalne systemu:

- 7) podsystem transportu i ruchu wojsk – moduł MT transportu w powiązaniu z systemem śledzenia zasobów;
- 8) zapewnienie widzialności zasobów w potencjale stacjonarnym logistyki na potrzeby operacji w wymiarze narodowym i sojuszniczym.

W podsystemie kierowania, logistyka wymaga od ZWSI RON, aby funkcjonalności jego dedykowanych modułów wspierały działalność dowództw jednostek logistycznych oraz organów kierowania logistyką i komórek planowania logistycznego na wszystkich poziomach dowodzenia i kierowania w RON. Odpowiednio zbudowane

moduły ZWSI RON mają zapewnić wsparcie wydzielonych struktur uczestniczących w procesie planowania operacyjnego w zakresie zabezpieczenia logistycznego.

Reasumując, aktualnie ZWSI RON jest podstawowym źródłem informacji o stanach ewidencyjnych zasobów resortu ON w obszarze logistyki i finansów, w tym SpW i przechowywanych zapasów do planowania i prowadzenia operacji w wymiarze narodowym. Jest to jednak narzędzie wciąż w fazie rozwoju. Inspektorat Wsparcia SZ w 2022 r. mając na uwadze zapewnienie pełnego spektrum widzialności zasobów logistycznych z wykorzystaniem SI LOGFAS (potencjał mobilny) i ZWSI RON (potencjał stacjonarny) rozpoczął prace nad integracją logistycznych systemów informatycznych w SZ RP oraz opracowaniem procedur obiegu informacji logistycznej w trakcie operacji. W tym celu zostały wykonane „Założenia na integrację ZWSI RON i SI LOGFAS” oraz „Wymagania na budowę interfejsów wymiany danych rzeczywistych pomiędzy ZWSI RON i SI LOGFAS”.

DKWOC od 2023 r. na bazie ww. założeń opracowuje nowe funkcjonalności ZWSI RON do wykorzystywania na potrzeby planowania i zabezpieczenia potrzeb mobilizacyjnych oraz zapewnienia widzialności zasobów wojsk własnych. Należą do nich:

- Plan Przydziałów Gospodarczych powiązany ze strukturą hierarchiczną jednostek wojskowych;
- definiowanie przez jednostki wojskowe potrzeb zapasów i SpW do mobilizacyjnego rozwinięcia;
- definiowanie przez organy logistyczne normatywów zapasów i SpW;
- określenie pokrycia normatywów SpW i zapasami w ewidencji RBLog/WOG/OG;
- generowanie asygnat mobilizacyjnych oraz eksport danych do SI LOGFAS (w celu utworzenia i utrzymania realnych baz danych jednostek operacyjnych).

Od 2023 r. nowo opracowane funkcjonalności ZWSI RON są testowane podczas treningów i ćwiczeń z jednostkami IWsp SZ. Ich zastosowanie pokazuje nową jakość widzialności zasobów dla pionów operacyjnych i logicznych stanowisk dowodzenia IWsp SZ, gdzie meldunki i informowanie operacyjne bazują na stanach ewidencyjnych w logistycznych systemach informatycznych. W DKWOC wciąż trwają prace projektowe nad rozwojem ww. nowych funkcjonalności ZWSI RON w takim zakresie, aby zapewnić dodatkowe raporty i zestawienia dedykowane dla poszczególnych branż i służb funkcjonujących w IWsp SZ – jest to proces złożony i wymagający zaangażowania ze strony DKWOC i IWsp SZ. Efektem docelowym jest wdrożenie nowych funkcjonalności ZWSI RON do systemu produkcyjnego ZWSI RON i zbudowanie realnych baz danych SI LOGFAS jednostek operacyjnych do końca 2026 r.

W Siłach Zbrojnych funkcjonują jeszcze inne logistyczne systemy informatyczne, których funkcjonalności powinny być przejęte (zintegrowane) przez ZWSI RON. Dotyczy to następujących narzędzi informatycznych:

1. System Informatycznego Wsparcia Eksploatacji Statków Powietrznych SAMANTA<sup>16</sup> jest przeznaczony do:

– gromadzenia i przetwarzania danych dotyczących przebiegu procesu eksploatacji wojskowych statków powietrznych (SP), zgodnie z przepisami o sprawozdawczości w Siłach Zbrojnych w zakresie ustalonym przez Organizatora systemu oraz przepisami służby inżynieryjno-lotniczej i dokumentacją pokładową statków powietrznych;

– prowadzenia analizy bieżącej i okresowej procesów eksploatacji SP w zakresie niezawodności i bezpieczeństwa techniki lotniczej, stanów eksploatacyjnych SP oraz zarządzania zasobami ich pracy.

2. SI KONWÓJ<sup>17</sup> jest programem komputerowym, wspomagającym zadania realizowane przez organy podsystemu transportu i ruchu wojsk SZ RP oraz jednostki wojskowe, realizujące przewozy środków zaopatrzenia materiałowego i technicznego. Jego zasadniczym zadaniem jest wsparcie procesu wydawania zezwoleń na przejazd drogowy oraz monitoring przemieszczania wojsk (przejazd pojazdu nienormalnego, przewożącego towary niebezpieczne oraz kolumn) w czasie rzeczywistym.

3. System informatyczny Local Budget Planning Program (SI LBPP)<sup>18</sup>, który:

– wspomaga procesy zarządzania budżetem, planowania zasobów, usług i robót budowlanych oraz planowania działalności w zakresie dotyczącym opracowania części tabelarycznej do zamiaru;

– umożliwia przetwarzanie danych jawnych w zakresie procesów związanych z zarządzaniem budżetem;

– umożliwia przetwarzanie danych niejawnych do klauzuli ZASTRZEŻONE<sup>19</sup> włącznie w zakresie procesów związanych z systemem planowania zasobów, usług i robót budowlanych oraz planowania działalności w zakresie dotyczącym opracowania części tabelarycznej do zamiaru.

Niewątpliwie wdrożenie tych funkcjonalności oraz realizacja zaplanowanych prac rozwojowych zdecydowanie podniesie poziom wykorzystania ZWSI RON do wspierania procesów decyzyjnych w zarządzaniu logistyką wojskową.

Oczekiwania od współczesnej logistyki wojskowej w zakresie zarządzania jej potencjałem jednak wciąż rosną i aktualnie realizowane projekty w tym obszarze są niewystarczające i wymagają ukierunkowania na zwiększenie analitycznych możliwości systemu wykorzystując posiadane i zbierane dane w trybie choćby zbliżonym do czasu rzeczywistego (on-line). Osiągnąć to można jedynie przez implementację najnowszych technologii informatycznych opartych na „Big data” i sztucznej inteligencji.

---

<sup>16</sup> Załącznik E do Szczególnych Wymagań Bezpieczeństwa Systemu Teleinformatycznego MIL-WAN dla Systemu Informatycznego SAMANTA.

<sup>17</sup> Instrukcja operacyjnego wykorzystania teleinformatycznego systemu monitorowania położenia wojsk SI KONWÓJ DU-4.4.4.2.


<sup>18</sup> Rozkaz Szefa IWsp SZ nr 172 z dnia 14 lipca 2015 roku wdrożenia do eksploatacji użytkowej systemu informatycznego Local Budget Planning Program — SI LBPP.

#### 4. PROCES DECYZYJNY ZAPEWNIENIA ENERGII DLA WOJSK W SZRP NA PRZYKŁADZIE ZARZĄDZANIA ZASOBAMI PALIWA

W tej części publikacji przedstawiam na przykładzie zarządzania zasobami paliwa, aktualny stan zaawansowania procesu informatyzacji logistyki wojskowej – **DZISIAJ**. Należy zdawać sobie sprawę, że cele postawione przed SI ZWSI RON nie zostały jeszcze osiągnięte, więc obraz stanu nie byłby obiektywny bez opisanie działań i nakreślonych celów do osiągnięcia w najbliższych latach, umownie nazywane jako – **JUTRO**. Ta syntetyczna analiza skupiona jest na ocenie wdrożonych DZISIAJ i planowanych JUTRO rozwiązań informatycznych (również organizacyjnych) pod kątem efektywności wsparcia procesów decyzyjnych w zarządzaniu zasobami paliwa.

Na podstawie Decyzji nr 8 MON z dnia 20 stycznia 2012 r. został wdrożony w jednostkach budżetowych resortu obrony narodowej Zintegrowany Wieloszczeblowy System Informatyczny. Celem projektu była budowa i wdrożenie scentralizowanego, zintegrowanego i zunifikowanego systemu informatycznego wspomagającego zarządzanie wieloma obszarami funkcjonalnymi Sił Zbrojnych.

W zakresie zarządzania zużyciem paliw znaczący wpływ miało wprowadzanie od 2016 r. podsystemu wsparcia eksploatacji (PWE). Od tego czasu wprowadzane są informacje pozwalające na identyfikację eksploatacji pojedynczego egzemplarza sprzętu wojskowego. Widoczny na wykresie (Rys. 3) wzrost ilości wprowadzanych rekordów wynika z wdrożenia znacznej ilości SpW do PWE. Mając na uwadze dynamiczny wzrost liczby pozyskiwanego SpW należy oczekiwać dalszego stałego wzrostu wprowadzanych rekordów do systemu.

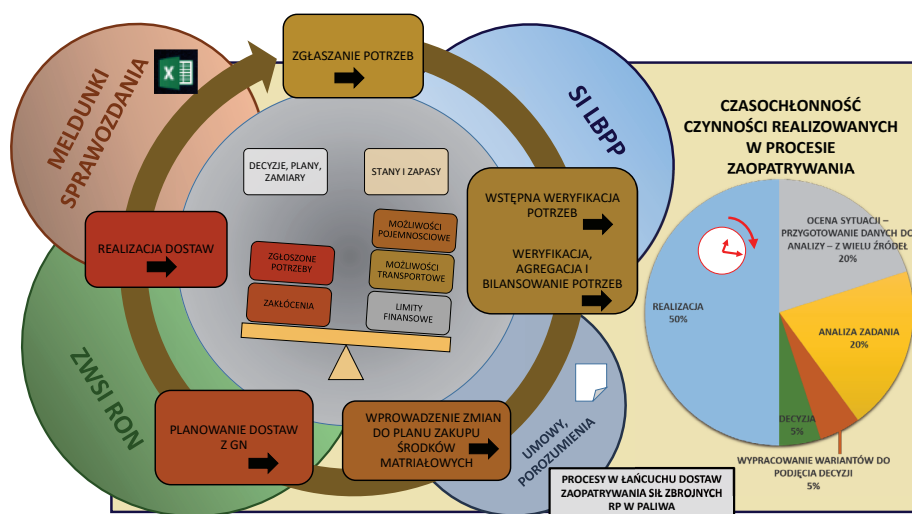


Rys. 3. Liczba rekordów wprowadzonych do ZWSI RON w dziale MPS w latach 2012-2023

Dane zawarte w SI ZWSI RON aktualnie pozwalają na:

- pozyskanie informacji w zakresie dostaw oraz stanów magazynowych paliw (wg rodzaju zapasu);
- zarządzanie jakością paliw;
- pozyskanie informacji w zakresie zużycia paliw, w tym na zdefiniowane przedsięwzięcia (np. ćwiczenia) oraz informacji o paliwach przekazanych wojskom sojuszniczym.

DZISIAJ, oprócz SI ZWSI RON, który eksploatowany jest głównie na poziomie jednostek zaopatrujących, używane są funkcjonujące niezależnie systemy informatyczne i informatyczne bazy danych: system pozyskiwania potrzeb (SI LBPP), meldunki i sprawozdania (EXCEL), narzędzia ewidencjonujące zapotrzebowania bieżące (EXCEL, ACCESS) oraz papierowe lub zdigitalizowane (np. pdf) zapotrzebowania, decyzje, zarządzenia. W związku z dużym rozproszeniem informacji znajdującej się w różnych dokumentach, plikach, systemach analiza sytuacji logistycznej (zabezpieczenia w potrzeby) musi być poprzedzona czasochłonnym przygotowaniem danych (Rys. 4). Wskazane w artykule procentowe podziały czasu w procesie zarządzania paliwem mają charakter poglądowy, a zawarte w nich proporcje oparte są na konsultacjach z osobami funkcyjnymi różnych szczebli zarządzania procesem oraz osobistym doświadczeniem autora.

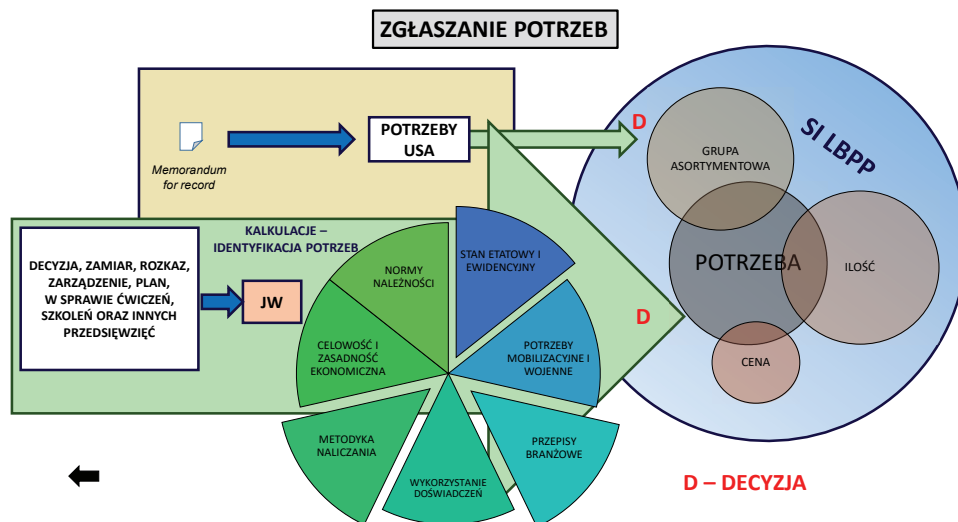


Rys. 4. Proces zarządzania zaopatrywaniem Sił Zbrojnych RP w paliwo – DZISIAJ (opracowanie własne)

Weryfikacja, agregacja i bilansowanie zgłoszonych potrzeb paliw oraz analiza możliwości ich zabezpieczenia, poprzedzona przygotowaniem danych z decyzji, planów i zamiarów wobec stanów ewidencyjnych zasobów i utrzymywanych zapasów,

z ujęciem możliwości transportowych i pojemnościowych, w ramach limitu planu finansowego oraz gotowości na ewentualne zakłócenia odbywa się w oparciu o system planowania potrzeb (SI LBPP), meldunki i sprawozdania oraz SI ZWSI RON.

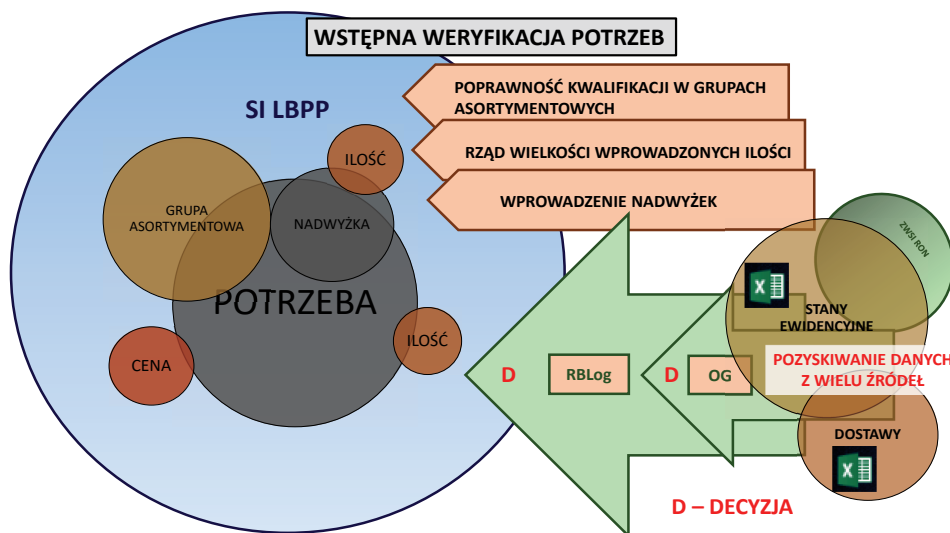
Z tego powodu **DZISIAJ** przygotowanie danych do podjęcia decyzji odbywa się kosztem czasu na analizę i podjęcie decyzji. W konsekwencji skraca się czas na realizacji zadania przez wykonawców.



Rys. 5. Schemat procesu zgłaszania potrzeb z identyfikacją punktów decyzyjnych D – DZISIAJ (opracowanie własne)

Zgodnie z Decyzją Nr 118/MON z dnia 1 września 2021 r. w sprawie zasad opracowywania i realizacji centralnych planów rzeczowych (Dz. Urz. Min. Obr. Nar. poz. 190 z późn. zm.) oraz Wytocznymi Szefa Inspektoratu Wsparcia SZ z dnia 12 października 2022 roku w sprawie określenia szczegółowych zasad planowania potrzeb w SZ na 18 miesięcy przed rokiem planowym, inicjowany jest proces wprowadzenia przez JW. potrzeb w zakresie m.in. paliw płynnych niezbędnych do realizacji zaplanowanych zadań. Na etapie wprowadzenia danych do systemu SI LBPP następuje wstępna weryfikacja prawidłowości wprowadzenia danych zgodnie z zasadami. Wstępne dane z SI LBPP pokazują skalę finansową realizacji zadań postawionych JW. (Rys. 5).

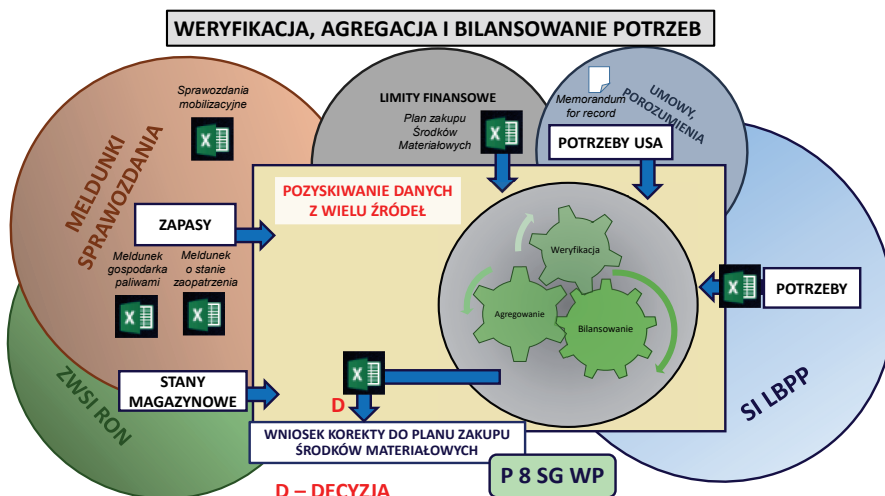
Dopiero weryfikacja i analiza na szczeblu Inspektoratu Wsparcia SZ (IWsp SZ) przedstawia zakres ilościowy zakupu paliw płynnych dostosowanych do zgłoszonych potrzeb, ponieważ system nie uwzględnia stanów magazynowych posiadanych paliw płynnych, a jedynie pokazuje koszty wykonania powierzonych zadań.



Rys. 6. Schemat procesu wstępnej weryfikacji potrzeb paliwa – DZISIAJ (opracowanie własne)

Wstępna Weryfikacja Potrzeb polega na sprawdzeniu poprawności kwalifikacji potrzeb w grupach asortymentowych, rzędu wielkości wprowadzonych ilości oraz wprowadzenia ewentualnych nadwyżek.

Realizowana jest przez OG i RLog (Rys. 6).



Rys. 7. Schemat procesu weryfikacji, agregacji i bilansowania potrzeb – DZISIAJ (opracowanie własne)

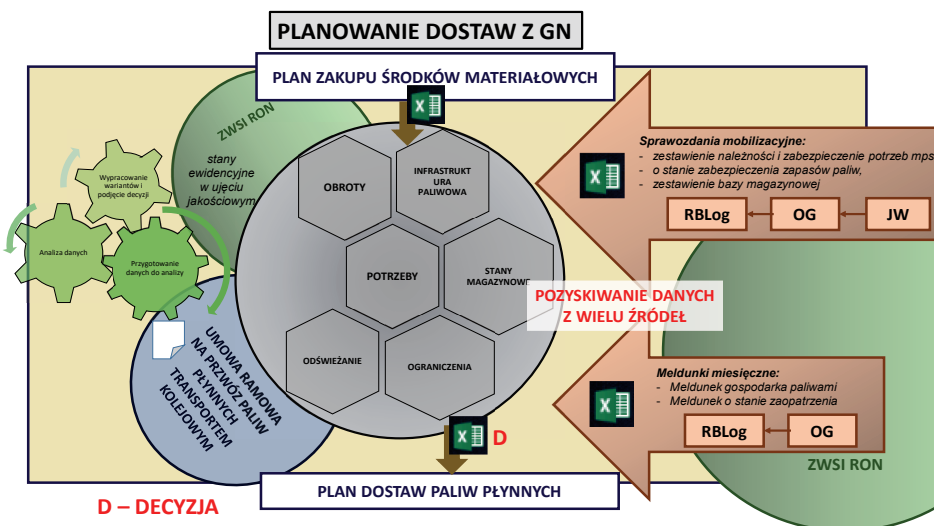
Po zakończeniu etapu wstępnej rejestracji potrzeb w SI LBPP, na sześć miesięcy przed rokiem planowym (w procesie ciągłym do końca roku przedplanowego), w IWsp SZ dokonywana jest analiza ilościowych potrzeb zakupu paliw płynnych, na podstawie:

- zweryfikowanych, zgłoszonych potrzeb paliw płynnych w SI LBPP przez JW.;
- zgłoszonych potrzeb fizycznego zabezpieczenia paliw płynnych dla wojsk USA - Memorandum for Record;
- utrzymania nakazanych normatywnych zapasów;
- analizy porównawczej stopnia wykorzystania przydzielonych dla SZ RP limitów zużycia paliw płynnych w latach poprzednich oraz zgłoszonych potrzeb w tym zakresie na rok następny;
- stanów magazynowych zaksięgowanych w ZWIS RON na początek roku oraz przewidywanych stanów posiadania na koniec roku, w którym jest analiza;
- dostępności bazy magazynowej – wyłączenia składów / oddanie nowych obiektów itp.;
- przydzielonych limitów finansowych na zakup materiałów pędnych i smarów w PZŚM, w tym bieżących cen dostaw paliw płynnych zmieniających się z częstotliwością tygodniową.

Wówczas generowane są wnioski korekt do Planu Zakupów Środków Materiałowych (PZŚM), przedstawiające niezbędne ilości paliw płynnych, które należy planować do zakupu celem utrzymania nakazanych zadań i zamierzeń. Na tej podstawie tworzony jest plan dostaw paliw płynnych, który jest m.in. częścią składową do zamówień publicznych przy ich zakupie (Rys.7).

Kolejnym etapem jest planowanie dostaw z gospodarki narodowej (GN). Sporządzenie „Planu dostaw paliw płynnych” z GN (Rys.8) realizowane jest z uwzględnieniem:


- a. dostępnej infrastruktury paliwowej:
  - wolnej pojemności zbiornikowej możliwej do wykorzystania;
  - planowanych prac serwisowych i legalizacyjnych (GUM, WDT) wymagających opróżnienia zbiorników;
  - „Zestawienie bazy magazynowej Służby MPS w .... wg stanu na dzień 01. stycznia ... roku”;
- b. Planu odświeżania paliw (Książka ewidencji odświeżania i kontroli jakości mps - z ZWSI RON-a w zakresie zaopatrywania Baz Lotniczych ze składów RBLog określonym rodzajem transportu w pierwszych miesiącach roku, przed uruchomieniem dostaw z GN) - zapewnienie ciągłości zaopatrywania lotnictwa oraz utrzymanie jakości poprzez odświeżanie.
- c. wielkości obrotów materiałowych w Składach RBLog i Lotniskowych Składach Paliwowych (potrzeby roczne Baz Lotniczych- limit);
- d. znanych wyłączeń z eksploatacji cywilnych i wojskowych bocznic kolejowych.



Rys. 8. Schemat przedstawiający proces planowania dostaw paliw z GN – DZISIAJ (opracowanie własne)

Po zakończeniu całego cyklu planistycznego, wymagającego użycia niezależnych, niezintegrowanych narzędzi informacyjnych oraz meldunków, zapotrzebowań, sprawozdań, planów, harmonogramów i innych dokumentów w formatach pdf, excel czy nawet papierowych, przechodzimy do etapu realizacji dostaw.

W trakcie realizacji dostaw główne zadania służb MPS koncentruje się na monitorowaniu przebiegu dostaw oraz ich weryfikacji (Rys.9). Opiera się to zasadniczo na meldunku „Gospodarka paliwami w rejonie ... RBLog... wg stanu na dzień ...” składanym w cyklu miesięcznym, przedstawiającym wykorzystanie infrastruktury paliwowej składów RBLog i lotniskowych składów paliw w zakresie pojemności bazy paliwowej możliwej do wykorzystania oraz czasowo wyłączonej z użytkowania, stanu ewidencyjnego oraz planowanych i zrealizowanych dostaw paliw.

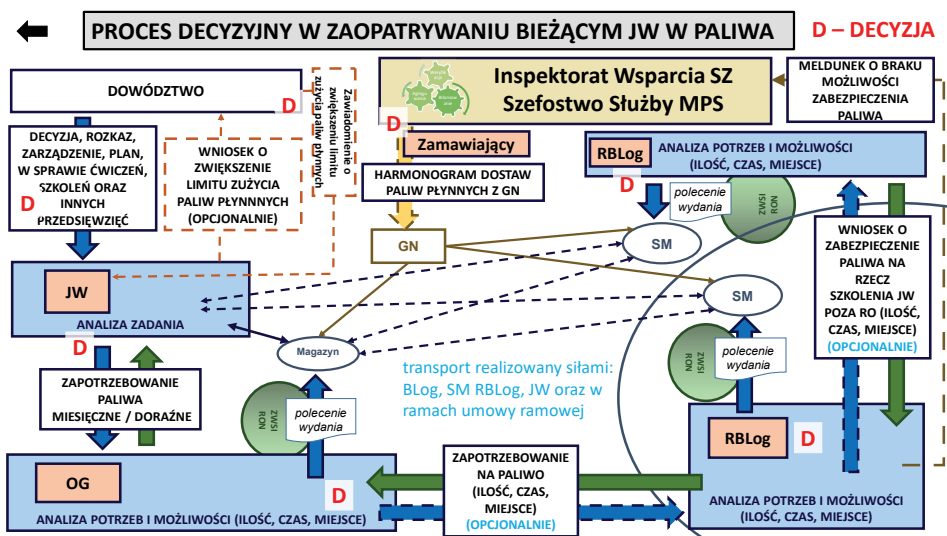


Rys. 9. Schemat procesów monitorowania i weryfikacji realizowanych dostaw paliwa z GN – DZISIAJ (opracowanie własne)

W celu potwierdzenia możliwości realizacji planu dostaw oraz wprowadzenia korekty dostaw w poszczególnych miesiącach Zamawiający (RBlog) weryfikuje w cyklu miesięcznym możliwości odbiorców poprzez system „zapotrzebowań” (wniosków zmian do planu) składanych przez RBlog za składy i bazy lotnicze z rejonu odpowiedzialności (RO). W przypadku odchyień między planem, a możliwościami odbiorcy lub dostawcy Szefostwo Służby MPS IWspSZ określa priorytety i sposób realizacji. Następnym etapem w zarządzaniu zasobami paliwa jest jego dystrybucja ze składów RBlog do punktów odbiorczych w RO. Zadania te realizowane są na podstawie „Planu Zaopatrywania w mps w RO RBlog na rok...” weryfikowanego w cyklu miesięcznym poprzez zapotrzebowania z WOG i jednostek pełniących funkcję OG w następujący sposób:

- transportem BLog (plan dowozu na miesiąc);
- transportem składów RBlog wspomagająco;
- transportem Jednostek Wojskowych i WOG (w szczególności podczas zabezpieczenia szkolenia poligonowego);
- wybranymi rodzajami środków transportowych pomiędzy składami RBlog, a lotniskowymi składami mps (umowa ramowa na transport paliw płynnych podpisana przez RBlog).

Dochodzimy w tym miejscu do najistotniejszego etapu w zarządzaniu zasobami paliwa z perspektywy procesów decyzyjnych, czyli bieżące zaopatrywanie wojsk w paliwa. Na Rys.10 przedstawiono schematycznie przebieg całego procesu decyzyjnego realizowanego przez decydentów/dowódców (D) na wielu szczeblach uczestniczących w zarządzaniu procesem.



Rys. 10. Schemat przedstawia proces decyzyjny w zaopatrzeniu bieżącym jw. w paliwa (opracowanie własne)

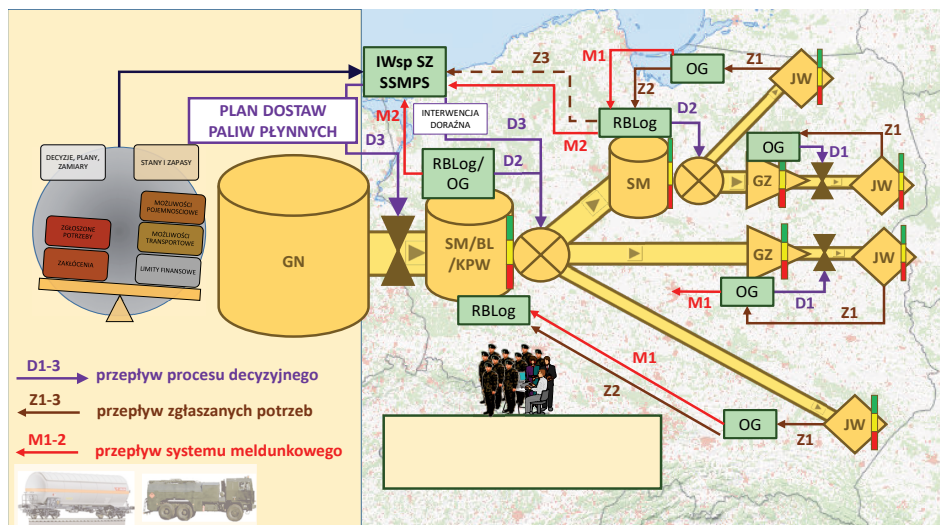
Jednostki operacyjne, po otrzymaniu zadania i jego analizie, składają zapotrzebowania do oddziałów gospodarczych, w których zabezpieczane są zaplanowane jak i dorażne potrzeby. Oddziały gospodarcze zabezpieczają potrzeby jednostek operacyjnych w ramach posiadanych zasobów, w przypadku braku możliwości zabezpieczenia – składają zapotrzebowanie do RBlog. RBlog dokonuje analizy i decyduje o sposobie zabezpieczenia potrzeby a w przypadku braku możliwości zabezpieczenia potrzeb, w ramach „manewru materiałowego”<sup>19</sup> występuje do innego RBlog. Jeśli potrzeba nie może zostać zabezpieczona w ramach zasobów posiadanych w RBlog-ach, lub zakupów własnych – RBlog występuje do IWsp SZ o zabezpieczenie potrzeby.

Ponadto równolegle funkcjonuje system meldunkowo-sprawozdawczy w cyklu miesięcznym, kwartalnym i rocznym.

Analiza procesów decyzyjnych w zarządzaniu zasobami paliwa DZISIAJ wykazuje, że duża część tych procesów odbywa się poza głównym narzędziem - SI ZWSI RON, co wynika z jego ograniczeń - braku określonych funkcjonalności. Wykorzystuje się więc niezintegrowane z nim systemy „pomocnicze”, a system sprawozdawczy i meldunkowy jest w dużej mierze „analogowy” (format pdf, excel, czy wersje papierowe). Wymusza to pracochłonne wprowadzanie danych i opóźnienie w aktualizacji stanu rzeczywistego, który zwłaszcza w sytuacjach niestandardowych (zakłóceń, pilnych potrzeb) jest niezbędny do analizy i wypracowywania decyzji. Cykle meldunkowe miesięczne i kwartalne nie zapewniają aktualnej informacji o stanie realizacji

<sup>19</sup>Instrukcja o gospodarce materiałowej służby materiałów pędnych i smarów (DU-4.21.3), MON/IWspSZ. Warszawa 2019.

zadań czy zasobów. Gdy zachodzi taka potrzeba, zapewniane jest to w trybie meldunków doraźnych (Rys. 11).



Rys. 11. Procesy decyzyjne w łańcuchu zaopatrzenia Sił Zbrojnych RP w paliwa – DZI-SIAJ (opracowanie własne)

Schemat obrazujący przepływy informacji (rozkazodawcze, sprawozdawcze/ za-potrzebowujące, meldunkowe) w procesach decyzyjnych na rysunku 11 został przedstawiony na tle łańcucha zaopatrzenia w paliwo Sił Zbrojnych RP. Wniosek z analizy tych procesów rysuje się następujący: **DZISIAJ pomimo zwiększanych zasobów danych oraz funkcjonalności w SI ZWSI RON umożliwiającym zarządzanie zasobami (stan, jakość, zużycie), to brak automatyzacji procesów wprowadzania i analizy danych w czasie zbliżonym do rzeczywistego, w sposób istotny ogranicza zdolność systemu do oczekiwanego poziomu wsparcia procesów decyzyjnych w zarządzaniu paliwami.** Wynika to między innymi z używania wielu niezintegrowanych kanałów przepływu informacji (np. różne wspomagające SI, czy też formaty dokumentów) oraz braku rozwiniętych funkcji analitycznych, pozwalających na optymalne wykorzystanie posiadanych już danych w systemie.

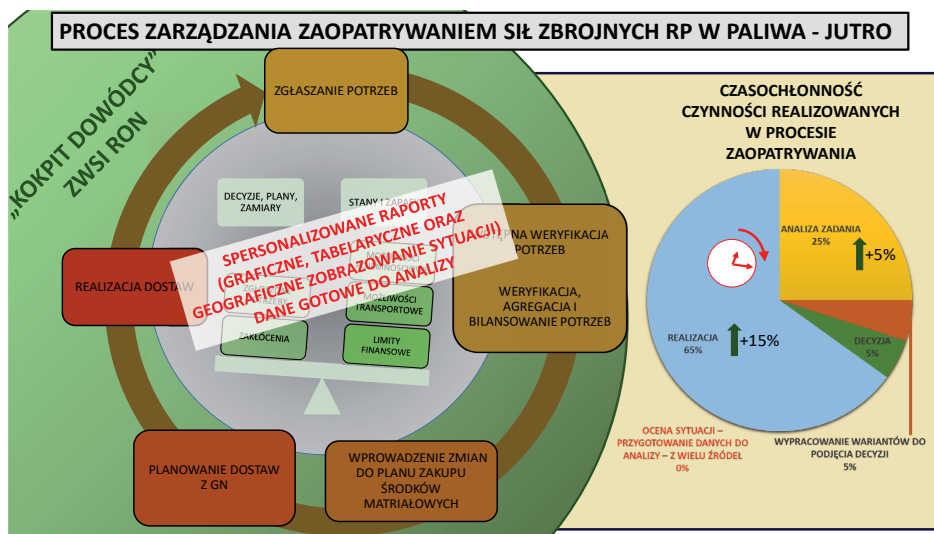
### JUTRO, czyli kokpit dowódcy.

ZWSI RON, w którym z roku na rok wprowadzanych jest coraz więcej informacji, może być wykorzystany jako narzędzie do automatycznego przedstawiania danych gotowych do analizy. Technologia SAP FIORI pozwala na przygotowanie na poziomach zaopatrzenia (oraz dowodzenia – w ramach wprowadzanych wieloszczeblowych funkcjonalności) spersonalizowanych raportów, dedykowanych konkretnym

osobom funkcyjnym do przeprowadzania analizy sytuacji i wypracowania wariantów do podjęcia decyzji, poprzez wprowadzane obecnie narzędzie określane jako „kokpit dowódcy”<sup>20</sup>).

Aktualnie trwają prace nad definiowaniem raportów zapewniających informacje otrzymywane dotychczas w meldunkach i sprawozdaniach. Do efektywnego wykorzystania „kokpitu dowódcy” niezbędne jest zintegrowanie funkcjonujących obecnie w SZ RP opisanych wcześniej wspomagających systemów informatycznych z SI ZWSI RON oraz wdrożenie do niego „pomocniczo” prowadzonych baz danych.

Pełna funkcjonalność pozwoli nie tylko na bieżące monitorowanie zasobów, ale również na monitorowanie zdarzeń i reakcji w zabezpieczaniu potrzeb jednostek operacyjnych. W ten sposób w SI ZWSI RON zostanie zaewidencjonowane powiązanie: „zdarzenie – reakcja”.



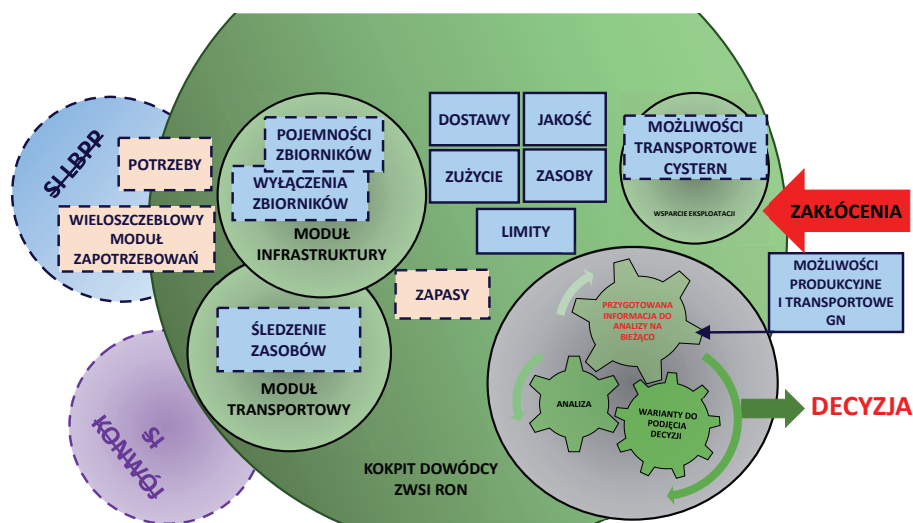
Rys. 12. Proces zarządzania zaopatrzeniem Sił Zbrojnych RP w paliwo – JUTRO

Weryfikacja, agregacja i bilansowanie zgłoszonych potrzeb paliw oraz analiza możliwości ich zabezpieczenia, poprzedzona przygotowaniem danych z decyzji, planów i zamiarów wobec stanów ewidencyjnych zasobów i utrzymywanych zapasów, z ujęciem możliwości transportowych i pojemnościowych, w ramach limitu planu finansowego oraz gotowości na ewentualne zakłócenia odbywać będzie się w oparciu o ZWSI RON przy użyciu spersonalizowanego narzędzia „kokpit dowódcy”.

<sup>20</sup> „Kokpit dowódcy ZWSI RON jako element wsparcia procesu decyzyjnego” artykuł DKWOC – <https://www.wojsko-polskie.pl/woc/articles/publikacje-r/kokpit-dowodcy-zwsi-ron-jako-element-wsparcia-procesu-decyzyjnego/> (wejście 10.03.2024 r.).

Przy założeniu pełnej integracji systemów JUTRO zostanie zaoszczędzony czas poświęcony dotychczas przygotowaniu danych do analizy, na rzecz procesów analitycznych i przede wszystkim samej realizacji zadania po podjęciu decyzji (Rys.12).

Monitorowanie bieżące zasobów może być realizowane poprzez kokpit dowódcy w narzędziu SAP FIORI i docelowo zastąpić dotychczasową sprawozdawczość (meldunki i sprawozdania cykliczne). Aktualnie istnieje możliwość raportowania z ZWSI RON, aż do informacji o zasobach i ich jakości, dostawach, zużyciu oraz wykorzystaniu limitów zużycia paliw płynnych. Trwają prace nad implementacją „przyjaznych” raportów, które zobrazują dane znajdujące się w systemie ZWSI RON na potrzeby dowodzenia i kierowania zaopatrywaniem SZ w paliwa, gdzie osoba funkcyjna otrzymuje dedykowane dane poprzez „kliknięcie” odpowiedniego okna raportu i bardzo uproszczone (w stosunku do standardowych raportów ZWSI RON) wskazanie zakresu informacji.



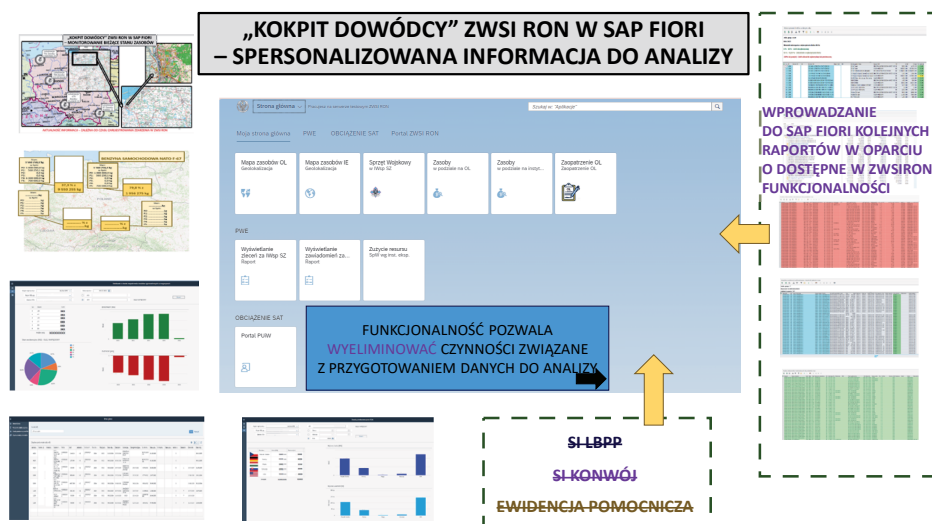
Rys. 13. Funkcjonalności SI ZWSI RON w Kokpicie dowódcy jako narzędzie wsparcia procesu decyzyjnego w zarządzaniu paliwem. Linia przerywana wskazuje funkcje do zintegrowania wg stanu na JUTRO (opracowanie własne)

Dane w ZWSI RON mogą być nieaktualne, w związku z odstępem czasowym między powstaniem zdarzenia, a jego rejestracją (zaksięgowaniem dokumentu materiałowego). W tym celu podjęto działania i zostały wprowadzone rozwiązania skracające czas rejestracji zdarzeń jak EDR, tankomaty, „szybkie” transakcje z uproszczonymi interfejsami oraz elektroniczna wymiana plików zapewniająca wykorzystanie danych już wprowadzonych do ZWSI RON. Podejmuje się również prace nad kolejnymi funkcjonalnościami m.in. funkcjonalnością do podpisu elektronicznego i elektronicznego

przesyłania dokumentów oraz „przybliżenia” miejsca rejestracji zdarzeń do miejsca ich powstawania, tj. implementację rozwiązania EDR w wersji online w magazynach posiadających infrastrukturę teleinformatyczną MILNET-Z. Warunkiem koniecznym jest uzyskanie w SI ZWSI RON zdolności automatycznego gromadzenia i przetwarzania informacji (Rys.13).

Pożądanym efektem JUTRO jest proste, szybkie i rzetelne obrazowanie danych z ZWSI RON, również w zakresie zgłaszanych potrzeb (integracja ZWSI RON i SI LBPP), normatywów i zapasów (przy okazji integracji ZWSI RON z LOGFAS), śledzenia zasobów (aktualnie w SI KONWÓJ), możliwości transportowe cystem (po wdrożeniu do PWE ZWSI RON), informacji o wolnej pojemności zbiorników (w zintegrowaniu z modułem infrastruktury) oraz implementacji wieloszczeblowego modułu zapotrzebowań.

SAP FIORI dysponuje narzędziem oferującym wysoce intuicyjny sposób wykorzystania danych znajdujących się na serwerach ZWSI RON (po odpowiednim zdefiniowaniu struktury raportów).

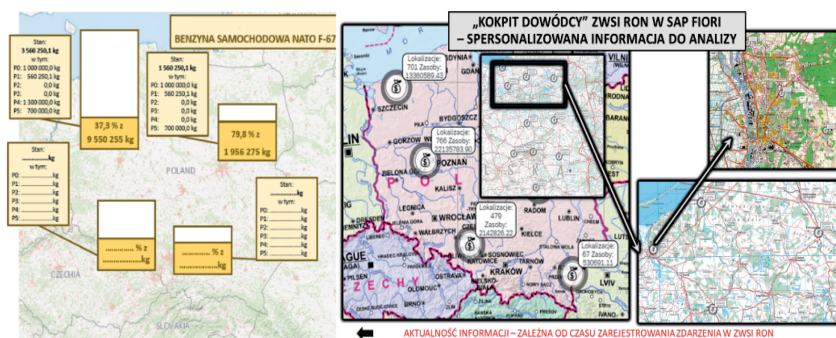


Rys. 14. Kokpit dowódcy w SI ZWSI RON – wykorzystanie technologii SAP FIORI do personalizowania informacji do analiz (opracowanie własne)

Kokpit dowódcy stanowić ma zobrazowanie danych znajdujących się w SI ZWSI RON na potrzeby dowodzenia i kierowania, gdzie osoba funkcyjna otrzymuje dedykowane dane poprzez „kliknięcie” odpowiedniego okna raportu i jak i w formie bardzo uproszczonej w stosunku do standardowych raportów ZWSI RON (Rys.14). Z tego powodu koniecznym jest sukcesywne wdrażanie do ZWSI RON „pomocniczo” prowadzonej ewidencji oraz integracja wszystkich stosowanych w resorcie systemów informatycznych.

Gospodarka paliwami w zobrazowaniu na mapie Polski pokaże pojemności i napętnienie poszczególnych zbiorników oraz ich sumę w zależności od obserwowanego obszaru. Stan paliw będzie podzielony wg rodzaju zapasu, a w szczegółach zbiorników cechy partii paliw. Funkcjonalność budowana jest w oparciu o moduł infrastruktury, a docelowo planowane jest również wprowadzenie informacji o danych dozorowych i metrologicznych zbiorników (Rys. 15).

Powyższe informacje dostępne będą na poziomie OG, RBLog i IWsp SZ odpowiednio za rejon zaopatrywania. Stan zaopatrzenia jest meldunkiem wskazującym zasoby w podziale na rodzaj zapasu, informację o rocznym zużyciu w odniesieniu do rocznych dostaw, a informacje będą dostępne na poziomie OG, RBLog i IWsp SZ odpowiednio za rejon zaopatrywania.



Rys. 15. Kokpit dowódcy w SI ZWSI RON. Zobrazowanie na mapie gospodarki paliwami (opracowanie własne)

Analogicznie w przygotowywaniu jest meldunek o ilości paliw przekazanych poza RON, wg narodowości odbiorcy. Po wskazaniu rodzaju paliwa i wprowadzeniu zakresu czasowego zostanie wygenerowana informacja o ilości i wartości zasobów przekazanych poza RON.

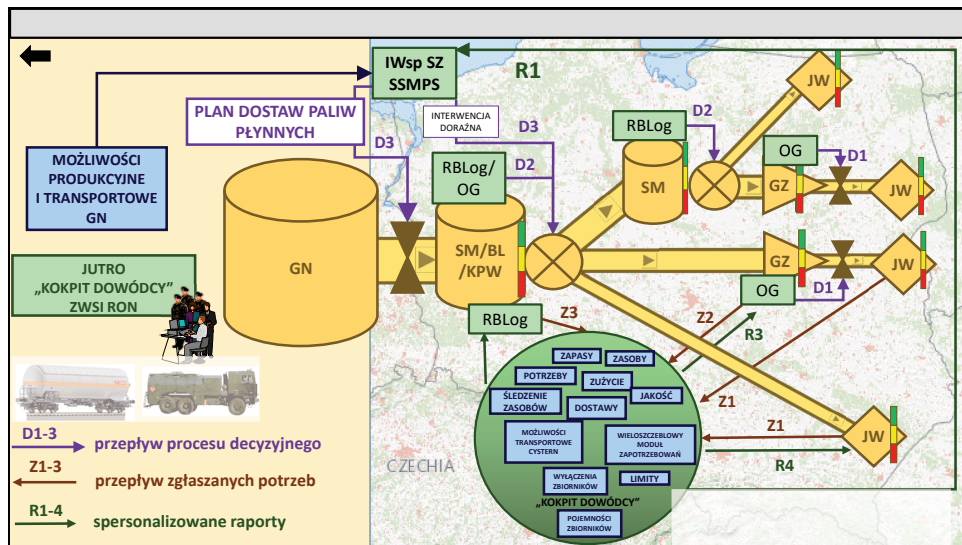
Raporty dostępne będą na poziomie OG, RBLog i IWsp SZ odpowiednio za rejon zaopatrywania.

W przygotowywaniu jest również meldunek o produktach „zbędnych” w składach RBLog i magazynach OG. Informacja dedykowana dla OG, RBLog i IWsp SZ bez ograniczenia do rejonu zaopatrywania.

Od 2022 roku w ZWSI RON w oddziałach gospodarczych RON wykorzystywane są funkcjonalności przydziału i rozliczenia limitu zużycia paliw płynnych. Monitorowanie zużycia limitu jest również możliwe na poziomie IWspSZ, jednakże koniecznym jest utworzenie w SI ZWSI RON tzw. „struktury przydzielania limitu” z poziomu dowództw, nad czym aktualnie trwają prace.

Raport SAP FIORI o przydzielonych limitach i ich wykorzystaniu, projektowany aktualnie na wniosek Szefostwa Służby MPS IWspSZ, będzie dostępny w pierwszym

etapie na szczeblach zaopatrzenia. W drugim etapie planowane jest wprowadzenie funkcjonalności do zarządzania przydzielonymi limitami na poziomie dowództw i z czasem całkowite zastąpienie dotychczasowego systemu meldunkowego i informacyjnego (zawiadomienia) funkcjonalnością SI ZWSI RON.



Rys. 16. Procesy decyzyjne w łańcuchu zaopatrzenia Sił Zbrojnych RP w paliwa – JUTRO - Kokpit dowódcy w SI ZWSI RON (opracowanie własne)

Wysoka czasochłonność przygotowania danych do analizy DZISIAJ wynika przede wszystkim z konieczności zestawiania ze sobą informacji rozproszonych w różnych systemach informatycznych i informatycznych bazach danych. Takie działanie jest obciążone możliwością popełnienia błędu w ocenie sytuacji i w efekcie przekazaniu nieprawidłowych danych do analizy. JUTRO – opierając zestawienie danych na zintegrowanym systemie informatycznym – ocena sytuacji jest zaprezentowana na bieżąco w raportach graficznych, tabelarycznych i geograficznych. Możemy więc od razu rozpocząć analizę zadania w celu wypracowania wariantów do podjęcia decyzji (Rys.16).

## 5. WSPARCIA PROCESU DECYZYJNEGO W ZARZĄDZANIU ZASOBAMI PALIW SZ RP Z WYKORZYSTANIEM TECHNOLOGII SZTUCZNEJ INTELIGENCJI (AI)

Procesy decyzyjne w kontekście zarządzania logistyką wojskową, szczególnie w dostarczaniu energii w postaci paliw, są kluczowymi elementami zapewniającymi efektywne funkcjonowanie sił zbrojnych. Analizy obecnego stanu tej problematyki

w Siłach Zbrojnych RP (DZISIAJ) prowadzą do wniosku, że stan ten odbiega od nowoczesnych, funkcjonujących w przestrzeni logistycznej standardów automatyzacji procesów zarządzania logistyką. Wprowadzane już nowe rozwiązania technologii informatycznych (JUTRO) zdecydowanie podnoszą poziom automatyzacji w zarządzaniu danymi oraz uczynią SI ZWSI RON systemem bardziej intuicyjnym i przyjaznym dla użytkownika („kokpit dowódcy”).

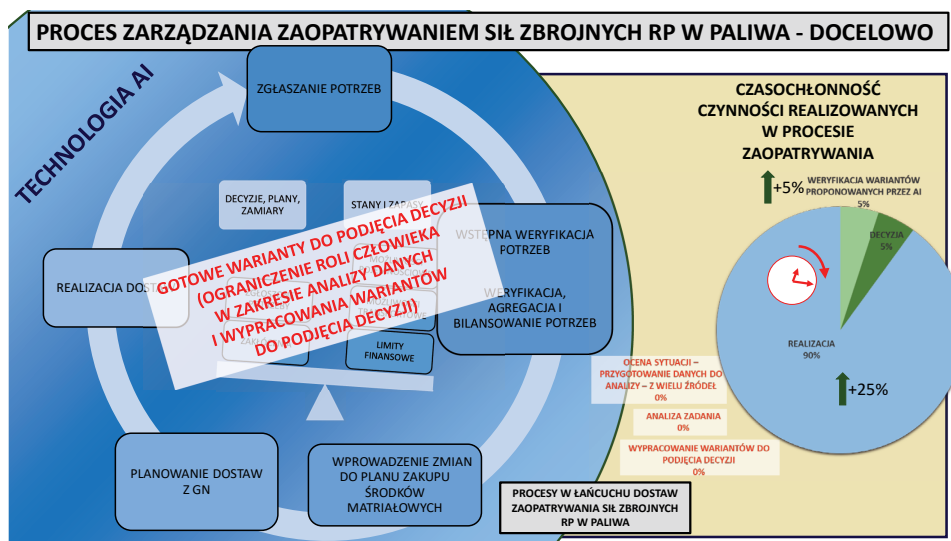
Sądzę jednak, że oczekiwania od systemu informatycznego zarządzającego całym systemem wsparcia i zabezpieczenia logistycznego Sił Zbrojnych RP powinny być zdecydowanie większe. Tyczy się to przede wszystkim posiadania zdolności systemowych do:

- widzialności potencjału logistycznego (we wszystkich podsystemach logistyki) w czasie rzeczywistym (on line) na każdym poziomie dowodzenia (zakres wg kompetencji);
- efektywnego zarządzania informacją – dostęp i analityka (Big data, chmura);
- automatyzacji wsparcia procesów decyzyjnych w zarządzaniu logistyką.

Osiągnięcie tych zdolności będzie wymagało zastosowania najnowszych technologii (z powodzeniem stosowanych w logistyce cywilnej) opartych o sztuczną inteligencję, analityczne rozwiązania „Big data” i szybki dostęp do informacji w wirtualnej chmurze danych. Takie trendy w rozwoju zarządzania logistyką dostrzega się od co najmniej kilku lat w najnowocześniejszych armiach z US Army na czele<sup>21</sup>. Dla utrzymania pewnego porządku logicznego w dalszych analizach ten etap rozwoju systemu nazwano DOCELOWYM, choć nie może to oznaczać, że definitywnie na tym kończy się proces rozwoju systemów dedykowanych zarządzaniu logistycznemu w Siłach Zbrojnych RP.

---

<sup>21</sup> M. Abadicio Artificial Intelligence for Military Logistics – Current Applications. April 30, 2019. Źródło internet : <https://emerj.com/ai-sector-overviews/artificial-intelligence-military-logistics/> (wejście; 12.02.2024 r.).



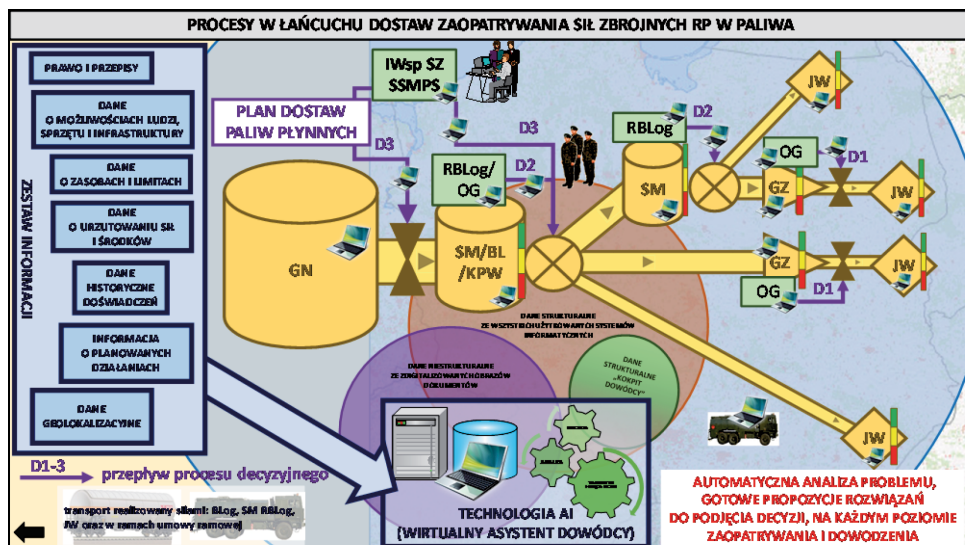
Rys. 17. Proces zarządzania zaopatrzeniem Sił Zbrojnych RP w paliwa wg koncepcji – DOCELOWO (opracowanie własne)

W DOCELOWYM rozwiązaniu systemowym zarządzania zasobami paliwa kluczem do sukcesu jest szybkość i trafność podejmowanych decyzji. Tego wymaga coraz bardziej sieciocentryczny charakter środowiska w działaniach operacyjnych wojsk<sup>22</sup>. Koncepcję DOCELOWO można syntetycznie opisać następująco: weryfikacja, agregacja i bilansowanie zgłoszonych potrzeb paliw oraz analiza możliwości ich zabezpieczenia, poprzedzona przygotowaniem danych z decyzji, planów i zamiarów wobec stanów ewidencyjnych zasobów i utrzymywanych zapasów, z ujęciem możliwości transportowych i pojemnościowych, w ramach limitu planu finansowego oraz gotowości na ewentualne zakłócenia realizowana będzie w sposób zautomatyzowany z wykorzystaniem technologii sztucznej inteligencji (AI). (Rys.17).

Kontynuacją idei kokpitu dowódcy (JUTRO) w rozwiązaniu DOCELOWYM ma być „Wirtualny Asystent Dowódcy (WAD)”, który „wskáže” gotowe możliwości rozwiązań do podjęcia decyzji przez decydenta/dowódcę. Właściwie „nauczony” WAD powinien identyfikować i sygnalizować problem na właściwym poziomie dowodzenia i zaopatrzenia oraz proponować możliwości jego rozwiązania. Zauważmy, że kompetencje do podjęcia decyzji pozostawiamy decydentowi. Interfejs końcowy AI jest określony statusem wirtualnego asystenta dla decydenta, który to dopiero decyduje o zastosowaniu jednego z proponowanych wariantów działania. Człowiek może oczy-

<sup>22</sup> M. Marciniak, T. Jakusz, Sieciocentryczność, czyli optymalizacja wykorzystania posiadanego potencjału. Nowa Technika Wojskowa 10/2019.

wiście odrzucić warianty lub zlecić ich modyfikację. Dotychczasowe analizy tego obszaru przez autora<sup>23</sup> wskazują, że system logistyczny najbardziej zoptymalizowany pod względem zastosowanego rozwiązania AI powinien być oparty o kontrolę zdecentralizowaną z elementami nagłej koordynacji.



Rys. 18. Procesy decyzyjne w łańcuchu dostaw paliwa do Sił Zbrojnych RP przy wsparciu AI (wirtualny asystent dowódcy)

Na rysunku 18 przedstawiono poglądowy schemat opisujący ideę koncepcji DOCELOWO dla zarządzania łańcuchami dostaw paliwa do Sił Zbrojnych RP oparty na wspomaganiu procesów decyzyjnych z wykorzystaniem sztucznej inteligencji (AI). Oczywiście wskazując AI mam na myśli zastosowanie równoległe również innych dostępnych technologii informatycznych wspierających lub wręcz umożliwiających jej efektywne działanie (np. Big data, chmury danych)<sup>24</sup>. Wirtualny Asystent Dowódcy (WAD) to określenie intuicyjnego, przyjaznego użytkownikowi interfejsu stanowiącego przestrzeń, w której następuje interakcja człowieka z maszyną. W dalszych analizach dotyczących modelowania systemu, zastosowania odpowiednich sieci neuronowych i algorytmów w technologii sztucznej inteligencji, rozważane jest narzędzie, którego WAD jako interfejs jest jedynie częścią. Będzie to System Wspomagania Decyzji

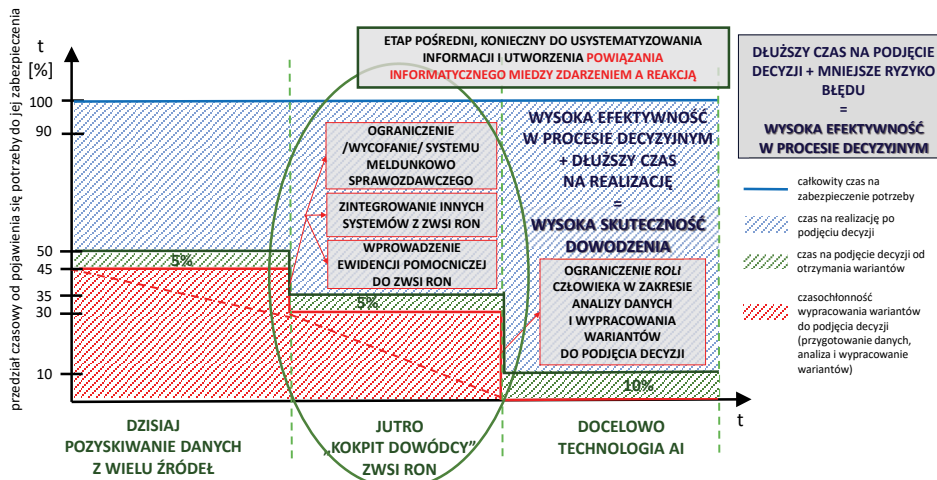
<sup>23</sup> A. Kępczyński, G. Lisowski, W. Prokopowicz, S. Stępień, Metody adaptacyjne w logistyce energii wojsk, AWIR AKCES, Warszawa 2023, s. 20.

<sup>24</sup> E. B. Lacroix, Future of Army Logistics | Exploiting AI, Overcoming Challenges, and Charting the Course Ahead. August 1, 2023. Źródło: [https://www.army.mil/article/267692/future\\_of\\_army\\_logistics\\_exploiting\\_ai\\_overcoming\\_challenges\\_and\\_charting\\_the\\_course\\_ahead/](https://www.army.mil/article/267692/future_of_army_logistics_exploiting_ai_overcoming_challenges_and_charting_the_course_ahead/), wejście: 20.02.2024.

Logistycznej (SWDLog)<sup>25</sup> tworzący kompleksowy model wspomagający procesy decyzyjne w logistyce Sił Zbrojnych RP z wykorzystaniem AI.

SWDLog jako moduł dysponujący odpowiednim potencjałem analitycznym AI, swoją efektywność będzie uzależniał od otrzymywanych (najlepiej w czasie rzeczywistym) odpowiednio dobranych informacji, parametryzujących czasoprzestrzeń logistyczną<sup>26</sup>. Do podstawowych parametrów należy zaliczyć:

- prawo i przepisy;
- dane o możliwościach ludzi i sprzętu;
- dane o zasobach i limitach;
- dane o utrzymaniu sił i środków;
- dane historyczne doświadczeń;
- informacja o planowanych działaniach;
- dane geolokalizacyjne i środowiskowe.



Rys. 19. Wpływ technologii systemów informatycznych na procesy decyzyjne w zarządzaniu zasobami (opracowanie własne)

DOCELOWO zostanie zaoszczędzony czas poświęcany wcześniej przygotowaniu danych do analizy jak i wypracowania wariantów do podjęcia działań na rzecz podjęcia samej decyzji i przede wszystkim na realizację zadania.

<sup>25</sup> W. Prokopowicz, A. Kępczyński, Zastosowanie sieci neuronowych do modelowania procesów decyzyjnych w wojskowym systemie dystrybucji paliw. Konferencja Perspektywy logistyki wojskowej i cywilnej w kontekście zapewnienia odporności Siłom Zbrojnym, Bydgoszcz 2024

<sup>26</sup> K. Ficoń, Badania operacyjne stosowane. Modele i aplikacje. Wydawnictwo BEL STUDIO 2006.

Oznaczając odcinek czasu od pojawienia się potrzeby (rozumianej jako zadania logistycznego) do jej zabezpieczenia (cel końcowy) konieczny jest do przeprowadzenia proces decyzyjny, który w uproszczeniu sprowadza się do poniższych czynności (etapów) w odpowiednich przedziałach czasu:

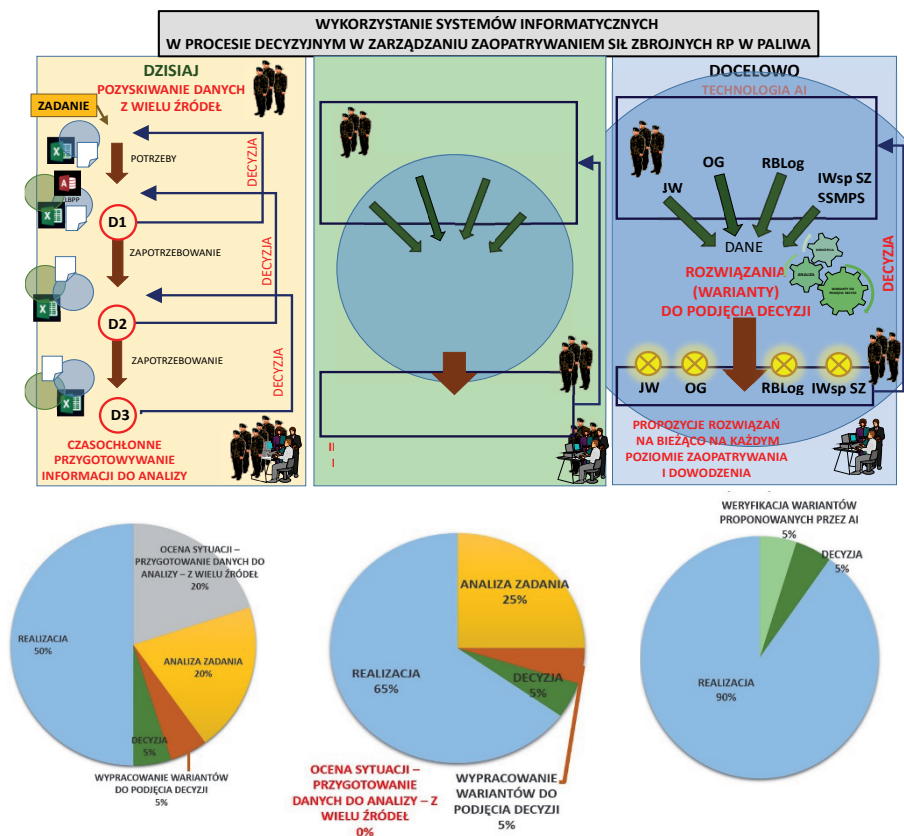
- Identyfikacja zadania (jego istota i cel);
- Ocena sytuacji (przygotowanie danych do analizy);
- Analiza danych (potencjał i zdolności);
- Wypracowanie wariantów do podjęcia decyzji;
- Decyzja;
- Realizacja zadania (w tym monitorowanie – gotowość do reakcji na zakłócenia).

Wykorzystanie technologii informatycznych do zastępowania człowieka w poszczególnych czynnościach procesu decyzyjnego, prowadzi do skrócenia czasu dedykowanego tym zadaniom i w konsekwencji zwiększenie czasu na podjęcie działań. W efekcie wpływamy na efektywność realizacji zadania, w tym optymalne wykorzystanie potencjału i pewność/prawdopodobieństwo pełnej realizacji zadania (istotny czynnik planistyczny w zabezpieczeniu wojsk). Rysunek 19 przedstawia w formie wykresu analizę wpływu zastosowania wspomagających technologii informatycznych w logistycznych procesach decyzyjnych na jakość realizacji stawianych celów/zadań przy założeniu, że dla zbliżonych finalnie decyzji czynnik czasu determinuje jakość realizacji zadania.

DZISIAJ wysoka czasochłonność oraz prawdopodobieństwo błędów w przygotowaniu danych do analizy, same wnioski i ostatecznie przedstawienie wariantów do podjęcia decyzji powoduje ograniczenie czasu na realizację zadania i fizyczne zabezpieczenie potrzeb.

Wprowadzenie do użytku „kokpitu dowódcy” spowoduje wycofanie dotychczasowego systemu meldunkowo – sprawozdawczego realizowanego cyklicznie w zamian na bieżące monitorowanie sytuacji logistycznej. Zgodnie z założeniami JUTRO nie będzie potrzeby poświęcania czasu na przygotowanie danych. Oszczędzony czas może zostać wykorzystany na efektywniejszą analizę i fizyczną realizację zabezpieczania potrzeb.

Etap integracji systemów informatycznych oraz wdrażania „pomocniczej” ewidencji do ZWSI RON jest konieczny do „informatycznego” powiązania zdarzenia z reakcją, co w efekcie powinno zostać wykorzystane do nauki sztucznej inteligencji w proponowanym rozwiązaniu docelowym.



Rys. 20. Graficzne porównanie przebiegu procesów decyzyjnych DZISIAJ, JUTRO i DOCELOWO oraz wynikające z tego podział czasu na proces przygotowawczy i samą realizację zadania

DOCELOWO ograniczenie roli człowieka i zastąpienie go w zakresie analizy danych i wypracowania wariantów do podjęcia decyzji przez AI (SWDLog) poprzez przyjazny dla decydenta WAD (Wirtualny Asystent Dowódcy) zapewni więcej czasu na podjęcie decyzji przez decydenta, mniejsze ryzyko błędu podczas oceny sytuacji, co spowoduje wzrost efektywności w procesie decyzyjnym oraz wyższą skuteczność dowodzenia.

## 6. PODSUMOWANIE

Paliwo jako jedna z form energii, pomimo bardzo szybkiego rozwoju technologicznego, wskazującego wiele nowych sposobów zaspokajania potrzeb energetycznych

wojsk, pozostaje wciąż najważniejszym źródłem w zapewnieniu wojskom zdolności do działania. Postęp naukowo-techniczny w dziedzinie IT nie pozostaje bez wpływu na standardy zarządzania logistyką wojskową, w tym również tak ważnymi dla wojsk zasobami paliwa. Zarządzanie logistyką wojskową musi nadążać za dynamicznie zmieniającymi się standardami w systemach dowodzenia i kierowania, wynikającymi głównie z zastosowania nowatorskich technologii informatycznych nadających systemom dowodzenia charakter sieciocentryczny. Można zaobserwować zaawansowane działania wielu armii świata w kierunku automatyzacji procesów decyzyjnych z wykorzystaniem AI. Dotyczy to również systemów dedykowanych logistyce.

W artykule poddano analizie obecnie funkcjonujące rozwiązania w obszarze zarządzania zasobami paliwami w logistyce Sił Zbrojnych RP oraz aktualnie przyjęte kierunki dalszego rozwoju. Z analizy tej wynika, że obecne rozwiązania oparte na wielu logistycznych systemach informatycznych nie spełniają oczekiwanych standardów narodowych i sojuszniczych. Dedykowanym narzędziem informatycznym do zarządzania szeroko rozumianą logistyką SZ RP jest (raczej ma być) SI ZWSI RON. Rozbudowywany od lat wciąż wymaga wielu działań w celu osiągnięcia minimalnych wymagań, oczekiwanych w zarządzaniu współczesną logistyką wojskową. Sporo nowych funkcjonalności jest w trakcie wdrażania (JUTRO). SI ZWSI RON, w którym z roku na rok wprowadzanych jest coraz więcej informacji, może JUTRO być wykorzystany jako narzędzie do automatycznego przedstawiania danych gotowych do analizy. Technologia SAP FIORI pozwala na przygotowanie na poziomach zaopatrywania (oraz dowodzenia – w ramach wprowadzanych wieloszczeblowych funkcjonalności) spersonalizowanych raportów, dedykowanych konkretnym osobom funkcyjnym do przeprowadzania analizy sytuacji i wypracowania wariantów do podjęcia decyzji, poprzez narzędzie określane jako kokpit dowódcy.

Jednak z perspektywy potrzeb sieciocentrycznego środowiska współczesnych systemów dowodzenia wojskiem, te działania wydają się być zdecydowanie niewystarczające. Należy podnieść zdolności SI ZWSI RON w zakresie widzialności potencjału logistycznego w czasie rzeczywistym, efektywnego zarządzania informacją (Big data), a przede wszystkim w zakresie automatyzacji wsparcia procesów decyzyjnych w zarządzaniu logistyką. Zdolności takie SI ZWSI RON osiągnąć może poprzez implementację nowatorskich rozwiązań w zarządzaniu logistyką opartych na zastosowaniu technologii sztucznej inteligencji (AI). Zaproponowana w artykule wstępna koncepcja (DOCELOWO) zakłada, że weryfikacja, agregacja i bilansowanie zgłoszonych potrzeb paliw oraz analiza możliwości ich zabezpieczenia, poprzedzona przygotowaniem danych z decyzji, planów i zamiarów wobec stanów ewidencyjnych zasobów i utrzymywanych zapasów, z ujęciem możliwości transportowych i pojemnościowych, w ramach limitu planu finansowego oraz gotowości na ewentualne zakłócenia realizowana będzie w sposób zautomatyzowany z wykorzystaniem technologii sztucznej inteligencji (Rys. 21).

Nowoczesne technologie oparte na Big Data i AI umożliwiają głęboką analizę i optymalizację łańcuchów dostaw poprzez przewidywanie zakłóceń, automatyzację procesów i identyfikację najbardziej efektywnych ścieżek dostaw. Logistyka wojskowa, korzystając z tych rozwiązań, może znacznie zwiększyć swoją sprawność operacyjną, minimalizując jednocześnie ryzyko i koszty. W koncepcji przyjmuje się zarządzanie procesami decyzyjnymi przez moduł SWDLog wykorzystujący technologię sieci neuronowych (NN). DOCELOWO przedstawia ideowy model wspomagania procesu decyzyjnego na potrzeby zapewnienia energii (paliwa) Siłom Zbrojnym. Dalsze prace analityczno-badawcze muszą być nakierowane na dobór odpowiednich typów sieci neuronowych, oraz odpowiedniej struktury modelu algorytmu procesu wspomagania decyzji. Istotne jest to, aby zaproponowane rozwiązanie obejmowało przede wszystkim powiązanie zdarzenia z reakcją. Przeprowadzenie procesu decyzyjnego wymaga zaprojektowania silnika AI przy wykorzystaniu dostępnych algorytmów tak, aby nie doprowadzić do niedouczenia lub przeuczenia systemu. W zaproponowanym rozwiązaniu sztuczna inteligencja musi być w odpowiedni sposób nadzorowana, a proces tworzenia wariantów działania odpowiednio weryfikowany pod względem powielania rozwiązań prowadzących do błędnych decyzji, a w konsekwencji awarii systemu. W przypadku wskazanego problemu logistycznego najbardziej optymalnym rozwiązaniem może okazać się model głębokiego uczenia poprzez wzmocnienie Reinforcement Learning (RL). Natomiast struktura modułów WOD powinna nawiązywać do struktury uczenia się decydenta opartej na aktorze i krytyku.

Zaproponowane rozwiązania oraz planowane dalsze prace koncepcyjne nad wykorzystaniem technologii AI do wspomagania procesów decyzyjnych w zarządzaniu zasobami paliwa mają charakter uniwersalny i z powodzeniem będą mogły być zastosowane do zarządzania nie tylko paliwem, ale całym potencjałem logistycznym, zintegrowanym w SI ZWSI RON.



Rys. 21. Grafika to wytwór AI (GPT4) - przedstawia wsparcie przez AI procesu decyzyjnego w zabezpieczeniu wojsk w paliwo (opracowanie własne)

## LITERATURA

1. D. Łukowski, Znaczenie surowców energetycznych i źródeł energii w Siłach Zbrojnych, Nauka dla obronności i środowiska, Wydawnictwo ITWL, 2020.
2. T. Jałowicz, Logistyka wojskowa – od nauk wojskowych do nauk o zarządzaniu i jakości, Systemy Logistyczne Wojsk, Zeszyt 55 (2021).
3. Energy & the Military: Convergence of Security, Economic and Environmental Decisionmaking <https://www.eprg.group.cam.ac.uk/wp-content/uploads/2017/11/1717-Text.pdf>, wejście 13.01.2024.
4. Editors: Sonia Lucarelli; Alessandro Marrone; and Francesco Niccolò Moro “NATO Decision-Making in the Age of Big Data and Artificial Intelligence”, 2021 NATO HQ - Boulevard Léopold III, 1110 Brussels – Belgium.
5. K. Ficoń, G. Krasnodębski, Nowoczesne technologie logistyczne jako źródło dodatkowych wartości w łańcuchu dostaw, Systemy Logistyczne Wojsk nr 48/2018.
6. M. Pawlisiak, System logistyczny Sił Zbrojnych Rzeczypospolitej Polskiej. Teoria i praktyka. Toruń 2021 Wydawnictwo Adam Marszałek.
7. Doktryna Logistyczna Sił Zbrojnych RP D-4(B) Szkol. 965/2019.
8. Powierża L., Elementy inżynierii systemów. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 1997.

9. Kaliszewski I. Wielokryterialne podejmowanie decyzji. Wydawnictwo Naukowo-Techniczne, Warszawa 2008.
10. A.P. Wierzbiński, Teoria i praktyka wspomagania decyzji, Wydawnictwa Uniwersytetu Warszawskiego, Warszawa 2018
11. Allied Joint Doctrine for NATO Asset Visibility - AJP-4.11. 21.02.2011r.
12. SI LOGFAS (Logistic Function Area Services) wprowadzony decyzją MON w 2017r. (DU-4.11.1).
13. Decyzja nr 8/MON z dnia 20.01.2012 r. w sprawie dopuszczenia do eksploatacji Zintegrowanego Wieloszczeblowego Systemu Informatycznego Resortu Obrony Narodowej (ZWSI RON) w jednostkach budżetowych resortu obrony narodowej.
14. Doktryna Logistyczna Sił Zbrojnych RP D-4(B), Szkol. 965/2019.
15. System informatyczny LOGFAS. Zasady funkcjonowania w resorcie obrony narodowej, DU-4.11.1(A) Logis 54/2024.
16. T. Nowakowski, Niezawodność systemów logistycznych, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2011.
17. . Instrukcja o gospodarce materiałowej służby materiałów pędnych i smarów (DU-4.21.3), MON/IWspSZ. Warszawa 2019.
18. M. Abadicio Artificial Intelligence for Military Logistics – Current Applications. April 30, 2019. Źródło internet : <https://emerj.com/ai-sector-overviews/artificial-intelligence-military-logistics/> wejście; 12.02.2024 r.
19. M. Marciniak, T. Jakusz, Sieciocentryczność, czyli optymalizacja wykorzystania posiadanego potencjału. Nowa Technika Wojskowa 10/2019.
- A. Kępczyński, G. Lisowski, W. Prokopowicz, S. Stępień, Metody adaptacyjne w logistyce energii wojsk. Nauka dla obronności i środowiska, Wydawnictwo ITWL, 2023.
20. E. B. Lacroix, Future of Army Logistics | Exploiting AI, Overcoming Challenges, and Charting the Course Ahead. August 1, 2023. Źródło Internet: [https://www.army.mil/article/267692/future\\_of\\_army\\_logistics\\_exploiting\\_ai\\_overcoming\\_challenges\\_and\\_charting\\_the\\_course\\_ahead/](https://www.army.mil/article/267692/future_of_army_logistics_exploiting_ai_overcoming_challenges_and_charting_the_course_ahead/) , wejście: 20.02.2024.
21. W. Prokopowicz, A. Kępczyński, Zastosowanie sieci neuronowych do modelowania procesów decyzyjnych w wojskowym systemie dystrybucji paliw. Konferencja Perspektywy logistyki wojskowej i cywilnej w kontekście zapewnienia odporności Siłom Zbrojnym, Bydgoszcz 2024.
22. K. Ficoń, Badania operacyjne stosowane. Modele i aplikacje. Wydawnictwo BEL STUDIO 2006.

#### **DECISION MAKING SUPPORT MODEL FOR ENSURING ENERGY SUPPLY FOR MILITARY OPERATIONS. FUEL RESOURCE MANAGEMENT IN THE MILITARY**

Ensuring an adequate level of energy for contemporary military forces is considered a key factor in maintaining operational capability. Although military energy needs can be viewed in various ways, hydrocarbons (fuels) remain its most important source. This article

addresses the issue of decision making process support in the logistical sustainment of military forces in the area of energy resource management, using fuel as an example. The need to address this issue from the perspective of broadly understood logistics of the Polish Armed Forces arises from the intense development of information technologies (IT), rapidly expanding databases requiring advanced analytical tools (Big Data), and almost universally used artificial intelligence (AI) in management/command. As a result of that, the operation of modern forces occurs in a network-centric environment saturated with automated command means. This translates into the need to adapt management standards in military logistics. The article provides a synthetic analysis of the current state of automation in fuel resource management processes in the Polish Armed Forces and the directions of development of logistical information systems planned for the coming years. According to the author, the conclusions from the analysis of the current level of automation support for decision-making processes in fuel resource management unequivocally indicate the need for urgent actions to expand the logistical information system integrated with the network-centric command environment in the Armed Forces. The author presents a conceptual model for supporting decision-making processes in fuel resource management using artificial intelligence technology. The summary indicates further directions for analytical and research work focused on selecting appropriate types of neural networks and the appropriate structure of the decision support process algorithm model. The proposed solutions and further planned conceptual work are of a universal nature and will successfully be applicable to managing not only fuel but also the entire logistical potential integrated into the IT infrastructure of the Polish Armed Forces.

**Keywords:** artificial intelligence in military logistics, military logistics system, decision support model, neural network.

**PUBLIKACJA [3]**

- [3]. Prokopowicz W., Kępczyński A., *Zastosowanie sieci neuronowych do modelowania procesów decyzyjnych w wojskowym systemie dystrybucji paliw*, rozdział w monografii *Perspektywy logistyki wojskowej i cywilnej w kontekście zapewnienia odporności Siłom Zbrojnym* (konferencja Bydgoszcz), Warszawa: Wydawnictwo ITWL 2024, Tom 1.

Wojciech PROKOPOWICZ\*  
Artur KĘPCZYŃSKI\*\*

## **ZASTOSOWANIE SIECI NEURONOWYCH DO MODELOWANIA PROCESÓW DECYZYJNYCH W WOJSKOWYM SYSTEMIE DYSTRYBUCJI PALIW**

Model systemu zaopatrywania w energię wojsk nie byłby kompletny bez wskazania wariantów działania, które prowadzą do zapewnienia optymalnego poziomu medium energetycznego w podstawowych Oddziałach Gospodarczych (OG)<sup>1</sup> oraz Nadrzędnych Oddziałach Gospodarczych (NOG)<sup>2</sup>. W tym celu należy zintensyfikować działania mające na celu implementację algorytmów sztucznej inteligencji Artificial Intelligence (AI) do systemów wsparcia decyzji decydentów poszczególnych szczebli systemu zabezpieczenia logistycznego wojsk. W artykule przedstawiono jedynie system dystrybucji paliwa, ale jest to doskonały punkt wyjścia do rozszerzenia prezentowanego modelu decyzyjnego na pozostałe procesy występujące we wszystkich podsystemach logistyki wojskowej. W celu sprostania zadaniu opracowania modelu wsparcia decyzji w systemie dystrybucji paliw, należy opracować model sieci i wskazać podstawowe parametry regresyjne algorytmu uczenia opartego o sieci neuronowe (Neural Network - NN), do których należą: wartości mierzone, odpływu i dopływu medium roboczego<sup>3</sup>, dane środowiskowe, uchyby, wskaźniki regulacji, sygnały sterujące, czas i przepustowości łączny transmisji energii. Prezentowany w artykule model modularnej wielowarstwowej jednokierunkowej sieci neuronowej MNN (Modular Neural Network) wytrenowany dzięki modelowi głębokiego uczenia się poprzez wzmacnianie Reinforcement Learning (RL), pozwoli nauczyć system AI w oparciu o doświadczenia decydentów i dane historyczne, w jaki sposób przedstawiać kilka optymalnych wariantów dystrybucji paliw. Artykuł pokazuje model algo-

---

\* Ministerstwo Obrony Narodowej.

\*\* Inspektorat Wsparcia Sił Zbrojnych.

<sup>1</sup> W artykule Oddział Gospodarczy jest odpowiednikiem rzeczywistego Wojskowego Oddziału Gospodarczego bez przypisania lokalizacji. W OG znajduje się magazyn paliwa o skończonej pojemności.

<sup>2</sup> NOG to obiekt systemu logistycznego wojsk odpowiadający Regionalnej Bazie Logistycznej (RBLog) bez podania lokalizacji. W lokalizacji znajduje się skład paliw o zwiększonej pojemności, z którego zasilane są pozostałe OG.

<sup>3</sup> Na potrzeby artykułu założono, że medium robocze w modelowanym systemie wspomaganie decyzji w logistyce wojsk to paliwo.

rytmu opartego o sieć neuronową z algorytmem uczenia poprzez wzmacnianie wariantu działania w systemie uczenia z obserwatorem, która na podstawie wielu kryteriów zapewnienia optymalny poziom paliwa w OG na wybranym obszarze kraju, przy uwzględnieniu infrastruktury magazynowej i przesyłowej. Model wspomaganie procesu decyzyjnego na potrzeby zapewnienia energii Siłom Zbrojnym bazujący na algorytmach uczenia maszynowego wymaga znalezienia ekstremum funkcji celu przy założeniu ograniczeń wprowadzanych przez środowisko naturalne, operacyjne oraz dokumenty normatywne. Opisany w artykule algorytm jest niczym innym jak złożonym kryterium wojskowego systemu logistycznego dla podsystemu materiałowego ze wskazaniem na zasilanie OG w paliwo. Prezentowany model sieci neuronowej stanowi podstawowy element modelu decyzyjnego wojskowego systemu logistycznego i wpływa po transformacji na wielkość potencjału logistycznego jednostek, co przekłada się w konsekwencji na ich potencjał operacyjny.

Słowa kluczowe: model decyzyjny, system logistyczny, model wspomaganie decyzji, sieć neuronowa

## 1. WPROWADZENIE

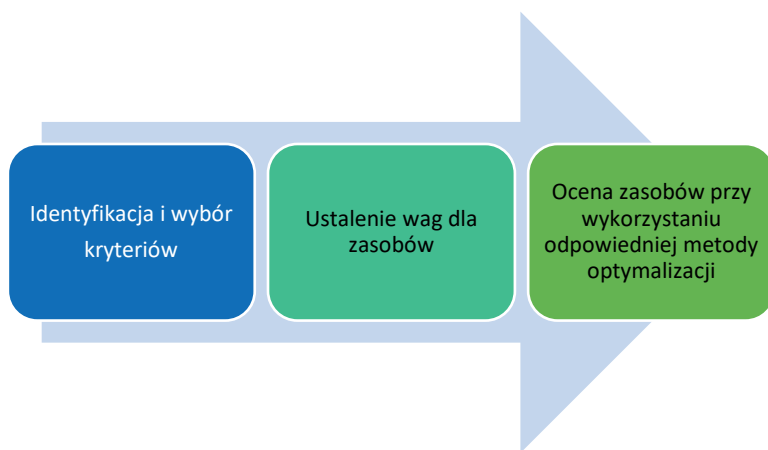
Wzrost znaczenia systemów wspomaganie decyzji w wojsku wynika z ciągłego wzrostu ilości danych do przetworzenia przez decydentów w jednostce czasu. Przygotowanie operacji wsparcia logistycznego wymaga obecnie przetworzenia ogromnej ilości danych. Nie zawsze są to jedynie informacje o ilości dostępnych nośników energii, ale konieczne jest przewidywanie ich zużycia w odniesieniu do aktywności wojsk w danym rejonie odpowiedzialności OG. Wymaga to posiadania planu działania, na który nakłada się szereg czynników nie tylko środowiskowych, ale i operacyjnych. Linie przesyłowe w postaci dróg lądowych (drogi, linie kolejowe), powietrznych i morskich mogą zostać odcięte lub ich przepustowość ograniczona.

Niezakłócone prowadzenie działań wojsk uzależnione jest od dostaw energii. Obecnie rozdrobnienie logistyczne w obszarze jej nośników w Siłach Zbrojnych jest duże. Powoduje to zwiększenie ilości procesów dystrybucji, pozyskiwania, magazynowania, analizy jakości, a przede wszystkim podejmowania decyzji, co do optymalnego zapewnienia energii jednostkom w zakładanym czasie. Na potrzeby opracowania modelu decyzyjnego wybrano spośród wielu nośników energii paliwo, celem opracowania rozwiązań optymalizacji podejmowania decyzji w procesach jego dostarczenia. Prezentowane w artykule rozwiązanie jest na tyle uniwersalne, że można je rozszerzyć na pozostałe systemy dystrybucji energii zarówno w Siłach Zbrojnych jak i w firmach cywilnych. Zaprezentowany sposób optymalizacji podejmowania decyzji jest na tyle uniwersalny, że może być przydatny również w innych obszarach planowania operacji wojskowych.

Na potrzeby artykułu opracowano reprezentację graficzną czasoprzestrzeni logistycznej w wybranej części kraju będącą w podporządkowaniu OG i NOG. Reprezentacja ta stanowi uproszczony schemat systemu zasilania w paliwo wojsk poprzez OG. Już na tym przykładzie widać liczbę parametrów jakie należy wziąć pod uwagę po to, aby w nakazanym czasie zapewnić wymaganą ilość paliwa.

W celu podjęcia decyzji, co do utrzymania wskaźników dostępności paliwa na zakładanym poziomie w OG i NOG należy stosować do wspomaganie decyzji systemy informatyczne oparte o sztuczną inteligencję (AI – Artificial Intelligence) przetwarzającą dane „big data”<sup>4</sup> szybko i w założony przez użytkownika sposób z uwzględnieniem wprowadzonych parametrów brzegowych. W tym celu należy stworzyć Wielokryterialny Model Procesu Decyzyjnego (WMPD) na podstawie podstawowych kroków procesu decyzyjnego (Rys. 1).

W procesie decyzyjnym można wyróżnić umownie kilka kolejnych faz: identyfikacja sytuacji decyzyjnej; sformułowanie problemu decyzyjnego; zbudowanie modelu decyzyjnego; wyznaczenie różnych podzbiorów zbioru opcji (np. dopuszczalnych, zadowalających, optymalnych); podjęcie/wybór decyzji [Kwiatkowski 2011].



Rys. 1. Kroki procesu decyzyjnego (źródło: opracowanie własne)

Upraszczając zagadnienie skupimy się w badaniach nad optymalizacją decyzji, co do dostaw paliwa do wojsk. Przykładowy schemat rozmieszczenia poszczególnych elementów systemu logistyki zarządzania paliwami w zadanym rejonie na potrzeby modelowania sieci neuronowej przedstawia rys. 2. Na rysunku pokazano podstawowe magazyny dystrybucyjne NOG oraz punkty wydawcze w OG. Cały system połączony jest liniami przesyłowymi zaznaczonymi kolorem: czarnym jako drogi; brązowym linie kolejowe; niebieskim możliwy transport lotniczy. Czerwone linie obrazują sygnały

<sup>4</sup> Big Data - zbiory informacji, które są zbyt duże lub zbyt złożone, aby można je było obsługiwać, analizować lub wykorzystywać standardowymi metodami, Oxford Dictionary.

wykonawcze i kontrolne, natomiast kolorem zielonym zaznaczono sygnały stanu (sensoryczne). Całość tworzy czasoprzestrzeń logistyczną  $(X, T)$  dla uproszczenia dwuwymiarową, gdzie:

- $X$  element zbioru zmiennych decyzyjnych dotyczący przestrzeni prowadzonej operacji zabezpieczenia logistycznego;
- $T$  element zbioru zmiennych decyzyjnych dotyczący czasu operacji zabezpieczenia logistycznego.

Na podstawie rejonu prowadzonej operacji logistycznej możemy wyodrębnić ogólną funkcję czasoprzestrzeni prowadzonej operacji [Ficoń 2020]:

$$F(t^*, x^*) = (F(t, x)|G_{WSL}) \rightarrow \min; t^* \in T, x^* \in X \quad (1)$$

gdzie:

$F(t, x)$  – funkcja czasoprzestrzeni logistycznej;

$t$  – zmienna decyzyjna, niezależna obrazująca pokonanie czasu;

$x$  – zmienna decyzyjna, niezależna obrazująca pokonanie przestrzeni;

$(X, T)$  – zbiór dopuszczalnych wartości zmiennych decyzyjnych;

$t^*$  – optymalna wartość zmiennej czasowej  $t \in T$ ;

$x^*$  – optymalna wartość zmiennej przestrzennej  $x \in X$ ;

$G_{WSL}$  – ograniczenia operacyjno-logistyczne.

Czasoprzestrzeń logistyczna to pojęcie złożone, na które nakłada się wiele czynników. Są to między innymi dynamika działań, manewr siłami, zaskoczenie, rozproszenie. WSL musi nadążać za zmianami tego środowiska, a dowódcy pododdziałów muszą podejmować decyzje w krótkim czasie, analizując duże ilości danych. Zabezpieczenie w paliwa na teatrze działań militarnych to jedynie jeden z elementów systemu logistyki wojsk. Na potrzeby stworzenia modelu decyzyjnego zakładamy, że zabezpieczenie potrzeb paliwowych ćwiczących (walczących) pododdziałów wymaga przeprowadzenia szeregu procesów logistycznych w oparciu o posiadane zasoby w przestrzeni operacyjnej w czasie (na bazie NOG, OG zasobów sojusznicy i cywilnych).

Zgodnie z tym należy pokonać ograniczenia czasoprzestrzeni logistycznej [Ficoń 2020] po to, aby zapewnić odpowiedni poziom paliwa w czasie ( $T$ ) we wskazanych lokalizacjach ( $X$ ) przy występujących parametrach regresyjnych takich jak:

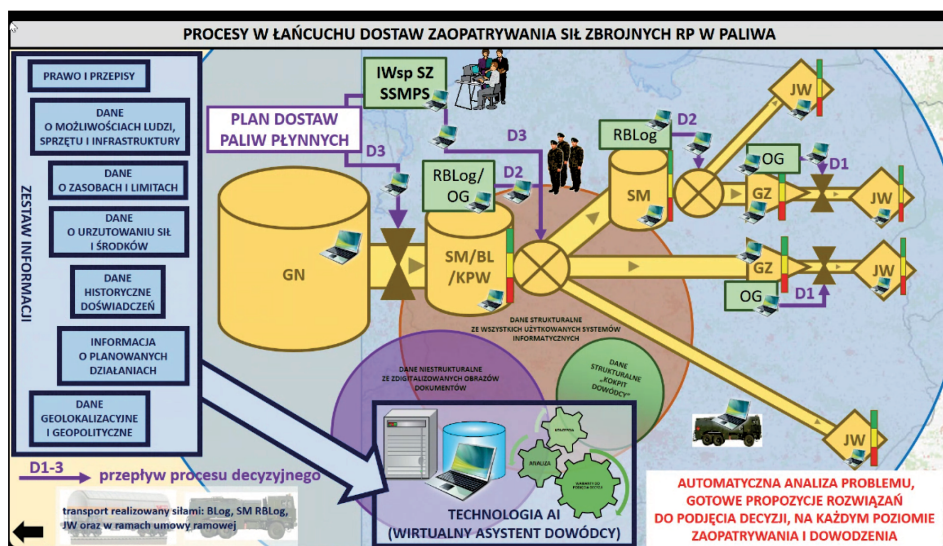
a) środowiskowe:

- temperatura;
- wilgotność;
- ilość opadów deszczu w danym rejonie;
- charakterystyka terenu;
- pora roku;
- wysokość nad poziomem morza;
- itp.

b) infrastrukturalne:

- dostępność dróg lądowych, morskich i przestrzeni powietrznej wraz z lądowiskami;
- przepustowość linii transmisyjnej (tonaż paliw w czasie);

- baza magazynowa: parametry urządzeń, tonaż, możliwości wydawcze oraz czas napełniania i dystrybucji;
- itp.
- c) operacyjne (przestrzeń, czas, zasoby i informacja):
- czas trwania operacji;
- ilość SpW, infrastruktury, żołnierzy w rejonie odpowiedzialności;
- dynamika działań;
- współczynnik strat;
- itp.

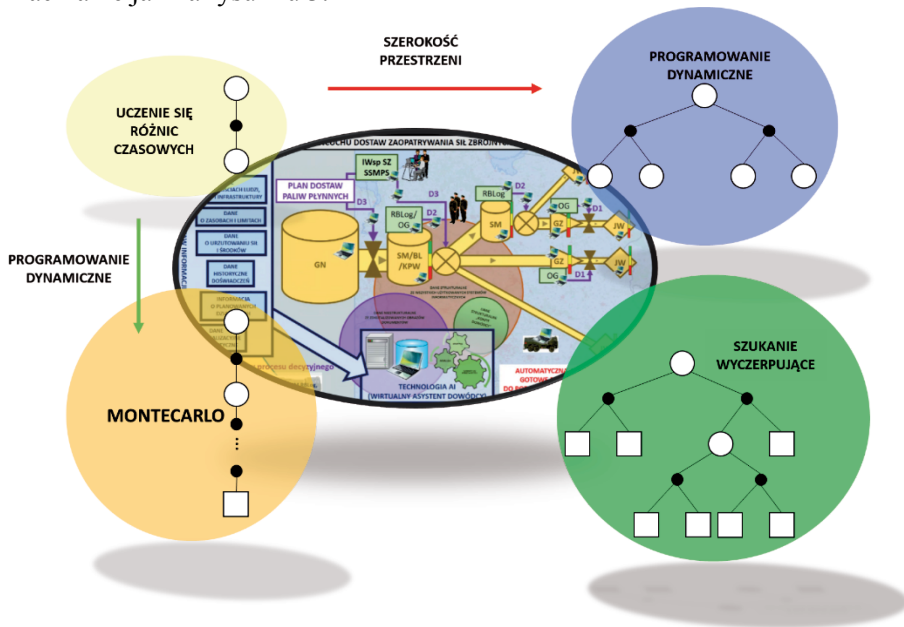


Rys. 2. Schemat systemu logistyki paliwa na wybranym obszarze odpowiedzialności OG i NOG wspierany modulem SWDLog, który generuje sygnały sterujące w oparciu o algorytmy AI. Na rysunku oznaczenia od D1..n przedstawiają punkty, w których należy podjąć decyzję, co do dalszego działania [Kępczyński 2024]

Wycinek przestrzeni metod uczenia się przez wzmacnianie można zaprezentować przy użyciu wielu algorytmów uczenia maszynowego, najbardziej optymalne z punktu widzenia wsparcia decyzji w logistyce przedstawiono w dalszej części artykułu.

Wszystkie metody uczenia się przez wzmacnianie, które zostaną przedstawione w artykule, posiadają trzy kluczowe wspólne idee. Po pierwsze, celem każdej z nich jest oszacowanie wartości funkcji celu. Po drugie, wszystkie metody działają poprzez tworzenie kopii zapasowych wartości wzdłuż rzeczywistych lub możliwych trajektorii stanu. Po trzecie, wszystkie metody podążają za ogólną strategią uogólnioną iteracji polityki, co oznacza, że zachowują one przybliżoną wartość funkcji i przybliżoną strategię (politykę), przy czym stale starają się udoskonalać każdą z nich na podstawie drugiej. Te trzy idee mają wspólne metody. Sugerujemy, że funkcje wartości, kopie

zapasowe i możliwe trajektorie stanu to potężne zasady, które mogą być potencjalnie istotne dla dowolnego modelu AI w procesach logistycznych. Obrazowo można przedstawić przybliżanie przestrzeni logistycznej za pomocą metod uczenia przez wzmacnianie jak na rysunku 3.



Rys. 3. Wycinek przestrzeni metod uczenia się przez wzmacnianie (opracowanie na podstawie [Sutton i Barto 2012])

Zastosowanie algorytmów uczenia maszynowego ma za zadanie pomóc decydom<sup>5</sup> w podjęciu szybkiej decyzji przy wzięciu pod uwagę najważniejszych informacji ze zbioru danych „big data”. W tym celu zaproponowano moduł wsparcia decyzji SWDLog, który zawiera wybrany optymalny algorytm uczenia maszynowego, wynikający z przeprowadzonych badań. Celem wprowadzenia SWDLog na poszczególnych szczeblach dowodzenia jest to, aby przez pryzmat wskazanych czynników regresyjnych zminimalizować czasoprzestrzeń logistyczną  $(X, T)$  przy maksymalizacji współczynnika regresji, czym jest optymalne dostarczanie paliwa w zakładanym czasie i ilości zgodnej z dynamiką prowadzonych działań militarnych.

Na współczynnik regresji wpływa szereg czynników, które stanowią funkcję celu  $n$ -zmiennych, którą należy maksymalizować. Należy zakładać, że aby w pełni opisać SWDLog należy otrzymać maksimum wartości zbioru kryteriów funkcji celu, które dotyczą różnych wymiarów prowadzonej operacji zabezpieczenia logistycznego. Wynikiem działania sieci neuronowej będzie  $n$ -wariantów działania (najlepiej cztery),

<sup>5</sup> Decydent - dowódca jednostki logistycznej WSL. Na potrzeby WMPD przyjęto, że jest to na początek Dowódca Organu Logistycznego.

które różnią się kryterium wartości wskaźnika regresji. Wspomniana wielokryterialność cechuje się tym, że nie można wcześniej wskazać ilości wariantów dystrybucji paliwa z podaniem wartości atrybutów dla wybranych problemów. Zamiast tego problemy te składają się ze zbioru kwantyfikowalnych celów oraz dobrze określonych ograniczeń dla czynników kształtujących możliwości wyboru opcji (zmiennych decyzyjnych), na podstawie których algorytm AI uczy się i podejmuje decyzję o wyborze określonej liczby opcji decyzyjnych (wariantów działania). Zabezpieczenie wojsk w paliwo (w nakazanym czasie, miejscu i ilości) jako cel systemu wspomagania decyzji jest procesem uczenia maszynowego na bazie algorytmu z silnikiem opartym o sieć neuronową, gdzie rozwiązaniem jest  $n$ -wskaźników regresji jako  $n$ -wariantów działania.

Najważniejszym zadaniem jest wskazanie odpowiedniego modelu sieci neuronowej, który będzie adekwatny do analizowanego problemu. Dostosowane NN do konkretnego zadania decyzyjnego nie jest łatwe, ale stanowi klucz do dalszego rozwoju oprogramowania wspierającego SWDLog. Literatura wskazuje szereg rozwiązań [Taherdoost 2023] w tym zakresie. Ze względu na to, że konfiguracja NN ma charakter adaptacyjny oprogramowanie oparte o algorytmy z ich wykorzystaniem może obsługiwać szeroki zakres scenariuszy podejmowania decyzji.

Sieci neuronowe ze względu na ich złożoność często nazywane są „czarnymi skrzynkami”. Określenie to wynika z trudności, co do określenia architektury i zrozumienia uzasadnienia ich decyzji [Li et al. 2022]. Należy brać to pod uwagę w przypadku wypracowywania strategii, ponieważ są to procesy krytyczne, od których zależy powodzenie misji i często życie żołnierzy. W związku z tym przejrzystość i odpowiedzialność są najważniejsze, a szczegółowy opis algorytmu działania systemu wspomagającego decyzję jest bardzo istotny. Zainteresowane strony i decydenci mogą wahać się, czy w pełni zaufać decyzjom podejmowanym na podstawie modeli głębokiego uczenia się, jeśli nie potrafią wyjaśnić, w jaki sposób i dlaczego podjęto konkretną decyzję [S. Cheng et al. 2022]. Rozwój technologii AI dąży do zwiększania interpretowalności otrzymywanych wyników, ale modele uczenia się to ciągły obszar badań, którego celem jest wyjaśnienie wskazanych ograniczeń.

Wybór odpowiedniejszej architektury sieci neuronowej zależy od charakteru przetwarzanych danych. W przypadku wskazanego problemu logistycznego najbardziej optymalny rodzaj sieci to wytrenowany model głębokiego uczenia się poprzez wzmacnianie Reinforcement Learning (RL).

Uczenie się przez wzmacnianie różni się od uczenia nadzorowanego tym, że nie wymaga przedstawiania oznaczonych par informacji wejściowa/wyjściowa i nie wymaga bezpośredniego korygowania nieoptymalnych działań. Zamiast tego skupiamy się na znalezieniu równowagi pomiędzy eksploracją nieznanymi rozwiązań, a doświadczeniem decydenta<sup>6</sup>, celem maksymalizacji długoterminowej nagrody, której informacja zwrotna może być niekompletna lub opóźniona [Kaelbling et al. 1996].

---

<sup>6</sup> Decydent w dalszej części jest również określany jako agent.

Przy zastosowaniu tego typu sieci, środowisko (w naszym przypadku przestrzeń logistyczna) będzie określane w formie procesu decyzyjnego Markowa (Markov Decision Process - MDP), ponieważ wiele algorytmów uczenia się przez wzmacnianie w tym kontekście wykorzystuje techniki programowania dynamicznego [van Otterlo, Wiering 2012]. Algorytmy uczenia się przez wzmacnianie, w porównaniu do innych metod uczenia maszynowego, nie zakładają znajomości dokładnego modelu matematycznego procesu decyzyjnego Markowa i skupiają się na dużych procesach decyzyjnych Markowa, gdzie dokładne metody stają się niewykonalne [Li 2023].

Metoda AI uczenia się przez wzmacnianie jest aktualnie badana w wielu dyscyplinach, między innymi w teorii gier, teorii sterowania, badaniach operacyjnych, teorii informacji, optymalizacji opartej na symulacji, systemach wieloagentowych, inteligencji roju i statystyce. Często w literaturze pojawia się określenie uczenia się przez wzmacnianie jako przybliżone programowanie dynamiczne lub programowanie neurodynamiczne.

Uczenie się przez wzmacnianie (RL) to podzbiór uczenia maszynowego, w którym algorytm uczy się, jak uzyskać najlepszy wariant do osiągnięcia celu poprzez interakcję z otoczeniem. W przeciwieństwie do nadzorowanych algorytmów uczenia maszynowego, które opierają się na pozyskiwaniu i przetwarzaniu danych, RL nie potrzebuje danych do uczenia się. Zamiast tego algorytm uczy się na podstawie interakcji ze środowiskiem i „nagród”, które otrzymuje, aby podejmować lepsze decyzje. RL dąży do optymalizacji celu w czasie, a algorytm uczy się metodą prób i błędów po to, aby wybierać działania, które prowadzą do najlepszych rezultatów.

Proces RL obejmuje następujące proste kroki:

- obserwacja otoczenia;
- podejmowanie decyzji o tym, jak działać, stosując zdefiniowaną przez eksperta strategię;
- wykonanie akcji;
- otrzymywanie nagrody lub kary w zależności od podjętego działania;
- uczenie się na doświadczeniach i udoskonalanie strategii;
- powtarzanie tego procesu iteracyjnego do momentu znalezienia optymalnej strategii [Trung Luu 2024].

Można wskazać kilka faz procesu decyzyjnego. Na wstępie należy zidentyfikować sytuację decyzyjną, którą powinny charakteryzować się wszystkie czynniki, mające wpływ na decyzję, jakiej dokona decydent. Następnie sformułowany jest problem decyzyjny jaki stoi przed decydem. Należy w nim zawrzeć definicję: decydenta; opcji decyzyjnych; czynników ograniczających przestrzeń decyzyjną oraz przyczyny kształtujące ocenę opcji decyzyjnych. Pierwsze fazy problemu decyzyjnego są głównie opisowe i oparte o ogólne matematyczne metody definiowania zbiorów.

Kolejna faza to budowa Modelu Decyzyjnego (MD). Model ten to matematyczna reprezentacja rozważanego problemu decyzyjnego. Z pomocą tego modelu można określić elementy zbioru dopuszczalnych opcji decyzyjnych, a także wskazać opty-

malne opcje<sup>7</sup>. Na koniec należy wyznaczyć różne podzbiory zbioru opcji: dopuszczalnych; zadowalających i optymalnych, a następnie na tej podstawie podjąć decyzję. Wyznaczenie różnych podzbiorów zbioru opcji opiera się na zastosowaniu między innymi metod optymalizacji jedno i wielokryterialnych. System wspomaganie decyzji logistycznych - SWDLog (z ang. Decision Support System – DSS w obszarze logistyki) jest to skomputeryzowany system informacyjny, który wspomaga podejmowanie decyzji w obszarze logistyki odpowiedniego poziomu decyzyjnego systemu logistyki SZ.

W miarę jak Decydent wystawia się na działanie otoczenia i otrzymuje różne nagrody poprzez wykonywanie różnych działań, wartości są aktualizowane zgodnie z modelem Markowa:

- a) zbiór stanów otoczenia i decydentów –  $S$ ;
- b) zbioru działań decydenta  $A$ ;
- c) prawdopodobieństwem przejścia ze stanu  $s$  do stanu  $s'$  w czasie wykonywania zadania  $a$ :

$$P_a(s, s') = \Pr(S_{t+1} = s' | S_t = s, A_t = a) \quad (2)$$

- d)  $R_a(s, s')$  to nagroda przy przejściu ze stanu  $s$  do  $s'$ ;

Celem uczenia się przez wzmacnianie jest nauczenie decydenta optymalnej lub prawie optymalnej strategii, która maksymalizuje „funkcję nagrody” na podstawie cząstkowych nagród poszczególnych iteracji procesu decyzyjnego.

Agent procesu wzmacniania AI wchodzi w interakcję z otoczeniem w dyskretyzowanych przedziałach czasu. W czasie  $t$  decydent znajduje się w stanie  $S_t$  i otrzymuje nagrodę  $R_t$ , następnie wybiera działanie  $A_t$  ze zbioru najlepszych rozwiązań, które następnie jest wysyłane do środowiska (przestrzeni logistycznej rys. 2) [Russell, Norvig 2011].

Środowisko reaguje w postaci stanu  $S_{t+1}$  z nagrodą  $R_{t+1}$ , a wszystko jest opisane transmitancją systemu ( $S_t, A_t, S_{t+1}$ ). Celem uczenia przez wzmacnianie jest osiągnięcie strategii:  $\pi: S \times A \rightarrow [0,1], \pi(s, a) = \Pr(A_t, S_{t+1})$ , co zmaksymalizuje nagrodę.

W procesie decyzyjnym Markowa agent bezpośrednio obserwuje bieżący stan środowiska, czyli problem jest w pełni obserwowalny. W przypadku, kiedy decydent ma dostęp tylko do podzbioru stanów lub jeśli obserwowane stany są zniekształcone przez szum (niepełna informacja, zakłócenia w systemie logistycznym), mówi się, że agent ma **częściową obserwowalność** i formalnie problem należy sformułować jako **częściowo obserwowalny proces decyzyjny** Markowa. W obu przypadkach można ograniczać zestaw akcji dostępnych dla decydenta. Na przykład, kiedy decydent ma do wyboru tylko te akcje, które wyznaczy mu poziom nadrzędny systemu logistycznego.

---

<sup>7</sup> Przykład: mistrz szachowy wykonuje ruch. O wyborze wariantu działania informują zarówno planowane z wyprzedzeniem możliwości odpowiedzi i kontr-odpowiedzi oraz poprzez natychmiastowe, intuicyjne oceny celowości określonych położenia. Następnie wykonuje ruch (akcja). Kolejny etap to znów ocena sytuacji i kolejna analiza dostępnych wariantów działania.

W innym przypadku przejście nie będzie dozwolone (mogą to być tylko te akcje, które zakładają wykorzystanie określonych elementów systemu logistycznego lub ograniczenia w postaci dostępności paliwa). W przypadku, kiedy porównuje się działanie decydenta działającego optymalnie oraz tego, który nie maksymalizuje nagrody, rodzi się „poczucie żalu”. W celu zapewnienia działania niemal optymalnego, agent musi rozważyć długoterminowe konsekwencje swoich działań (tj. maksymalizować efekty swoich działań), chociaż natychmiastowa nagroda z tym związana może być w danej chwili niedoborem.

Zatem uczenie się przez wzmacnianie nadaje się do zastosowania w systemach wspomagania decyzji w logistyce o charakterze działań długoterminowych i krótkoterminowych. Zostało ono z powodzeniem zastosowane do rozwiązania różnych problemów, w tym do przechowywania energii [Duque et al. 2022].

Dwa elementy sprawiają, że uczenie się przez wzmacnianie jest skuteczne: wykorzystanie próbek (w naszym przypadku danych o stanie systemu logistycznego na podstawie ZWSI RON) w celu optymalizacji wydajności oraz wykorzystanie aproksymacji funkcji w przypadku dużych środowisk (całego systemu logistyki wojsk). Uczenie przez wzmacnianie nadaje się doskonale do wypracowywania decyzji systemu logistycznego, w którym znany jest model przestrzeni logistycznej, ale nie jest dostępne rozwiązanie analityczne lub kiedy nie musimy zbierać danych o systemie logistyki w danym rejonie działań w interakcji z nim.

## **2. ALGORYTM UCZENIA PRZEZ WZMACNIANIE DO ZASTOSOWANIA W DYSTRYBUCJI PALIW**

Podstawowym zadaniem jakie stoi przed algorytmem optymalizacyjnym to zapewnienie wymaganej ilości paliwa dla oddziału w danym rejonie i w odpowiednim czasie. Nawet jeśli pominięto kwestię eksploracji przestrzeni logistycznej i nawet jeśli stan systemu dystrybucji paliw będzie możliwy do zaobserwowania (założono poniżej), problemem pozostaje wykorzystanie przeszłych doświadczeń w celu ustalenia, które działania prowadzą do wyższych skumulowanych nagród. W przypadku zaopatrzenia w paliwo, celem jest dostarczenie wymaganej ilości paliwa w czasie.

W chwili podjęcia decyzji o wyborze rejonu prowadzonej aktywności przez wojska, brane są pod uwagę środki logistyczne w podanym rejonie celem płynnej realizacji zadań. Niemniej jednak w toku prowadzenia działań może mieć miejsce szereg zdarzeń, które zmieniają pierwotnie przyjęte kryteria prowadzonej operacji. Planowanie działań to proces ciągły, wielowariantowy, w którym prezentowane rozwiązania optymalizacyjne mają za zadanie wskazanie decydentowi  $k$  – najlepszych możliwych rozwiązań w zależności od sytuacji operacyjnej w danym rejonie i czasie. Wymaga to zdefiniowania zestawu informacji w systemie SWDLog o odpowiednich elementach systemu. Do podstawowych parametrów należy zaliczyć:

- prawo i przepisy;

- dane o możliwościach ludzi i sprzętu;
- dane o zasobach i limitach;
- dane o utrzymaniu sił i środków;
- dane historyczne doświadczeń;
- informacja o planowanych działaniach;
- dane geolokalizacyjne [Kępczyński 2024].

Wybór działań decydenta jest modelowany jako mapa zwana polityką (strategią) systemu logistycznego zasilającego wojska w paliwo:

$$\pi: S \times A \rightarrow [0,1] \quad (3)$$

$$\pi(s, a) = \Pr(A_t, S_{t+1}) \quad (4)$$

Mapa strategii daje prawdopodobieństwo podjęcia działań  $a$ , w stanie  $s$  systemu logistycznego. Model algorytmu uczenia przez wzmacnianie przedstawia rysunek 4.

Funkcja wartości stanu  $V_\pi(s)$  jest definiowana jako oczekiwany zdyskontowany zwrot (potencjalny wariant działania), zaczynając od stanu  $s$ , czyli  $S_0=s$  sukcesywnie podążając za założeniami systemu dystrybucji paliwa dla wojsk  $\pi$ .

W związku z tym Funkcja wartości stanu określa to „jak dobrze” jest być w danym stanie [Sutton i Barto 2024]:

$$V_\pi(s) = E[G|S_0 = s] = E[\sum_{t=0}^{\infty} \gamma^t R_{t+1} | S_0 = s] \quad (5)$$

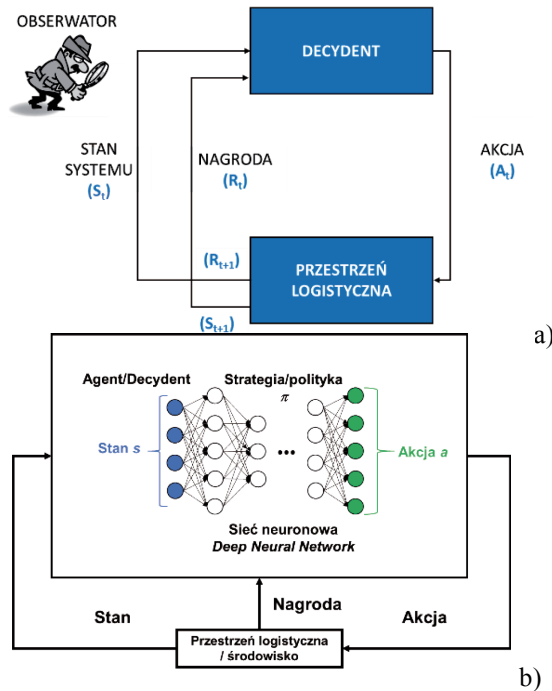
gdzie zmienna losowa  $G$  oznacza korzystny zwrot i jest definiowana jako suma przyszłych najbardziej lukratywnych nagród:

$$G = \sum_{t=0}^{\infty} \gamma^t R_{t+1} = R_1 + \gamma R_2 + \gamma^2 R_3 + \dots \quad (6)$$

gdzie  $R_{t+1}$  jest nagrodą za przejście ze stanu  $S_t$  do  $S_{t+1}$ ,  $0 \leq \gamma \leq 1$  [Xuefei et al. 2017].

Współczynnik zwrotu  $\gamma$  określa ilość przyszłych nagród. Wartość 0 oznacza, że decydent będzie „krótkowzroczny”, biorąc pod uwagę tylko bieżące nagrody. Gdy współczynnik zbliża się do 1 oznacza to, że będzie on dążył do długoterminowej optymalizacji nagród. Jeśli współczynnik  $\gamma$  jest równy lub większy niż 1, wartości podjętych decyzji mogą się różnić i dochodzimy do stanu, gdzie agent nigdy nie osiągnie zakładanego celu, a wszystkie stany systemu logistycznego stają się nieskończenie długie podobnie jak nagrody nieskończone.

Nawet przy współczynniku zwrotu tylko nieznacznie niższym niż 1, gdy funkcja wartości jest aproksymowana za pomocą sztucznej sieci neuronowej uczenie się funkcji  $V$  prowadzi do propagacji błędów i niestabilności. W takim przypadku rozpoczęcie od niższego współczynnika zwrotu i stopniowe zwiększanie go do wartości końcowej przyspiesza naukę [François-Lavet, Fonteneau i Ernst, 2018].



Rys. 4. Model uczenia przez wzmacnianie na danym etapie procesu logistycznego  
 a) bez sieci neuronowej, b) z propozycją umieszczenia sieci neuronowej  
 (źródło: opracowanie własne na podstawie - H. Xuefei, H. H. Seung i inni, Demand Response Management for Industrial Facilities: A Deep Reinforcement Learning Approach)

Podejście poprzez zastosowanie „bezwzględnej” siły obejmuje dwa etapy:

- dla każdej możliwej strategii przykładowa odpowiedź powraca podczas jej stosowania;
- wybierz strategię z największym oczekiwanym zwrotem przy minimalnym wkładzie.

Problemem stanowi liczba strategii, która może być duża lub nawet nieskończona. Ponadto może wystąpić rozbieżność wartości zwrotu, która może być duża, co wymaga wielu próbek, aby dokładnie oszacować minimalną stopę zwrotu dla każdej strategii.

Problemy te można złagodzić, jeśli przyjmiemy pewną strukturę i pozwolimy, aby próbki wygenerowane z jednej z nich wpływały na szacunki dokonane dla innych. Dwa główne podejścia do osiągnięcia tego to **estymacja funkcji wartości stanu** i **bezpośrednie poszukiwanie strategii**.

Przybliżmy teraz wskazane oba rozwiązania przydatne do wypracowania optymalnej decyzji w systemie logistycznym. Na początku należy zaznaczyć, że nagrody

w odległej przyszłości mają mniejszą wagę niż nagrody w najbliższej przyszłości (system logistyczny kształtowany w perspektywie krótkoterminowej będzie bardziej dopracowany niż ten w dalekiej przyszłości).

Najbardziej optymalne rozwiązanie do systemu wspomagania decyzji w procesach logistycznych jest oparte na **funkcji wartości stanu**  $V_\pi(s)$ . Ważne jest odpowiednie zdefiniowanie tego parametru, ponieważ w zależności od wprowadzonych współczynników można mówić o  $n$ -wariantach działania w danym stanie systemu logistycznego.

Podejścia oparte na funkcji wartości stanu próbują znaleźć politykę, która maksymalizuje najbardziej korzystny wariant, utrzymując zestaw szacunków nakierowanych na minimalny zwrot  $E[G]$  dla przyjętej strategii działania. Zwykle jest to szacunek, który mieści się „w strategii” lub jeżeli to najbardziej optymalne „poza strategią”.

Podejście to opiera się na teorii prezentowanych już procesów decyzyjnych Markowa, gdzie optymalność jest zdefiniowana w sensie silniejszym niż powyższy: strategia jest optymalna, jeśli osiąga najbardziej oczekiwany zwrot z dowolnego stanu początkowego (tj. stany początkowe nie odgrywają żadnej roli w wyznaczeniu strategii). W związku z tym politykę strategii można odnaleźć wśród polityk stacjonarnych. Po to, aby zdefiniować najbardziej optymalną strategię  $\pi$  trzeba zdefiniować stan systemu:

$$V^\pi(s) = E[G|s, \pi] \quad (7)$$

gdzie  $G$  oznacza obniżony zwrot związany z obserwacją stanu początkowego.

Definiując  $V^*(s)$  jako maksymalną możliwą wartość stanu  $V^\pi(s)$ , gdzie  $\pi$  może ulegać zmianie otrzymujemy poniższą zależność:

$$V^*(s) = \max_{\pi} V^\pi(s) \quad (8)$$

Strategię, która osiąga optymalne wartości stanu w każdym stanie, nazywa się optymalną. Jest oczywiste, że strategia optymalna w tym mocnym sensie jest również optymalna w tym sensie, że maksymalizuje oczekiwany obniżony zwrot  $\rho^\pi$  dla  $\rho^\pi = E[V^\pi(s)]$ , gdzie  $s$  to stan losowo wybrany z rozkładu stanów początkowych  $\mu$  ( $\Pr(S_0 = s)$ ).

Chociaż wartości stanu wystarczą do zdefiniowania optymalności, przydatne jest zdefiniowanie wartości działania. Biorąc pod uwagę stan  $s$ , akcję  $a$  i strategię  $\pi$ , można zdefiniować wartość akcji  $(s, a)$  w strategii  $\pi$  w następujący sposób:

$$Q^\pi(s, a) = E[G|s, a, \pi] \quad (9)$$

gdzie  $G$  oznacza teraz losowy obniżony zwrot związany odtąd z podjęciem pierwszego działania  $a$  w stanie  $s$  i strategii  $\pi$ .

Teoria procesów decyzyjnych Markowa oznacza, że jeżeli  $\pi^*$  jest optymalną strategią, działamy optymalnie (podejmujemy optymalną akcję) wybierając akcję ze  $Q^{\pi^*}(s, \cdot)$  z najwyższą wartością akcji w danym stanie  $s$ . Wartość akcji w optymalnej strategii  $Q^{\pi^*}$  jest nazywany optymalną wartością funkcji akcji i jest zwykle oznaczany przez  $Q^*$ . Podsumowując, sama wiedza o optymalnej funkcji wartość-działanie wystarczy, aby wiedzieć, jak działać optymalnie.

Zakładając pełną wiedzę na temat procesu decyzyjnego Markowa, dwoma podstawowymi podejściami do obliczenia optymalnej funkcji wartość-działanie są powtarzalność wartości i powtarzalność strategii. Obydwa algorytmy obliczają sekwencję funkcji  $Q_k (k = 0, 1, 2, \dots)$ , które dążą do  $Q^*$ . Obliczanie tych funkcji obejmuje obliczanie oczekiwania w całej przestrzeni stanów procesu logistycznego, co jest niepraktyczne w przypadku wszystkich procesów decyzyjnych Markowa z wyjątkiem najmniejszych (skończonych). W metodach uczenia się przez wzmacnianie oczekiwane są stopniowo przybliżane wartości uśrednionych próbek i stosowanie technik aproksymacji funkcji, aby sprostać konieczności reprezentowania funkcji wartości w dużych przestrzeniach stanu-akcji.

Alternatywną metodą jest **bezpośrednie poszukiwanie strategii** w (pewnym podzbiórce) przestrzeni strategii, w którym to przypadku problem staje się zagadnieniem optymalizacji stochastycznej. Dostępne są metody gradientowe i bezgradientowe. Metody oparte na gradiencie (metody gradientu polityki) rozpoczynają się od odwzorowania przestrzeni skończonych wymiarów (parametrów) na przestrzeń strategii: biorąc pod uwagę wektor parametrów  $\theta$ . Niech  $\pi_\theta$  oznacza strategię powiązaną z  $\theta$ . Funkcja wydajności jako  $\rho(\theta) = \rho^{\pi_\theta}$  jest różniczkowalna jako funkcja wektora parametrów  $\theta$ . W metodach bezgradientowych nie jest dostępne wyrażenie analityczne dla gradientu, znane jest jedynie rozmyte oszacowanie. Takie oszacowanie można skonstruować na wiele sposobów, co daje podstawę do algorytmów takich jak metoda REINFORCE Williamsa [Williams 1987] (znana również jako metoda współczynnika wiarygodności w literaturze dotyczącej optymalizacji opartej na symulacji [Peters, Vijayakumar i Schaal]).

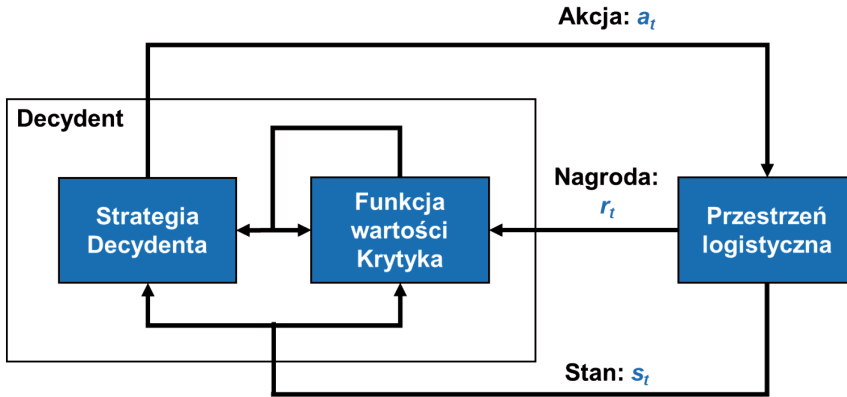
Duża klasa metod pozwala uniknąć polegania na informacjach o gradiencie. Należą do nich symulowane wyżarzanie, poszukiwanie entropii krzyżowej lub metody obliczeń ewolucyjnych. Wiele metod bez gradientów może osiągnąć globalne maksimum. Metody wyszukiwania zasad mogą powoli się zbliżyć, biorąc pod uwagę zaszumione dane. Dzieje się tak na przykład w przypadku problemów epizodycznych, gdy trajektorie są długie, a wariancja zwrotów duża. W tym przypadku pomocne mogą być metody oparte na funkcjach wartości, które opierają się na różnicach czasowych. W ostatnich latach zaproponowano metody aktora-krytyka, które dobrze się sprawdziły w przypadku różnych problemów [Juliani 2024]. Wiele metod wyszukiwania zasad może utknąć w lokalnych optimach (ponieważ opierają się na wyszukiwaniu lokalnym).

### 3. SCHEMAT SIECI NEURONOWEJ DLA SWDLOG

W metodach uczenia maszynowego opartych na wartościach (np. Q-learning [Watkins i Dayan 1992] i SARSA [Rummery i Niranjan 1994]), agent uczący się wybiera jedynie funkcję wartości wariantu działania (akcji) przy braku wyraźnej funkcji strategii  $\pi$ . Wybierając odpowiedni wariant (akcję), agent korzysta z funkcji, która szacuje wartość oczekiwanej nagrody za wszystkie działania zrealizowane przez decydentów, a następnie podejmuje decyzję. Przykładowo wybiera najlepsze działanie, które zapewnia najwyższą nagrodę. Niestety decydent (agent) w celu zapewnienia optymalnego wariantu działania musi wykonać iterację wszystkich potencjalnych działań dla każdego stanu, aby określić najlepsze rozwiązanie, co jest czasochłonne, zwłaszcza gdy przestrzenie stanów i akcji są duże.

Dlatego samo zastosowanie algorytmów opartych na wartościach nie sprawdza się w realnym świecie, ponieważ przestrzenie stanu i akcji są zawsze złożone i wysublimowane. Dlatego algorytmy oparte na polityce nie używają funkcji wartości. Raczej bezpośrednio parametryzują strategię działania i aktualizują parametry za pomocą metod gradientowych [Sutton et al. 2000]. Zatem w przeciwieństwie do stosowania rozwiązań procesu krok po kroku dla funkcji wartości, agent wykonuje sekwencję działań specyficzną dla danej strategii i dostosowuje działanie/wybór poprzez odniesienie do skumulowanej nagrody dopiero po przejściu przez cały etap uczenia się. Stronniczość kumuluje się od dowolnego pojedynczego kroku decyzyjnego przez cały przedział czasu. W związku z tym gradient jednoetapowy szacunków wykazuje wysoki poziom wariacji, dlatego nauka sieci jest powolna. Aby przezwyciężyć wady powyższych dwóch typów sieci RL, łączy się aktora i krytyka, którego można uznać za zaawansowaną wersję algorytmu opartego na zdefiniowanych zasadach. Decydent nadal wskazuje działania (warianty), a krytyk wykorzystuje do tego funkcję wartości po to, aby ocenić stosowaną strategię. Samo przyłączenie się krytyka do procesu uczenia się sieci neuronowej zmniejsza wariację podczas szacowania gradientu jednoetapowego.

Podczas optymalizacji polityki (strategii) krytyk używa funkcji wartości do oszacowania skumulowanej nagrody dla wszystkich stanów, których decydent doświadczył. Potem różnice pomiędzy wartościami oczekiwanymi i otrzymanymi rejestruje się jako tymczasowe błędy różnicowe (Temporal Difference - TD), wskazujące czy bieżąca polityka jest najbardziej dostosowana do osiągnięcia wymaganych rezultatów. Aktor wykorzystuje błędy TD, gdy aktualizuje gradienty wyboru akcji w każdym stanie, w celu zmniejszenia wariacji i przyspieszenia nauki. Dlatego algorytmy aktora krytycznego zwykle wykazują się szybszą zbieżnością niż w przypadku, kiedy aktor lub krytyk pracuje sam [Ernst et al. 2009]. Rysunek 5 przedstawia schemat uczenia się decydenta opartego na aktorze i krytyku; aktor determinuje działania, a krytyk przetwarza nagrody.



Rys. 5. Schematyczna struktura uczenia się decydenta opartego na aktorze i krytyku  
(źródło: opracowanie własne na podstawie [Xuefei 2022])

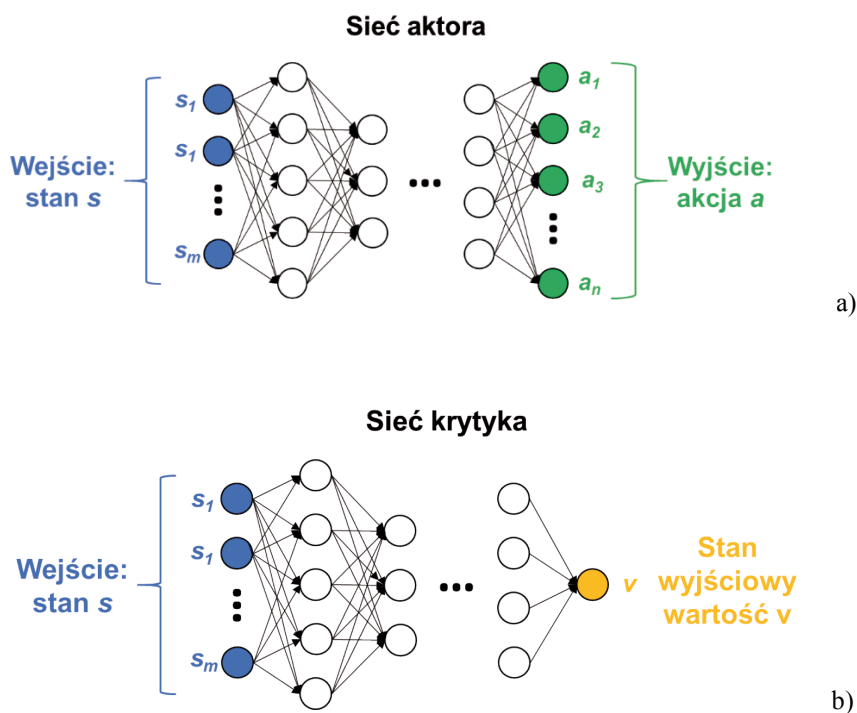
W trakcie nauki decydent, po zapoznaniu się z najnowszymi stanami środowiska realizuje akcję (zadanie) zgodnie ze swoją obecną polityką. Z drugiej strony krytyk ocenia jakość tej decyzji za pomocą funkcji wartości.

Powstały błąd TD służy jako informacja zwrotna zarówno dla decydenta, jak i krytyka, na podstawie którego można zbudować odpowiednio dostosowaną politykę i funkcję wartości.

Podczas tradycyjnego algorytmu wzmacniającego RL przy użyciu prostej tabeli przeglądowej lub liniowej aproksymatora funkcji, trudno jest zidentyfikować optymalną politykę planowania, gdy przestrzeń stanów jest duża. Nazywa się to określeniem „przekleństwa wymiarowości” [Bach 2017].

Wykorzystując krytyka i jego ocenę strategii wykorzystuje się najnowszy trend w szkoleniu głębokich sieci neuronowych do radzenia sobie z zagrożeniami złożoności procesów [Atallah, Assi i Khabbaz 2018]. Szczególnie AlphaGo [Silver et al. 2016] zachęcało do intuicyjnego zrozumienia tego, co może osiągnąć głęboki algorytm RL i głęboka sieć neuronowa, co w połączeniu stanowi potężną funkcję aproksymacyjną [Mnih 2015].

Proces MDP (Markov Decision Process) w procesach logistycznych DR (Demand Response) zawiera wiele wejść stanu i wiele wyjść akcji, z których korzysta głęboka sieć neuronowa w celu przybliżenia zarówno polityki, jak i wartości funkcji działania. Rysunek 6 przedstawia przykładową implementację aktora i sieci krytyków.




Rys. 6. Przykładowa implementacja sieci a) decydentów i b) krytyków  
(źródło: opracowanie własne na podstawie [Xuefei, et al. 2017])

Konkretnie, zgodnie z ogólną strukturą architektury aktor-krytyk na rysunku 6, dane wejściowe do obu sieci to stany środowiska agenta; zawiera  $m$ -wymiarowe pod elementy ponumerowane od  $s_1$  do  $s_m$ . W związku z tym wyjście sieci aktora zawiera  $n$  jednostek oznaczonych od  $a_1$  do  $a_n$ , które można nazwać działaniami. Z drugiej strony wyjście sieci krytyka jest wartością stanu  $v$ ; jest to oczekiwana skumulowana nagroda od aktualnego stanu wejścia. Na tej podstawie wyliczono błąd TD (różnica pomiędzy szacowaną wartością stanu, a rzeczywistą nagrodą), który wprowadza sygnał wzmacniający służący do regulacji obu sieci decydentów i krytyków.

Niezależnie od wniosków, co do struktury sieci neuronowej przedstawionych powyżej należy określić rodzaj sieci jaką wykorzysta algorytm w procesie wspomaganie decyzji. Głębokość, liczba ukrytych warstw i możliwości determinacji danych wejściowych i wyjściowych każdego węzła to najważniejsze kryteria stosowane w procesie doboru sieci neuronowych do realizacji problemów decyzyjnych. Najważniejsze rodzaje modeli sieci neuronowych to:

- sieci neuronowe ze sprzężeniem zwrotnym;
- perceptronowe i wielowarstwowe sieci neuronowe;
- rekurencyjne sieci neuronowe;
- modułarne sieci neuronowe.

W wyniku analizy literatury pod kątem wyboru sieci neuronowej do modelu RL wskazano, że najbardziej korzystnym z punktu widzenia złożoności systemów wsparcia decyzji w logistyce będzie sieć neuronowa modułarna MNN (Modular Neural Network).



Rys. 7. Przykład struktury neuronów i modułów sieci modułowej do algorytmu uczenia sieci typu RL możliwa do zastosowania zarówno dla decydenta i krytyka (źródło: opracowanie własne na podstawie [A. Schmidt, et al. 1996])

MNN składa się z kilku odrębnych sieci, z których każda wykonuje określone zadanie. W całym procesie obliczeń komunikacja i interakcja między różnymi sieciami jest niewielka. Każda z nich osobno przyczynia się do wyniku. Ma to szczególne znaczenie w procesach wspomaganiania decyzji w logistyce ze względu na występowaniu wielu procesów decyzyjnych w tym samym czasie. Wyniki każdego z procesów decyzyjnych z osobna mogą oddziaływać między sobą. Niemniej jednak każda z sieci zgodnie z RL dąży do doskonałości prezentowanego wyniku. Modułarna sieć neuronowa MNN:

a) zalety:

- wydajna;
- uczona niezależnie;

b) wady:

- możliwość rozmycia celu działania.
- wewnątrz poszczególnych modułów można przyjąć następujące algorytmy uczenia, w tym trzy drugiego rzędu:
  - BGGs Quasi-Newton (oznaczany BFG);
  - Levenberg-Marquardt (oznaczany LM);
  - Bayesian Regularization (oznaczany BR);

i jeden odporny algorytm uczenia:

- RBP odporny algorytm propagacji wstecznej (oznaczany RP).

We wszystkich modelach można zastosować sigmoidalne funkcje aktywacji neuronów w warstwie ukrytej.

Zastosowanie poszczególnych algorytmów wymaga przeprowadzenia stosowanych badań na podstawie zgromadzonych danych z systemu logistycznego. Na podstawie empirycznych testów wskazane zostaną najbardziej optymalne sieci. Niemniej jednak jest to odrębne zagadnienie, a prezentowany artykuł określa początkowe ramy

modułu wspomaganie decyzji SWDLog do opracowania programu, który zostanie poddany badaniom.

Prezentowany model AI musi znaleźć najlepszą strategię, aby maksymalizować oczekiwane rezultaty przy minimalnych kosztach proponowanego rozwiązania. Z teorii procesów decyzyjnych Markowa wiadomo, że bez utraty ogólności rozwiązanie problemu można ograniczyć do zbioru tzw. polityk (strategii) stacjonarnych (PS). Strategia jest stacjonarna, jeśli zwrócony przez nią rozkład działań zależy tylko od ostatniego ustalonego stanu systemu logistycznego (z historii działań decydenta). Wyszukiwanie można dodatkowo ograniczyć do deterministycznych polityk stacjonarnych. Deterministyczna polityka stacjonarna wybiera działania na podstawie bieżącego stanu. Każdą taką politykę można zidentyfikować za pomocą mapowania zbioru stanów na zbiór działań bez utraty ogólności wskazywanego rozwiązania.

#### 4. WNIOSKI

W artykule zaproponowano model AI przeznaczony do wspomaganie procesu podejmowania decyzji w logistyce. Tego typu rozwiązanie może zostać zaimplementowane do modułu systemu ZWSI RON o nazwie SWDLog przeznaczonego do wsparcia procesu decyzyjnego w czasie rzeczywistym dzięki wypracowywanym wariantom działania. Zaproponowany model wsparcia decyzji w systemie dystrybucji paliw opiera się o sieć neuronową, dla której wskazano podstawowe parametry wejściowe jak i stany początkowe systemu, ograniczone jedynie do dystrybucji paliw. Model modularnej wielowarstwowej jednokierunkowej sieci neuronowej MNN (Modular Neural Network) wytrenowany dzięki modelowi głębokiego uczenia się poprzez wzmacnianie Reinforcement Learning (RL) wydaje się być najbardziej optymalnym rozwiązaniem do zapewnienia wariantów działania dla kadry kierowniczej na wskazanych stanowiskach systemu logistycznego wojsk. Niemniej jednak, aby wskazane rozwiązanie informatyczne przyniosło efekty należy nauczyć system AI poprzez doświadczenia decydentów i dane historyczne w jaki sposób przedstawiać kilka optymalnych wariantów dystrybucji paliw. Model wspomaganie procesu decyzyjnego na potrzeby zapewnienia energii Siłom Zbrojnym bazujący na algorytmach uczenia maszynowego wymaga poza stworzeniem modułu SWDLog opartego o NN przeprowadzenia badań z użyciem zaproponowanego narzędzia informatycznego i rzeczywistych danych wprowadzonych do systemu ZWSI RON. Dzięki temu zostanie potwierdzona teza zastosowanego modelu uczenia, struktury sieci neuronowej oraz wewnętrznych algorytmów uczenia się. Biorąc powyższe pod uwagę autorzy rozpoczęli prace nad kolejnym artykułem, który przedstawi wyniki badań w oparciu o opracowane oprogramowanie z modułem SWDLog zawierające zaproponowane rozwiązanie AI. Wnioski z tego artykułu pozwolą na zaproponowanie kompleksowego modelu wspomaganie procesu decyzyjnego w Siłach Zbrojnych nie tylko do zastosowań w logistyce.

## LITERATURA

1. Kwiatkowski L., 2011, *Podjęmowanie decyzji. 5 kroków do lepszych wyników*, Wydawnictwo MT Biznes Sp. z o.o., Warszawa
2. Kępczyński A., 2024, *Model wspomagania procesu decyzyjnego na potrzeby zapewnienia energii Siłom Zbrojnym*, Konferencja Perspektywy logistyki wojskowej i cywilnej w kontekście zapewnienia odporności Siłom Zbrojnym, tom 1, s. 3
3. Sutton S., Barto A. G., 2012, *Reinforcement Learning: An Introduction*, The MIT Press Cambridge, Massachusetts London
4. *Deep Learning and Neural Networks: Decision-Making Implications*, H. Taherdoost, <https://www.mdpi.com/journal/symmetry>, (dostęp 10.03.2024 r.)
5. Li J., Yin G., Wang X., Yan W., 2022, *Automated decision making in highway pavement preventive maintenance based on deep learning*, *Automation in Construction*, Elsevier B.V., nr 135, s.135
6. Kaelbling L., Littman P., Michael L., Moore A., 1996, *Reinforcement Learning: A Survey*, *Journal of Artificial Intelligence Research*, nr 4, s. 237–285
7. Cheng S., Wang Z., Yang B., Nakano K., 2022, *Convolutional Neural Network-Based Intelligent Decision-Making for Automated Vehicles*, *IFAC-PapersOnLine*, nr 55, s. 509–514
8. van Otterlo M., Wiering M., 2012, *Reinforcement Learning and Markov Decision Processes*, Springer, Berlin, Heidelberg
9. Li S., *Reinforcement Learning for Sequential Decision and Optimal Control (First ed.)*. 2023, Springer, Verlag
10. *Q-Learning vs. Deep Q-Learning vs. Deep Q-Network*, <https://www.baeldung.com/cs/q-learning-vs-deep-q-learning-vs-deep-q-network>, Trung Luu Q., (dostęp 10.03.2024)
11. Russell J., Norvig P., 2011, *Artificial intelligence: a modern approach (Third ed.)*. Upper Saddle River, New Jersey
12. Duque S., Mauricio E., Giraldo S. i inni, 2022, *Community energy storage operation via reinforcement learning with eligibility traces*, *Electric Power Systems Research*, nr 212, s. 212
13. *Reinforcement learning: An introduction*, <https://web.archive.org/web/20170712170739/>, Richard Sutton S., Barto A. G., (dostęp 2024.03.16)
14. Xuefei H., Seung HH., i inni, 2017, *Demand Response Management for Industrial Facilities: A Deep Reinforcement Learning Approach*, School of Computer Science and Engineering, Tianjin University of Technology, Tianjin, China 2 Department of Electronic Engineering, Hanyang University, Ansan, Republic of Korea
15. François-Lavet V., Fonteneau R., Ernst D., 2018, *An Introduction to Deep Reinforcement Learning*, *Foundations and Trends in Machine Learning*, nr 11, s. 219–354
16. Williams R., 1987, *A class of gradient-estimating algorithms for reinforcement learning in neural networks*, *Proceedings of the IEEE First International Conference on Neural Networks*, Kluwer Academic Publishers, Boston, s. 230
17. *Reinforcement Learning for Humanoid Robotic*, International Conference on Humanoid Robots, Peters J., Vijayakumar S., Schaal S., <https://homepages.inf.ed.ac.uk/svijayak/publications>, (dostęp 17.03.2024)
18. *Simple Reinforcement Learning with Tensorflow Part 8: Asynchronous Actor-Critic Agents (A3C)*, Juliani A., <https://medium.com/emergent-future/simple-reinforcement->

- learning-with-tensorflow-part-8-asynchronous-actor-critic-agents-a3c-c88f72a5e9f2, (dostęp 17.03.2024)
19. Schmidt A., 1996, A Modular Neural Network Architecture with Additional Generalization Abilities for High Dimensional Input Vectors, Manchester Metropolitan University, Department of Computing, Manchester
  20. Bach F., 2017, Breaking the curse of dimensionality with convex neural networks, *Journal of Machine Learning Research*, JMLR.org, nr 18, s. 1-53
  21. Atallah R. F., Assi C. M. and Khabbaz M. J., 2022, Scheduling the Operation of a Connected Vehicular Network Using Deep Reinforcement Learning, Elsevier Science Publishers B. V. Netherlands, nr 33
  22. Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., Van Den Driessche, G., Schrittwieser, J., Antonoglou, I., Panneershelvam, V., Lanctot, M., et al. 2016, Mastering the game of go with deep neural networks and tree search, *Nature*, Macmillan Publishers Limited, NY, nr 529, s. 484–489
  23. Mnih, V. et al., 2015, Human-level control through deep reinforcement learning, *Nature*, Macmillan Publishers Limited, NY, nr 518, s. 529–533

## **APPLICATION OF NEURAL NETWORK IN TO DECISION-MAKING MODEL PROCESSES FOR MILITARY FUEL DISTRIBUTION SYSTEM**

### **Abstract**

The model of the energy sustainment system for military unit's would not be complete without identify the operating variants that lead to ensure the optimal level of energy in the Logistics Sustainment Units. In this case, all activities should be intensified to implement Artificial Intelligence (AI) algorithms into computer decision support systems for commanders (decision-makers) at every level of the military logistics support system. The authors focus only at the fuel distribution system, but it is an excellent starting point for extending the presented decision-making model to other military processes. In order to cope with the task of developing a decision support model in the fuel distribution system, it is necessary to develop a basic regression parameter of the learning algorithm based on neural networks (Neural Network - NN), which include: measured values, outflow and inflow of the working medium, environmental data, errors, regulation indicators, control signals distribution system, time of operation and energy capacity. The model of a modular multi-layer unidirectional neural network MNN (Modular Neural Network) presented in this article, trained using the deep learning model based on Reinforcement Learning (RL) and the experience of decision-makers will allow the AI system to present several optimal fuel distribution variants. The article shows a model of an algorithm based on a neural network with a learning algorithm by strengthening the optimal variant in the learning system with an observer solution, which based on several criteria, provides optimal provision of the required level of fuel in the OG in a selected space of the operation. The presented neural network model is the basic element of the decision-making proces of the military logistics system and, after could be transfered into their operational potential.

**Keywords:** decision model, logistic system, decision support model, neural network

**PUBLIKACJA [4]**

- [4].Łukowski D., Kępczyński A., *Transformacja energetyczna – wyzwania dla sił zbrojnych*, rozdział w monografii *Perspektywy logistyki wojskowej i cywilnej w kontekście zapewnienia odporności Siłom Zbrojnym* (konferencja Bydgoszcz), Warszawa: Wydawnictwo ITWL 2024, Tom 1.

Dariusz ŁUKOWSKI\*  
Artur KĘPCZYŃSKI\*\*

## **TRANSFORMACJA ENERGETYCZNA – WYZWANIA DLA SIŁ ZBROJNYCH**

Większość państw NATO należy do Unii Europejskiej, ale kilka z nich (w tym kluczowy sojusznik - Stany Zjednoczone) położonych jest poza Europą. We wszystkich dokonywana jest transformacja energetyczna wynikająca z wyzwań obejmujących ochronę klimatu, uniezależnienie od surowców zewnętrznych oraz rozwój nowych technologii. Jej tempo i sposób wdrażania uzależniany jest od prawa wspólnotowego i wewnętrznych uregulowań prawnych. Sposób realizacji i ramy prawne regulujące ten obszar są różne, a więc mają zróżnicowany, potencjalny wpływ na to jak oddziałują one na rozwój sił zbrojnych. Ma to bezpośredni wpływ na politykę obronną poszczególnych państw oraz zagrożenia wynikające z potencjalnego, zróżnicowanego sposobu i tempa wdrażania nowych rozwiązań w siłach zbrojnych NATO. Ewidentnie Stany Zjednoczone i Wielka Brytania bardzo mocno akcentują te zagadnienia w swojej strategii rozwoju i mają skonkretyzowane plany działania. Niektóre państwa UE również zapoczątkowały ten proces, ale większość nie uwzględnia tych wyzwań w swojej działalności obronnej. Dokonywane analizy, testy i wdrożenia wskazują na wiele ograniczeń i wyzwań związanych z elektryfikacją platform bojowych, stawiając na tym etapie rozwoju na rozwiązania hybrydowe. Jednocześnie zapotrzebowanie na energię na polu walki wciąż rośnie. Na dzień dzisiejszy dalej uznaje się paliwo lotnicze JP8 oraz olej napędowy za najbardziej efektywne źródło energii. Wszelkie dane wskazują, że przed rokiem 2040 nie należy spodziewać się wyraźnego przełomu w zakresie wdrożenia ciężkich wozów bojowych o napędzie elektrycznym.

Słowa kluczowe: transformacja energetyczna, napęd hybrydowy, napęd elektryczny, nośniki energii, gęstość energii

---

\* Biuro Bezpieczeństwa Narodowego.

\*\* Inspektorat Wsparcia Sił Zbrojnych.

## 1. WPROWADZENIE

Dokonująca się na przestrzeni ostatnich lat transformacja energetyczna zmierza w kierunku ograniczania emisji szkodliwych substancji do atmosfery poprzez wdrażanie proekologicznych, w tym odnawialnych, źródeł energii oraz budowę systemów poprawiających efektywność energetyczną i obniżenie zapotrzebowania na energię. Skutki tych działań obejmują wszystkie sfery życia publicznego, ekonomii, biznesu, struktur państwowych, a także sił zbrojnych, które funkcjonują w tym samym ekosystemie. Tempo i sposób wdrażania nowych rozwiązań jest zróżnicowane. Unia Europejska wypracowała odrębne strategie w tym zakresie od USA i Kanady. Należy jednak pamiętać, że państwa UE, USA i Kanada są członkami Sojuszu Północnoatlantyckiego, gdzie istotnym czynnikiem skuteczności militarnej jest interoperacyjność sił zbrojnych. Jednocześnie digitalizacja wojsk, coraz większe stosowanie energii jako systemu walki, czy to w postaci energii kierowanej, czy też walki radioelektronicznej, powoduje gwałtowne zwiększenie zapotrzebowania na energię w warunkach bojowych. Czy zatem nowe strategie i sposób realizacji transformacji energetycznej stanowią wyzwanie, czy też są niezbędne do zachowania zdolności wojsk do prowadzenia skutecznych działań militarnych. W niniejszym artykule podejmiemy próbę odpowiedzi na to pytanie.

## 2. UWARUNKOWANIA PRAWNE – UE I NATO

Europejski Zielony Ład jest wyrazem aspiracji naszej części świata do bycia pierwszym regionem neutralnym dla klimatu. W założeniu jest osiągnięcie do roku 2050 zerowego poziomu emisji gazów cieplarnianych netto. W tym celu podejmowanych jest szereg działań mających na celu konstrukcję przepisów regulujących między innymi politykę energetyczną i transportową. W ciągu najbliższych siedmiu lat na realizację celów zielonego ładu UE planuje wydatkować około 600 mld euro<sup>2</sup>. W ramach programów energetycznych zamierza się przeprowadzenie modernizacji sieci, ich ucyfrowienie, wdrożenie sieci inteligentnych z bardzo efektywnymi systemami zarządzania, wdrożenie rozproszonych, odnawialnych źródeł energii oraz zastosowanie wodoru jako nośnika energii oraz metody długoterminowego jej magazynowania. Jest to efekt wcześniej zaprezentowanego pakietu zwanego „Fit-for-55 package”<sup>3</sup> z roku 2021. Zwiera on między innymi tak zwany „Pakiet wodoryzacji i dekarbonizacji rynku gazowego”.

---

<sup>2</sup> Komisja Europejska, *Energia Zielony Ład*; [https://commission.europa.eu/strategy-and-policy/priorities-2019-2024/european-green-deal/energy-and-green-deal\\_pl](https://commission.europa.eu/strategy-and-policy/priorities-2019-2024/european-green-deal/energy-and-green-deal_pl)

<sup>3</sup> *Fit-for-55 – Gotowi na 55*

Integralną częścią Europejskiego Zielonego Ładu jest redukcja gazów cieplarnianych związanych z transportem o 90% do 2050 r<sup>4</sup>. Konsekwencją jest dążenie do ograniczenia emisji pochodzących z samochodów osobowych o 55% i z samochodów dostawczych o 50% do 2030r. Do 2035 r. zakłada się osiągnięcie celu zerowej emisji z nowo produkowanych samochodów osobowych i dostawczych, a do 2050 r. wycofanie z eksploatacji większości starych pojazdów emisyjnych. Oznacza to wycofanie z produkcji silników spalinowych, a w ich miejsce zastosowanie napędów elektrycznych lub bazujących na ogniwach paliwowych.

Podobne działania podjęto w obszarze redukcji emisji pochodzących od statków powietrznych i jednostek pływających. Tutaj koncentruje się uwagę na wsparciu zastosowania zrównoważonych paliw lotniczych, takich jak wodór, paliwa odnawialne pochodzenia niebiologicznego (paliwa syntetyczne) oraz zaawansowanie biopaliwa. W przypadku jednostek morskich do roku 2050 zakłada się ograniczenie emisji o 80%<sup>5</sup>.

Przywołane kierunki zmian w żadnym stopniu nie odnoszą się do ewentualnych wyłączeń w stosunku do sprzętu użytkowanego przez siły zbrojne państw Unii. Należy więc domniemywać, że skutki tworzonych regulacji obejmą również sferę obronną.

W przypadku NATO, już w Koncepcji Strategicznej przyjętej podczas szczytu lizbońskiego w 2010 r. pojawiają się zapisy dotyczące negatywnego wpływu zmian klimatycznych na środowisko potencjalnych działań wojsk oraz konieczność uwzględnienia wymogów ochrony środowiska przez siły sojusznicze. W ramach kolejnych szczytów NATO problematyka ta była pogłębiana i rozpoczęto również proces standaryzacji tego obszaru w ramach Sojuszu. Od niedawna rozpoczęto dyskusję na temat potencjalnego wpływu projektowanej i wdrażanej transformacji na funkcjonowanie wojsk analizując potencjalne ograniczenia i ryzyka związane jej wdrażaniem. Zainteresowanie to przekłada się również na analizy wpływu dostępu do surowców, uzależnień z tym związanych i wykorzystywania ich jako narzędzi nacisku polityczno-gospodarczego. Dostęp do surowców generuje również napięcia w relacjach międzynarodowych i w coraz większym stopniu staje się przyczyną potencjalnych konfliktów. Zakłócenie dostaw energii wpływa bezpośrednio na bezpieczeństwo i prowadzone operacje NATO.

W 2020 r. grupa analityczna powołana przez sekretarza generalnego NATO na wniosek państw członkowskich sformułowany podczas szczytu w Londynie w 2019 roku opracowała dokument zatytułowany „NATO 2030: Zjednoczeni dla

---

<sup>4</sup> Komisja Europejska, *Transport a Zielony Ład*; [https://commission.europa.eu/strategy-and-policy/priorities-2019-2024/european-green-deal/transport-and-green-deal\\_pl](https://commission.europa.eu/strategy-and-policy/priorities-2019-2024/european-green-deal/transport-and-green-deal_pl)

<sup>5</sup> Parlament Europejski; *Fit for 55: deal on new EU rules for cleaner maritime fuels*; <https://www.europarl.europa.eu/news/pl/press-room/20230320IPR77909/fit-for-55-deal-on-new-eu-rules-for-cleaner-maritime-fuels>

Nowej Ery”<sup>6</sup>. W dokumencie tym pojawił się rozdział dotyczący bezpieczeństwa energetycznego wraz z ośmioma rekomendacjami. W rekomendacjach, oprócz treści dotyczących analiz, wymiany informacji, czy ochrony infrastruktury krytycznej znajdują się zapisy dotyczące potrzeby rozwijania programu inteligentnej energii, poprawy efektywności energetycznej wojsk oraz zapewnienia dostępności zasobów energetycznych niezbędnych do prowadzenia działań w ramach Art. 5 Traktatu Północnoatlantyckiego.

Analizując zapisy dokumentów sojuszniczych trudno znaleźć konkretnych zapisów dotyczący wymogów związanych z adaptacją instalacji wojskowych oraz platform bojowych związanych z transformacją energetyczną, ale w środowisku sojuszniczym trwa dyskusja, głównie stymulowana przez USA na ten temat.

Z całą pewnością, w celu zachowania interoperacyjności wojsk NATO działania te wymagają spójnego planowania i wraźnia nowych rozwiązań, a dyskusja powinna dotyczyć między innymi:

- Zunifikowanego podejścia do wdrożenia zmodyfikowanych, niskoemisyjnych paliw;
- Standaryzacji w obszarze baterii stosowanych przez wojska;
- Zastosowania nowych napędów w postaci hybryd lub ogniwo-paliwowych w platformach bojowych;
- Zastosowania inteligentnych systemów zarządzania efektywnością energetyczną, mikrosieci, odnawialnych źródeł energii do zasilania baz polowych (rozwiązania mobilne) oraz militarnej infrastruktury stacjonarnej;
- Potencjalnego zastosowania małych, w tym mobilnych reaktorów atomowych;
- Wykorzystania nowoczesnych metod magazynowania energii;
- Gromadzenia krytycznych zapasów i rozbudowy systemów ich dystrybucji (paliwa, minerały ziem rzadkich).

Należy zwrócić uwagę na kontekst uzależnienia Sojuszu od surowców stanowiących bazę dla transformacji energetycznej, a zwłaszcza na minerały ziem rzadkich, które stanowią podstawę budowy baterii, ogniwo-paliwowych oraz wielu typów odnawialnych źródeł energii. Podobnie jak w przypadku gazu, czy ropy naftowej główne złoża tych surowców należą do Rosji i Chin, a Europa bazuje niemal w całości na ich imporcie z zagranicy. Rysunek 1 poniżej ilustruje zasoby i możliwości produkcyjne metali ziem rzadkich na świecie<sup>7</sup>.

---

<sup>6</sup> NATO 2030: *Unitet for a New Era, Analysis and Recommendations of the Reflection Group Appointed by the NATO Secretary General, 25 November 2020;*  
[https://www.nato.int/nato\\_static\\_fl2014/assets/pdf/2020/12/pdf/201201-Reflection-Group-Final-Report-Uni.pdf](https://www.nato.int/nato_static_fl2014/assets/pdf/2020/12/pdf/201201-Reflection-Group-Final-Report-Uni.pdf)

<sup>7</sup> *Metale ziem rzadkich. Te państwa mają największe złoża na świecie.*  
<https://forsal.pl/biznes/przemysl/artykuly/8637418,metale-ziem-rzadkich-najwieksze-zloza-na-swiecie.html>

Jak widać największe zasoby posiadają Chiny, Wietnam, Brazylia i Rosja. Ale jeśli chodzi o wydobycie absolutnym liderem są Chiny z 61% udziału, a na drugim miejscu są USA z 15.5%. Kluczowe zatem stają się badania idące w kierunku minimalizacji ryzyka związanego z kolejnym uzależnieniem, ukierunkowane na opracowanie technologii opartych na minerałach o powszechnej dostępności.

Z całą pewnością energia i bezpieczeństwo energetyczne w ujęciu militarnym nie w pełni odnoszą się do konwencjonalnych paradygmatów opartych na bezpieczeństwie ekonomicznym i społecznej harmonii, a koncentrują się na realizacji powierzonej misji i osiągnięciu celów strategicznych.



Rys. 1. Produkcja oraz zasoby metali ziem rzadkich na świecie<sup>6</sup>

### 3. PRAKTYCZNE PRZYKŁADY TRANSFORMACJI ENERGETYCZNEJ W OBSZARZE PLATFORM BOJOWYCH NATO

Bezpieczeństwo energetyczne w rozumieniu wojskowym koncentruje się na zasilaniu wysoce wydajnych systemów walki, infrastruktury telekomunikacyjnej na której bazuje system dowodzenia, na poziomie gwarantującym zachowanie parametrów bojowych, zasięgu i gotowości do użycia. Ze względu na podatność łańcuchów dostaw na ataki i ograniczenia w dostawach na przedni skraj, obejmuje również potrzebę minimalizacji zapotrzebowania na energię przez platformy bojowe operujące na wysuniętych pozycjach. W wielu z państw NATO, niezależnie od regulacji europejskich, czy sojuszniczych od lat prowadzone są prace nad trans-


formacją energetyczną sił zbrojnych. Absolutnym liderem w tym obszarze są Stany Zjednoczone i Wielka Brytania. Historycznie związane to jest ze sposobem prowadzenia operacji wojskowych przez te państwa, z reguły na dużych odległościach, w różnych częściach świata, często w środowisku o słabej lub nieistniejącej infrastrukturze sprzyjającej zasilaniu wojsk z wykorzystaniem lokalnych zasobów. Nie bez znaczenia jest systematyczny wzrost zapotrzebowania na energię w miarę unowocześniania sił zbrojnych.

Siły Zbrojne USA podczas operacji w Iraku (wojna w Zatoce Perskiej 1990–91) zużywała dziennie 4 galony paliwa na żołnierza. W 2006 roku podczas operacji w Iraku i Afganistanie było to już 16 galonów. W 2012 r. oparcia ISAF w Afganistanie, w której brało udział ponad 100tys. wojsk NATO zużywano 6.8 mln. litrów paliwa dziennie, które sprowadzane było ciężarówkami zza granicy. Ważne jest również zachowanie odpowiednich proporcji między wielkością „ogona logistycznego”, a zasilanymi wojskami. Według danych armii USA w Afganistanie na każde 24 konwoje paliwa i 29 konwojów wody ginął 1 żołnierz lub cywil realizujący zadanie<sup>8</sup>. Pamiętajmy, że nie mówimy o konflikcie pełnoskalowym. Gdyby odnieść te dane np. do konfliktu w Ukrainie, gdzie linie zaopatrzenia są najbardziej lukratywnymi celami artylerii, lotnictwa, czy też ataków dronami, liczba ofiar oraz strat w środkach zaopatrzenia niezbędnych do zasilania wojsk walczących w porównaniu z tymi danymi byłaby ogromna. Na rysunku poniżej przedstawiono jak zmieniał się zapotrzebowanie w ramach kolejnych konfliktów zbrojnych w relacji do wielkości użytych wojsk<sup>9</sup>.

---

<sup>8</sup> Constatntine samaras, William J. Nuttall, Morgan Bazilian, *Energy and the military: converge of security, economic, and environmental decision making. Energy Strategy Reviews, Volume 26, November 2019, 1000409*

<sup>9</sup> R. Kidd, U.S. Army, 2012, "Army Energy and Sustainability Program," presentation, <https://www.asaie.army.mil/Public/ES/doc/2-General%20Presentation.pdf>.



Rys. 2. Historyczne trendy zmian w zużyciu paliwa i wielkości użytych sił<sup>8</sup>

Biorąc powyższe pod uwagę, działania zmierzające do ograniczenia zapotrzebowania na energię oraz poprawy autonomiczności działań bojowych kreują dodatkowy bodziec do poszukiwania rozwiązań opartych na poprawie efektywności energetycznej sprzętu oraz instalacji wojskowych, dywersyfikacji źródeł zasilania, w tym stosowania nowych technologii w napędach platform bojowych.

W siłach zbrojnych USA rozgraniczono kwestie zasilania energetycznego obiektów wojskowych od energii operacyjnej wykorzystywanej do zasilania platform bojowych i systemów wsparcia wykorzystywanych na polu walki przez wszystkie rodzaje sił zbrojnych. O programach związanych z poprawą efektywności energetycznej baz wojskowych, związanych z tym programów NATO oraz USA pisałem w moim opracowaniu na zatyłowanym „Znaczenie surowców energetycznych i źródeł energii w siłach zbrojnych”.

Już od 2011 roku prowadzone są prace planistyczne i wdrożeniowe. Opierają się one dwa zasadnicze dokumenty. Pierwszy to dokument o charakterze strategicznym zatyłowany „Operational Energy Strategy: Energy for Warfighter”<sup>10</sup> a drugi to opracowany w 2012 roku dokument o charakterze wdrożeniowym „Operational Energy Strategy: Implementation Plan”<sup>11</sup>. Dokumenty te koncentrują się na realizacji trzech zasadniczych celów:


<sup>10</sup> S. Burke, *Energy for the Warfighter: the DoD Operational Energy Strategy*, Assistant Secretary of Defense, Operational Energy Plans and Programs, U.S. Department of Defense (2011)  
<http://www.dtic.mil/dtic/tr/fulltext/u2/a556514.pdf>

<sup>11</sup> S. Burke, *Operational Energy Strategy: Implementation Plan*, Assistant Secretary of Defense, Operational Energy Plans and Programs, U.S. Department of Defense (2012)  
[https://www.acq.osd.mil/eie/Downloads/OE/20120306\\_OE\\_Strategy\\_Implementation\\_Plan.pdf](https://www.acq.osd.mil/eie/Downloads/OE/20120306_OE_Strategy_Implementation_Plan.pdf)

- dłuższa walka przy mniejszym zużyciu paliwa;
- więcej opcji, mniej ryzyka;
- więcej zdolności przy mniejszych kosztach.

O ile kierunki i terminy realizacji tych przedsięwzięć zostały określone, to zdania co do sposobu ich realizacji są podzielone. Po pierwsze obawy dotyczą zachowania równowagi pomiędzy efektywnością bojową wojsk, a budową rozwiązań przyjaznych dla środowiska. Wprowadzane rozwiązania nie mogą obniżyć w żaden sposób zdolności bojowych. Po drugie wyzwaniem jest budowa jak najbardziej efektywnego i zintegrowanego łańcucha dostaw dla wojsk. Póki co koncepcja pojedynczego paliwa na polu walki (single fuel concept), którą przyjęto w NATO w roku 1978, bazująca na paliwie lotniczym JP8 (F-34 w nomenklaturze NATO) stosowanym w pojazdach wojsk lądowych, generatorach, czy turbinach statków powietrznych wydaje się najlepszym rozwiązaniem. Wprowadzanie do łańcuchów dostaw innych źródeł energii musi być poddane szczegółowej analizie.

Doskonale ilustruje to grafika na rysunku 3 poniżej, przedstawiająca porównanie gęstości poszczególnych paliw w odniesieniu do paliwa lotniczego JP8, która jest kluczowym zagadnieniem poddawanych analizom przy formułowaniu kierunków potencjalnych zmian. Grafika przedstawia gęstość energii pozyskiwanej w funkcji objętości i wagi w stosunku do paliwa JP8 zaindeksowanego do wartości odniesienia 1.<sup>12</sup> Analiza wyraźnie wskazuje że gęstość energii oferowana przez JP8 lub olej napędowy przewyższa inne źródła, co przelicza się na liczbę pojazdów w konwojach dostarczających paliwo do walczących jednostek wojskowych.



<sup>12</sup> U.S. Energy Information Administration, 2013, "Few Transportation Fuels Surpass the Energy Densities of Gasoline and Diesel," <https://www.eia.gov/todayinenergy/detail.php?id=9991>.

Niezależnie od tych parametrów w analizach brane są pod uwagę właściwości paliw w zmiennej temperaturze, łatwopalność - co ma ogromne znaczenie dla bezpieczeństwa załóg platform bojowych - warunki techniczne przechowywania, transportu i dystrybucji.

Analizy przeprowadzone przez wojska lądowe USA wskazują, że typowy Brygadowy Pancerny Zespół Bojowy (ABCT)<sup>13</sup> będzie zużywał 18,8 tys. MWh energii podczas 12 dniowej misji. Oznacza to 1600 MWh dziennie z przeciętną mocą zasilania 65MW<sup>14</sup>. Zapotrzebowanie to będzie rosło wraz z rozbudową systemów dowodzenia, wykorzystaniem sztucznej inteligencji, poszerzaniem świadomości sytuacyjnej na polu walki, zwiększaniem manewrowości, siły ognia, w tym wykorzystania energii kierowanej do obezwładniania w ramach walki elektronicznej, czy niszczenia celów. Wyposażenie żołnierzy Brygadowych Zespołów Zadaniowych Piechoty (IBCT)<sup>15</sup> w inteligentne gogle powoduje, że każdy z nich będzie zużywał w ciągu doby trzy baterie przenośne, a 40-to osobowy pluton będzie zużywał 120 baterii na dobę. Oczywiście to wyliczenie nie obejmuje baterii niezbędnych do zasilania przenośnych środków łączności, czy dronów. Całe IBCT może teoretycznie zużyć w ciągu doby 8000 tego typu baterii, a do zapewnienia ciągłości działań niezbędne będzie dysponowanie co najmniej 16 tys. baterii (połowa w ładowaniu). Grupa 10 żołnierzy do ładowania swoich przenośnych baterii potrzebuje 4,5 kWh dziennie<sup>16</sup>. Te kalkulacje wyraźnie wskazują na rosnące wyzwania.

Strategia Klimatyczna Wojsk USA zakłada rozwiązanie pośrednie polegające na wdrożeniu pojazdów ogólnego przeznaczenia (auta osobowe i pojazdy transportowe o napędzie hybrydowym i elektrycznym oraz hybrydowym dla pojazdów taktycznych (bojowych) do roku 2035 oraz w pełni elektrycznych pojazdów taktycznych do roku 2050. Pojazdach taktycznych wdrażany jest układ hybrydowy, który pozwala zasilać urządzenia pokładowe wozów bojowych podczas postoju, przy wyłączonym silniku<sup>17</sup>. Przy obecnie dostępnej gęstości baterii ocenia się, że pojazdy taktyczne w zależności od masy mogą pokonywać od 3 do 10 mil bez załączonego silnika spalinowego, zachowując wszystkie cechy w pełni elektrycznych pojazdów. Stopniowe zwiększanie możliwości baterii pozwoli nawet na zasilanie lokalnej mikrosieci przy użyciu pojazdów z takim napędem, zasilanie systemów walki, czy też ładowanie ogniw będących w indywidualnym wyposażeniu żołnierzy. Oczywiście w analizach brane są również zalety napędu elektrycznego zastosowanego w pojazdach taktycznych. Silnik elektryczny wydatnie zwiększa manew-

---

<sup>13</sup> ABCT- Armoured Brigade Combat Team

<sup>14</sup> *Powering the U.S. Army of the future (2021), A Consensus Study Report of the National Academies of Sciences, Engineering, Medicine; The National Academies Press; Washington DC; <http://nap.nationalacademies.org/26052>*

<sup>15</sup> IBCT- Infantry Brigade Combat Team

<sup>16</sup> *Plasan North America, Dod's push to electrify the battlefield is creating electricity demand problem sit is not solving; <https://breakingdefense.com/2022/08/dods-push-to-electrify-the-battlefield-is-creating-electricity-demand-problems-it-is-not-solving/>*

<sup>17</sup> *R. Maze, AUSA; Power Hungry: Feeding growing requirements for energy on the battlefield; 31 maj 2022; <https://www.ansa.org/articles/power-hungry-feeding-growing-requirements-energy-battlefield>*

rowość, nie generuje hałasu, emisji ciepłej ani dymu, co ogranicza jego wykrycie i zwiększa zdolność do przetrwania na polu walki. Przykładem aktualnie projektowanych rozwiązań w tym obszarze jest Amerykańsko-Japoński projekt hybrydowego wozu bojowego Stryker.

Bada się również możliwość wykorzystania wodorowych ogniw paliwowych. Wojska lądowe USA rozpoczęły eksperyment z zastosowaniem wodorowych ogniw paliwowych dla pojazdów ciężarowych. Skonstruowano eksperymentalny pojazd Chevrolet Colorado ZH2 z takim napędem. Również siły powietrzne USA w bazie na Hawajach wykorzystują pierwsze pojazdy o takim napędzie<sup>18</sup>.

Przetoczone wyżej analizy wskazują, że USA nie są gotowe na wprowadzenie w pełni elektrycznych napędów dla pojazdów taktycznych, zwłaszcza tych ciężkich. Obecnie w armii USA nie występują taktyczne pojazdy o napędzie elektrycznym, chociaż determinacja związana z osiągnięciem zakładanych celów jest ogromna. Nakłady na ten cel rosną z roku na rok. W roku fiskalnym 2022 w budżecie wojsk lądowych USA wydano na ten cel 47,8 mln. USD, ale kwota ta urosła do 78,4 mln. USD w roku 2023. W roku 2024 przeznaczono na ten cel już 270,6 mln. USD<sup>19</sup>. Dostępna technologia na razie nie pozwala budować wystarczająco lekkich baterii o oczekiwanej wydajności. Naładowanie baterii dla 50-tonowego czołgu wymagałoby 15 minut, a zespół bojowy z 30 pojazdami wymagałby ponad siedmiu godzin na ładowanie ze źródła o mocy 29 MW.

Jedynym rozwiązaniem w tym przypadku byłoby zastosowanie mobilnego reaktora nuklearnego, ale według raportu ekspertów amerykańskich takie urządzenie ważyłoby około 40 ton, zamontowane musiałyby być w dwóch 20-stopowych kontenerach klasy ISO, potrzebowałoby trzech dni na rozruch i dwa dni na schłodzenie po użyciu. Takie parametry są sprzeczne z doktryną użycia wojsk w operacjach wielodomenowych. Co prawda trwają prace nad budową ekspedycyjnego reaktora, ale do 2035 roku nie osiągnie on parametrów umożliwiających ładowanie ciężkiego sprzętu o napędzie elektrycznym<sup>20</sup>.

Analizy wykazują, że w warunkach polowych na szczeblu taktycznym, wykorzystanie energii z wiatru, hydroenergii, paneli słonecznych o dużej skali, czy przetwarzania odpadów nie będzie miało praktycznego zastosowania. W tym obszarze uwaga koncentruje się na odpowiedniej aplikacji cywilnych rozwiązań, głównie w celu ładowania baterii do zasilania wyposażenia indywidualnego żołnierzy, zasilania laptopów, czy też radiostacji przenośnych. A potrzeby rosną. Przejście na wyższe pasmo 5G wymaga w systemach telekomunikacji mobilnej większej energii niż pasmo 4G aby uzyskać ten sam zasięg łączności. Dramatycznie wzrasta

---

<sup>18</sup> E. Newton,; *How does the U.S. Military Rely on Renewable Energy?* 22 February 2023; <https://www.renewableenergymagazine.com/emily-newton/how-does-the-u-s-military-rely-20230222>

<sup>19</sup> S. Lee, D. Moore; *US Army's Electric Tanks on Hold as Battery Technology Develops*; 20 June 2023; <https://news.bloomberglaw.com/environment-and-energy/us-armys-electric-tanks-on-hold-as-battery-technology-develops>

<sup>20</sup> *Powering the U.S. Army of the future (2021), A Consensus Study Report of the National Academies of Sciences, Engineering, Medicine; The National Academies Press; Washington DC; http://nap.nationalacademies.org/26052*

zapotrzebowanie na energię przy wdrażaniu platform bojowych opartych o energię kierowaną. Walka w domenie cyber również schodzi na poziom taktyczny. Cała gama bezzałogowych pojazdów, statków powietrznych wymaga dodatkowego zasilania.

Zastosowanie zaawansowanych systemów łączności oraz budujących świadomość sytuacyjną zintegrowanych w indywidualnym wyposażeniu żołnierza przyrządów obserwacyjnych, oprócz wyzwań związanych z samym zasilaniem, tworzy dylemat masy ładunku jakim jest on obciążony. Baterie należą do najcięższych elementów wyposażenia, stąd poszukiwanie rozwiązań generujących energię z innych źródeł. Opracowywane są zastosowania pokryw fotowoltaicznych na elementach wyposażenia żołnierza (plecaki, koce), ale prace koncentrują się również na zastosowaniu nanotechnologicznych rozwiązań w obszarze termofotowoltaiki. Materiał nanofotoniczny (unikalny kryształ fotoniczny umożliwiający kontrolę widma emitowanego promieniowania) jest zaprojektowany tak, aby emitował określone preferowane długości fal światła po podgrzaniu na ciele żołnierza. Światło to, jest wychwytywane przez specjalne, zoptymalizowane ogniwo fotowoltaiczne wytwarzające energię<sup>19</sup>.

Armia Brytyjska również zakłada ambitne cele związane z ograniczeniem szkodliwych emisji. Brytyjczycy zakładają jednak, że co najmniej do 2040 roku nie da się wyeliminować silników spalinowych. Trzeba jednak pamiętać, że wojska lądowe nie są największym rodzajem sił zbrojnych, a wyspiarskie położenie powoduje, że armia brytyjska wyposażona jest głównie w lekkie platformy bojowe, przystosowane do działań ekspedycyjnych. Biorąc pod uwagę założenie, że do roku 2030 2/3 nowych pojazdów nabywanych w kraju będzie miało napęd elektryczny, trudno będzie zatrzymać zmiany w siłach zbrojnych. Niemniej jednak przyjmuje się, że elektryfikacja ciężkich platform bojowych do roku 2040 będzie trudna bez dokonania przełomu w produkcji nowych typów baterii. Dlatego na tym etapie również stawia się na technologie hybrydowe. Oprócz zalet zidentyfikowanych przez Amerykanów, Brytyjczycy uważają, że zastosowanie napędu elektrycznego znacznie uprości logistykę, poprawi autonomię działań, poprawi niezawodność pojazdów taktycznych (mniej ruchomych części), zredukuje potrzeby w zakresie systemów eksploatacji, ograniczy ilość części w systemach zaopatrzenia. Formacje będą mogły wykonywać zadania dłużej, w większym tempie, mniej zależąc od łańcuchów logistycznych. Nowe napędy dają możliwość zabudowy pojazdów w nowej architekturze.

Strategia brytyjska zakłada, że do 2025 r. zakończone zostaną testy lekkich pojazdów o napędzie hybrydowym, do 2030 r. poddziały wyposażone w tego typu pojazdy przejdą właściwe szkolenie i będą użyte w operacjach, a do 2035 roku większość z sił lądowych będzie wyposażona w pojazdy hybrydowe lub elektrycz-

ne. Na testy prototypowych pojazdów MAN SV, Jackal i Foxhound wydano 10 mln funtów.<sup>21</sup>

Francja również planuje wdrożenie do swoich sił zbrojnych pojazdów o napędzie hybrydowym do roku 2025, a wspólny francusko-niemiecki program budowy nowego czołgu znany jako Main Ground Combat System, może również uwzględnić zaprojektowanie napędu hybrydowego<sup>22</sup>. W kwietniu bieżącego roku Ministerstwo Obrony Francji zatwierdziło pierwszą strategię obrony związaną ze zmianami klimatycznymi. W projekty tego typu zaangażowanych jest szereg producentów z Francji, Niemiec i Włoch. Takich programów nie realizuje się w Polsce.

#### 4. WNIOSKI

Wprowadzane regulacje w obszarze Unii Europejskiej oraz NATO w sposób bezpośredni będą oddziaływały na kształtowanie przyszłych rozwiązań technologicznych związanych zarówno z flotą pojazdów ogólnego przeznaczenia wykorzystywanych do zabezpieczenia funkcjonowania wojsk, jak i pojazdów taktycznych. Biorąc pod uwagę aktualny stan rozwoju systemów napędowych opartych o rozwiązania inne niż silniki spalinowe oraz wyzwania i ograniczenia związane z zastosowaniem napędu elektrycznego, nie wydaje się aby w perspektywie objętej powszechnymi regulacjami udało się dokonać transformacji w siłach zbrojnych. Trzeba pamiętać, że nie może ona pogorszyć zdolności wojsk w obszarze zabezpieczenia ciągłości działań, ani ograniczać parametrów bojowych pojazdów taktycznych. Mimo, że nowe rozwiązania mogą przynieść wiele korzyści, to aktualny stan rozwoju technologii (zwłaszcza gęstość energii dostępnych baterii) nie pozwala na ich efektywne wykorzystanie. Oceniając aktualny stan prac i zainteresowanie sił zbrojnych poszczególnych państw w obszarze elektryfikacji pojazdów należy stwierdzić, że nie będzie to proces równoległy, a więc może potencjalnie wpłynąć na brak interoperacyjności wojsk i łańcuchów dostaw w ramach działań prowadzonych wspólnie. Największe szanse powodzenia dotyczą zastosowania rozwiązań hybrydowych.

Wojna w Ukrainie spowodowała przyspieszenie modernizacji sił zbrojnych w wielu państwach. Szczególnie jest to widoczne w Polsce. Podpisywane kontrakty obejmują dostawy sprzętu wykonanej w tradycyjnej konfiguracji napędu. Będą one realizowane w perspektywie kilku następnych lat, a ich eksploatacja będzie obliczona tradycyjnie co najmniej na 30 lat. Oznacza to, że w wielu państwach ( w tym zwłaszcza w Polsce) perspektywa przejścia na napędy elektryczne do roku 2050

---

<sup>21</sup> *British Army; British Army Approach to Battlefield Electrification;*  
<https://www.army.mod.uk/media/17010/british-army-approach-to-battlefield-electrification.pdf>

<sup>22</sup> *Vivieni Machi, Vehicle makers court Europe's militaries with hybrid, electric rides;*  
<https://www.defensenews.com/global/europe/2022/06/25/vehicle-makers-court-europes-militaries-with-hybrid-electric-rides/>

jest praktycznie wykluczona. Łańcuchy dostaw dalej będą funkcjonowały w oparciu o paliwa, zgodnie z obowiązującą koncepcją NATO.

Prawdopodobnie będą konieczne modyfikacje przepisów europejskich w kierunku zawarcia w nich wyłączeń dla sił zbrojnych w kontekście terminu zakończenia transformacji.

## LITERATURA

1. British Army; British Army Approach to Battlefield Electrification; <https://www.army.mod.uk/media/17010/british-army-approach-to-battlefield-electrification.pdf>
2. Constantine Samaras, William J. Nuttall, Morgan Bazilian, Energy and the military: converge of security, economic, and environmental decision making. Energy Strategy Reviews, Volume 26, November 2019,
3. E. Newton,; How does the U.S. Military Rely on Renewable Energy? 22 February 2023; <https://www.renewableenergymagazine.com/emily-newton/how-does-the-u-s-military-rely-20230222>
4. Komisja Europejska, Energia Zielony Ład; [https://commission.europa.eu/strategy-and-policy/priorities-2019-2024/european-green-deal/energy-and-green-deal\\_pl](https://commission.europa.eu/strategy-and-policy/priorities-2019-2024/european-green-deal/energy-and-green-deal_pl)
5. Komisja Europejska, Transport a Zielony Ład; [https://commission.europa.eu/strategy-and-policy/priorities-2019-2024/european-green-deal/transport-and-green-deal\\_pl](https://commission.europa.eu/strategy-and-policy/priorities-2019-2024/european-green-deal/transport-and-green-deal_pl)
6. Metale ziem rzadkich. Te państwa mają największe złoża na świecie. <https://forsal.pl/biznes/przemysl/artykuly/8637418,metale-ziem-rzadkich-najwieksze-zloza-na-swiecie.html>
7. NATO 2030: United for a New Era, Analysis and Recommendations of the Reflection Group Appointed by the NATO Secretary General, 25 November 2020; [https://www.nato.int/nato\\_static\\_fl2014/assets/pdf/2020/12/pdf/201201-Reflection-Group-Final-Report-Uni.pdf](https://www.nato.int/nato_static_fl2014/assets/pdf/2020/12/pdf/201201-Reflection-Group-Final-Report-Uni.pdf)
8. Parlament Europejski; Fit for 55:deal on new EU rules for cleaner maritime fuels; <https://www.europarl.europa.eu/news/pl/press-room/20230320IPR77909/fit-for-55-deal-on-new-eu-rules-for-cleaner-maritime-fuels>
9. Plasan North America, Dod's push to electrify the battlefield is creating electricity demand problem sit is not solving; <https://breakingdefense.com/2022/08/dods-push-to-electrify-the-battlefield-is-creating-electricity-demand-problems-it-is-not-solving/>
10. Powering the U.S.Army of the future (2021), A Consensus Study Report of the National Academies of Sciences, Engineering, Medicine; The National Academies Press; Washington DC; <http://nap.nationalacademies.org/26052>
11. R. Kidd, U.S. Army, 2012, "Army Energy and Sustainability Program," presentation, <https://www.asaie.army.mil/Public/ES/doc/2-General%20Presentation.pdf>
12. R. Maze, AUSA; Power Hungry: Feeding growing requirements for energy on the battlefield; 31 May 2022; <https://www.ausa.org/articles/power-hungry-feeding-growing-requirements-energy-battlefield>

13. S. Burke, Energy for the Warfighter: the DoD Operational Energy Strategy, Assistant Secretary of Defense, Operational Energy Plans and Programs, U.S. Department of Defense (2011)
14. S. Burke, Operational Energy Strategy: Implementation Plan, Assistant Secretary of Defense, Operational Energy Plans and Programs, U.S. Department of Defense (2012); [https://www.acq.osd.mil/eie/Downloads/OE/20120306\\_OE\\_Strategy\\_Implementation\\_Plan.pdf](https://www.acq.osd.mil/eie/Downloads/OE/20120306_OE_Strategy_Implementation_Plan.pdf)
15. U.S. Energy Information Administration, 2013, "Few Transportation Fuels Surpass the Energy Densities of Gasoline and Diesel," <https://www.eia.gov/todayinenergy/detail.php?id=9991>
16. S. Lee, D. Moore; US Army's Electric Tanks on Hold as Battery Technology Develops; 20 June 2023; <https://news.bloomberglaw.com/environment-and-energy/us-armys-electric-tanks-on-hold-as-battery-technology-develops>
17. Vivienne Machi, Vehicle makers court Europe's militaries with hybrid, electric rides; <https://www.defensenews.com/global/europe/2022/06/25/vehicle-makers-court-europes-militaries-with-hybrid-electric-rides/>

## **ENERGY TRANSFORMATION – CHALLENGES TO ARMED FORCES**

### **Abstract**

Majority of NATO nations belongs to European Union but some of them (including the key ally – United States) is located out of Europe. All of the nations do perform the energy transformation which is a consequence of challenges coming from climate protection, dependence on foreign energy resources and new technology development. Speed and way of implementation depends on both EU and national regulations. Way of implementation and legal framework varies and have differential influence on how do they impact the armed forces development. It has direct influence on defense policy of each state and constitutes risks associated with potential different approach to the implementation of new solutions into specific armed forces.

Obviously both the US and UK strongly emphasize these topics at the development strategy. They have a very concrete plans for implementation. Some other nations have just started processes, but many have not taken into account any of these challenges in their defense policy. Tests, analyses and some completed implementations indicate many of limitations and challenges to electrification of combat platforms putting more effort on hybrid solutions. At the same time appetite for energy within armed forces is still growing. For the time being jet fuel JP8 (or F-34 I NATO standard) or diesel have the best energy density parameters and are the most suitable to provide effective military supply chain.

All available data shows that theta we cannot expect any significant breakthrough in terms of introduction to the armed forces fully electric tactical vehicles before 2040.

**Keywords:** energy transformation, hybrid drive, electric engine, energy resources, energy density

**PUBLIKACJA [5]**

- [5]. Kępczyński A., Stępień S., *Optymalizacja i wspomaganie AI w logistyce wojskowej*, rozdział w monografii *Perspektywy logistyki wojskowej i cywilnej w kontekście zapewnienia odporności Siłom Zbrojnym* (konferencja Bydgoszcz), Warszawa: Wydawnictwo ITWL 2024, Tom 1.

Artur KĘPCZYŃSKI\*  
Sławomir STEPIEŃ\*\*

## **OPTIMALIZACJA I WSPOMAGANIE AI W LOGISTYCE WOJSKOWEJ**

W pracy opisano modele logistyczne stosowane w szeroko pojętej wojskowej logistyce operacyjnej. Rozpatrzono modele statyczne oraz dynamiczne z ograniczeniami. Dodatkowo zdefiniowano ogólne funkcje celu. Wskazano też metody rozwiązania problemów logistycznych poprzez zastosowanie metod programowania liniowego, jak również metod programowania dynamicznego. Omówiono też optymalizację z wykorzystaniem sztucznej inteligencji oraz optymalizację procesów logistycznych wykorzystującą sztuczną inteligencję. Pracę wzbogacono przykładami z zakresu optymalizacji dostaw energii w postaci paliwa.

Słowa kluczowe: logistyka wojskowa, programowanie liniowe i nieliniowe, programowanie dynamiczne, optymalizacja procesów logistycznych

### **1. WPROWADZENIE**

Logistyka wojskowa jest wielowymiarowym i złożonym zagadnieniem, który stanowi jeden z głównych czynników wpływających na przebieg działań wojennych. Jednakże, podobnie jak w przypadku innych złożonych terminów, takich jak ekonomia, strategia czy polityka, termin logistyka jest trudny do zdefiniowania w kilku słowach. W najbardziej ogólnym ujęciu, logistykę można postrzegać jako złożoną mieszankę fizycznych bytów, procesów i reguł – czyli jako system – twór rządzący się głównie abstrakcyjnymi pojęciami i zasadami. Pojęcie logistyki w rozumieniu wojskowym zostało przedstawione w doktrynie logistycznej DD 4(B ) jako dziedzinę obejmującą planowanie, przygotowanie oraz użycie środków zaopatrzenia, a także realizację świadczeń oraz usług specjalistycznych w celu utrzymania wojsk w odpowiedniej gotowości bojowej.

---

\* Inspektorat Wsparcia Sił Zbrojnych.

\*\* Wydział Automatyki, Robotyki i Elektrotechniki, Politechnika Poznańska.

Historia współczesnych konfliktów zbrojnych wskazuje, że potrzeby wojsk operacyjnych w zakresie zabezpieczenia logistycznego często przewyższają ograniczone możliwości potencjału logistycznego sił zbrojnych. Skoordynowane planowanie logistyczne jest zatem istotnym aspektem efektywnego i oszczędnego wykorzystania zasobów [1-3]. W związku z tym optymalizacja procesów zarządzania logistyką wojskową staje się kluczowa w osiągnięciu celów militarnych.

Podczas Międzynarodowego Salonu Przemysłu Obronnego odbywającego się w 2023 w Kielcach, z inicjatywy Biura Bezpieczeństwa Narodowego (BBN) przeprowadzono debatę strategiczną poświęconą zagadnieniom logistycznym przyszłego pola walki. W jej trakcie szef BBN Minister Jacek Siewiera powiedział: „Logistyka jest krwioobiegami naszej armii. To ona wygrywa wojnę, ale wiele osób nie zdaje sobie z tego sprawy. Przy dysproporcji sił właśnie ona pozwala zyskać przewagę nad przeciwnikiem”, co można ująć innymi słowami, że bez sprawnie działającego systemu logistycznego, jakakolwiek przewaga nad przeciwnikiem, może być trudna do osiągnięcia [5].

Jak pokazują ostatnie doświadczenia z przebiegu operacji wojskowych, dziś nie wystarczy określić jednorazowo optymalnego zapotrzebowania, przepływu zaopatrzenia czy usług logistycznych, wszystko musi działać się w sposób ciągły z uwzględnieniem procesów przejściowych, również przy wykorzystaniu najnowszych osiągnięć techniki i metod zarządzania czy dowodzenia, włączając sztuczną inteligencję i metody maszynowe uczenia [4].

Przedmiotem pracy jest pokazanie logistycznych modeli procesów decyzyjnych mających zastosowanie w szeroko pojętej logistyce wojskowej, ich opis oraz zdefiniowanie rozwiązania problemów logistycznych statycznych jak i dynamicznych dyskretnych. Pokazano również możliwości rozwiązania przy wykorzystaniu prostych przykładów. W artykule wskazano ponadto możliwości wykorzystania w procesach optymalizacyjnych sztucznej inteligencji opartej na sieciach neuronowych. Wykorzystując te same przykłady zagadnienie optymalizacji rozwiązano przy użyciu sztucznych sieci neuronowych, badając wpływ na prawidłowe działanie tego rozwiązania doboru struktury i rozmiaru sieci oraz systemu uczenia.

## **2. MODELE I OPTYMALIZACJA**

### **2.1. Modele logistyczne**

W zakresie modelowania procesów logistycznych na poziomie strategicznym, należy zawsze zdefiniować miary efektywności kosztowej, obliczyć kompromisy między alternatywnymi pakietami zasobów logistycznych, zoptymalizować alokację zasobów i efektywnie wdrażać przyjęte harmonogramy logistyczne. Na poziomie

operacyjnym i taktycznym procesy logistyczne dotyczą głównie planowania i realizacji przemieszczania zasobów, ich alokacji, monitorowania i prognozowania zużycia oraz ustalania lokalnych harmonogramów dotyczących zabezpieczenia logistycznego wojsk w przydzielonych operacyjnych obszarach odpowiedzialności [2].

Wszystkie te zadania wymagają narzędzi do analizy i wspomagania decyzji. Poniżej przedstawiamy wybrane metody, modele i techniki badań operacyjnych, które są wykorzystywane jako narzędzia analizy logistycznej i wspomagania decyzji. Narzędzia te niekoniecznie są unikalne dla logistyki wojskowej [3]. Większość z nich ma szerokie zastosowanie również w logistyce biznesowej, w szczególności jako pomoce decyzyjne w celu maksymalizacji zysku.

Ogólnie modele logistyczne możemy podzielić na modele statyczne i dynamiczne. W obu przypadkach definiuje się funkcję celu oraz ograniczenia. Model dynamiczny jest o tyle uniwersalny, iż pozwala uwzględniać zmiany ograniczeń jak również funkcji celu w czasie ciągłym lub dyskretnym [4].

W przypadku modeli statycznych, funkcja celu może w ogólności mieć charakter nieliniowy

$$J = f(\mathbf{X}), \quad (1)$$

względem wektora zmiennych decyzyjnych  $\mathbf{X} = [X_1 \dots X_n]^T$ , natomiast ograniczenia również mogą przyjmować nieliniowe zależności względem zmiennych decyzyjnych

$$g(\mathbf{X}) \leq \mathbf{b}, \quad (2)$$

gdzie

$$\mathbf{X} \geq \mathbf{0}. \quad (3)$$

W szczególnym przypadku, funkcje celu jak również ograniczenia mogą przyjmować zależności liniowe. Wówczas model przybiera prostszą formę

$$J = \mathbf{C}^T \mathbf{X}, \quad (4)$$

$$\mathbf{A} \mathbf{X} \leq \mathbf{b}, \quad (5)$$

$$\mathbf{X} \geq \mathbf{0}, \quad (6)$$

gdzie  $\mathbf{A}$  jest macierzą współczynników funkcji ograniczeń, a  $\mathbf{C}$  wektorem współczynników funkcji celu.

W przypadku modeli dynamicznych dyskretnych [6], funkcja celu może w ogólności mieć charakter sumy

$$J = \sum_{k=0}^{N-1} f(\mathbf{X}(k)) + S(\mathbf{X}(N)), \quad (7)$$

gdzie  $N$  oznacza tzw. horyzont czasowy, a  $S(\mathbf{X}(N))$  jest resztą dla czasu końcowego. Wówczas ograniczenia mogą przyjmować nieliniowe zależności względem zmiennych decyzyjnych jak również dynamicznie zmieniać się w czasie dyskretnym

$$\mathbf{X}(k+1) = g(\mathbf{X}(k)), \quad (8)$$

dla

$$\mathbf{X}(k) \geq \mathbf{0} \text{ dla } k = 1, \dots, N-1 \quad (9)$$

gdzie  $\mathbf{X}(k+1)$  oznacza zmianę wartości wektora zmiennych decyzyjnych w kroku  $k+1$  względem wartości w kroku  $k$ . Zauważmy, że z ograniczeń możemy odczytać informacje, jak zmienia się wektor decyzyjny i jakie może przyjąć wartości w najbliższym czasie.

## 2.2. Optymalizacja procesów logistycznych

Optymalizacja procesów logistycznych związana jest z poszukiwaniem maksymalnych lub minimalnych wartości funkcji celu przy zadanych ograniczeniach. W przypadku modeli statycznych nieliniowych zagadnienie wyznaczania optymalnych realizacji zadań logistycznych można zdefiniować następująco

$$\max J = \max f(\mathbf{X}), \quad (10)$$

przy ograniczeniach

$$g(\mathbf{X}) \leq \mathbf{b}, \mathbf{X} \geq \mathbf{0}, \quad (11)$$

co można zapisać w sposób zwięzły

$$\max\{f(\mathbf{X}) \mid \mathbf{X} \in \mathbf{R}^n \wedge g(\mathbf{X}) \leq \mathbf{b} \wedge \mathbf{X} \geq \mathbf{0}\}. \quad (12)$$

Dla zagadnień liniowych postać wyrażenia (12) redukuje się do

$$\max\{\mathbf{C}^T \mathbf{X} \mid \mathbf{X} \in \mathbf{R}^n \wedge \mathbf{A}\mathbf{X} \leq \mathbf{b} \wedge \mathbf{X} \geq \mathbf{0}\}. \quad (13)$$

Zagadnienie (12) można rozwiązać stosując metody programowania nieliniowego [4]. W literaturze istnieje wiele propozycji rozwiązań dla zagadnień tego typu, począwszy na metodach mnożników Lagrange'a z warunkami Karusha-Kuhna-Tuckera, aż po iteracyjne metody gradientowe i metody z funkcjami kary.

Z kolei zagadnienia klasy (13) rozwiązywane są metodami programowania liniowego [4]. Tu istnieje wiele propozycji rozwiązań, od tradycyjnych metod typu simplex, aż po metody dualne i niesympleksowe.

Z kolei metody dla modeli dynamicznych z czasem dyskretnym rozwiązuje się metodami programowania dynamicznego. Model (7) – (8) można poddać optymalizacji definiując funkcję

$$V_k(\mathbf{X}(k)) = \min_{\mathbf{X}(k) \dots \mathbf{X}(N-1)} \sum_{k=0}^{N-1} f(\mathbf{X}(k)) + S(\mathbf{X}(N)), \quad (14)$$

przy ograniczeniach

$$\mathbf{X}(k+1) = g(\mathbf{X}(k)). \quad (15)$$

Rozwiązanie zagadnienia polega na poszukaniu sekwencji funkcji  $V_k(\mathbf{X}(k))$ , która minimalizuje (lub maksymalizuje) wartość wskaźnika (7) [6].

### 2.3. Przykłady optymalizacji dostaw paliwa

**Przykład 1:** Dla bazy B istnieje potrzeba dostarczenia jak największej ilości paliwa. Do dyspozycji mamy 20 cystern  $CND\ 27$  (poj. 22 ton) i 12 cystern  $CND\ 33$  (poj. 25 ton). Zatankowanie  $CND\ 27$  trwa 1 godzinę i wymaga obsługi 2 osób, natomiast zatankowanie  $CND\ 33$  trwa 1,5 godziny i wymaga również 2 osób. Z kolei całkowity wysiłek załadowczy nie powinien przekraczać 30 osobogodzin.

Sformułowanie zadania:


Zmienne operacyjne  $X_1$  – liczba  $CND\ 27$ ,  $X_2$  – liczba  $CND\ 33$

Maksymalna ilość paliwa  $F_{max} = 22X_1 + 25X_2$

Ograniczenia  $X_1 \leq 20, X_2 \leq 12, 2X_1 + 3X_2 \leq 60$

Rozwiązując zagadnienie, stosując rachunek Zagadnienia Programowania Linijnego uzyskujemy:  $X_1 = 20, X_2 = 6$ , co daje maksymalną ilość paliwa  $F_{max} = 590\ ton$ .

**Przykład 2:** Dwa oddziały gospodarcze  $D1$  i  $D2$  dostarczają paliwo do odbiorców  $P1$  i  $P2$ . Do  $P1$  dostarcza tylko  $D1$ , a do  $P2$  dostarcza  $D1$  oraz  $D2$ .



Odległości między odbiorcami i oddziałami wynoszą odpowiednio  $d_{11}=50\ km$ ,  $d_{12}=75\ km$  oraz  $d_{22}=100\ km$ . Zapotrzebowania są następujące  $l_1=2000\ ton$ ,  $l_2=1500\ ton$ . W obu magazynach znajdują się zasoby  $s_1=3000\ ton$ ,  $s_2=1000\ ton$ . Niech  $X_{11}$  i  $X_{22}$  ilości ton paliwa pobranych z magazynu, stąd:

$$X_{11} + X_{12} \leq s_1$$

$$X_{22} \leq s_2$$

oraz

$$X_{11} \geq l_1$$

$$X_{12} + X_{22} \geq l_2$$

Przyjmijmy, że każdy samochód przewozi  $c=25$  ton paliwa, to funkcja celu wynosi:

$$\begin{aligned} F_{max} &= \frac{d_{11}}{c} X_{11} + \frac{d_{12}}{c} X_{12} + \frac{d_{22}}{c} X_{22} = \\ &= 2X_{11} + 3X_{12} + 4X_{22} \end{aligned}$$

Ograniczenia:

$$X_{11} + X_{12} \leq 3000$$

$$X_{22} \leq 1000$$

$$X_{11} \geq 2000$$

$$X_{12} + X_{22} \geq 1500$$

Ostatecznie:  $X_{11}=2000$  ton i  $X_{12}=1000$  ton,  $X_{22}=500$  ton. Na tej podstawie  $F_{max}=11000$  ton.

### 3. WSPOMAGANIE DECYZJI PRZY POMOCY SZTUCZNEJ INTELIGENCJI

W systemach zarządzania logistyki wojskowej algorytmy sztucznej inteligencji mogą analizować dane historyczne, identyfikować wzorce i przewidywać przyszłe zapotrzebowanie na materiały eksploatacyjne i sprzęt. Dzięki temu dedykowane sztaby wojskowe mogą zoptymalizować poziomy zapasów, zmniejszyć ilość odpadów i zapewnić terminowe dostarczanie krytycznych zasobów w rejon działania. Można wymienić różne rodzaje zastosowań sztucznej inteligencji w zakresie zapewnienia siłom zbrojnym zasobu energii na przykładzie paliw:

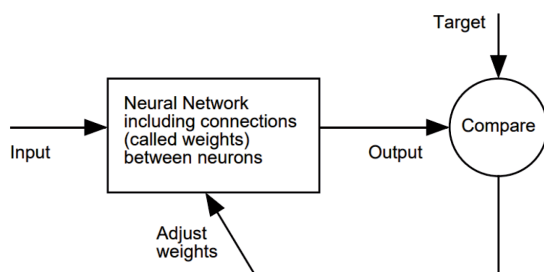
- optymalizacja transportu,
- optymalne zarządzanie zapasami,
- predycyjne utrzymanie ruchu,
- widoczność łańcucha dostaw,
- minimalizacja ryzyka dostaw.

Optymalizacja procesów kierowania w logistyce wojskowej z wykorzystaniem sztucznej inteligencji dąży do zaoferowania wojsku znaczące korzyści, w tym lepszą wydajność, niższe koszty, zwiększoną efektywność operacyjną i zwiększoną elastyczność. Wykorzystując sztuczną inteligencję, dowództwa jednostek wojskowych mogą zoptymalizować procesy logistyczne, zapewniać terminowe dostawy i utrzymywać gotowość operacyjną w złożonych i wymagających środowiskach. Należy jednak pamiętać, że systemy ekspertowe wykorzystujące sztuczna inteligencję, nie

powinny działać same, bez nadzoru dowódcy. Ponadto narzędzia te powinny być tak dobrane i przystosowane aby nie doprowadziły do katastrofy systemu logistycznego.

### 3.1. Sztuczne sieci neuronowe

Sztuczne sieci neuronowe są chętnie wykorzystywane jako narzędzie w systemach eksperckich opartych w swym działaniu na tzw. sztucznej inteligencji. Stanowią one element oparty na działaniu ludzkiego mózgu, i często są wykorzystywane do rozwiązywania różnych zagadnień m.in. optymalizacyjnych czy sterujących. Składają się z elementów działających równolegle, gdzie elementy te są inspirowane biologicznym układem nerwowym. Podobnie jak w przyrodzie, funkcja sieci jest w dużej mierze zdeterminowana przez połączenia między elementami. Możemy wytrenować (nauczyć) sieć neuronową do wykonywania określonej funkcji, dostosowując wartości połączeń (wag) między elementami. Zazwyczaj sieci neuronowe są dostosowywane lub uczone w taki sposób, że określone dane wejściowe prowadzą do określonego docelowego wyjścia, jak pokazano na rysunku:



Rys. 1. Model sieci neuronowej w procesie uczenia [9]

Sieci neuronowe jako element sztucznej inteligencji, zostały przystosowane do wykonywania złożonych funkcji w różnych dziedzinach zastosowań, w tym w rozpoznawaniu wzorców, identyfikacji, klasyfikacji, mowie, systemach wizyjnych, optymalizacji i sterowaniu. Obecnie sieci neuronowe stosuje się do rozwiązywania problemów, które są trudne dla konwencjonalnych komputerów lub ludzi. W całym zestawie narzędzi nacisk kładziony jest na paradygmaty sieci neuronowych, które budują lub same są wykorzystywane w inżynierii, finansach i innych praktycznych zastosowaniach, jak np. logistyka cywilna lub wojskowa [9].


### 3.2. Przykład optymalizacji z wykorzystaniem sieci neuronowej

Zastosowanie sieci neuronowych można zobrazować na prostym przykładzie (Przykład 1) z rozdziału 2.3. W tym przypadku nauczanie nieskomplikowanej sieci

wielowarstwowej zagadnienia optymalizacji dostaw paliwa nie stanowi dziś żadnego problemu. Ponadto, można z powodzeniem je wykorzystywać jako decyzyjny element doradczy dla procesu logistyki dostaw. Jednak należy pamiętać, że w celu dobrego dostosowania takiej sieci do określonego zagadnienia, musi być skorelowane z odpowiednią strukturą i rozmiarem (w tym odpowiednią liczbą neuronów w każdej warstwie). Sieć w swej strukturze i wytrenowaniu, musi być na tyle dobra na ile jest użyteczna.

Poniższy przykład pokazuje nie tyle metodę rozwiązywania czy wspomaganie decyzji dostaw energii w postaci paliwa, co stanowi pewną przestrożę przed zbyt nieprzemyślanym stosowaniem tego typu narzędzi w eksperckich systemach optymalizacyjnych.

Do pokazania rozwiązania zagadnienia z omawianego przykładu zastosowano sieć jednokierunkową (ang. feed-forward) 3-warstwową z liniowymi funkcjami aktywacji (ze względu na liniową strukturę zagadnienia programowania), pokazaną na rysunku:

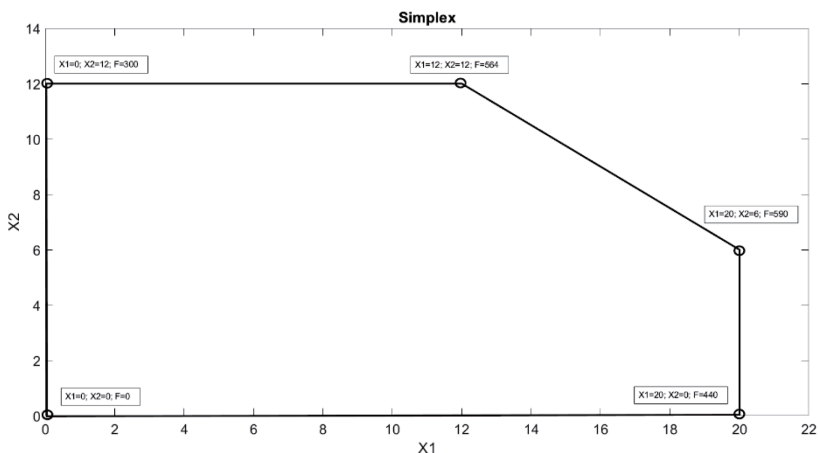


Rys. 2. Jednokierunkowa sieć neuronowa 3-warstwowa

Ekspertyment symulacyjny wykonano dla różnej liczby neuronów w warstwie ukrytej (środkowej). Dokładnie wykorzystano trzy rodzaje sieci o strukturach:


- 5-10-1,
- 5-15-1,
- 5-30-1,

aby pokazać wpływ liczby neuronów na proces uczenia sieci. Dodatkowo, każdą z konfiguracji poddano uczeniu w kilku cyklach prowadząc do zjawiska przeuczenia sieci (ang. overtraining). W tym celu dokonano uczenia sieci zagadnienia programowania liniowego wykorzystując na wzór metodę simpleksów. Dla zadania z przykładu 1 (rozdział 2.3), simpleks ma następującą postać:



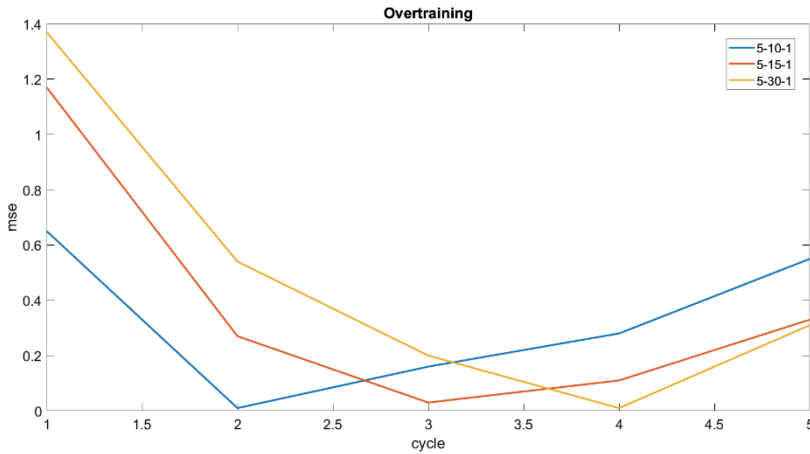
Rys. 3. Simpleks do zadania z przykładu 1

Jak wiadomo, rozwiązanie optymalne leży w jednym z wierzchołków, a geometria simpleksu zależy od ograniczeń w zadaniu. Na rysunku pokazano wartości zmiennych decyzyjnych  $X_1$  oraz  $X_2$ , a także wartości funkcji celu. Sieć neuronowa na podstawie wprowadzonego sympleksu znajduje wierzchołek o maksymalnej wartości funkcji celu, przeszukując poszczególne punkty simpleksu. Funkcje wartości funkcji celu w zależności od wprowadzonych punktów pokazano na Rys. 4, gdzie wskazano rozwiązanie optymalne.



Rys. 4. Wartości funkcji celu

Jak wspomniano, wykonano testy sprawdzające dla różnej liczby neuronów w warstwie ukrytej sieci, prowadząc jej naukę w kilku cyklach. Wyniki symulacji zilustrowano na Rys. 5.



Rys. 5. Błąd uczenia w zależności od liczby cykli oraz struktury sieci

Powyższy rysunek pokazuje, że zastosowanie sieci neuronowej w procesie wspomagania decyzji nie jest zagadnieniem trywialnym i jednoznacznym. Wartość błędu początkowego zależy od rozmiaru sieci, tzn. im większa liczba neuronów w warstwie, tym błąd jest większy. Następnie optymalna liczba cykli uczących zależy również od jej rozmiaru i zwiększanie liczby cykli prowadzi do zjawiska przeuczenia sieci i wzrostu błędu uczenia. Przy opracowywaniu systemu wspomagania decyzji opartego na sztucznych sieciach neuronowych należy zatem starannie dobrać strukturę i rozmiar sieci, jak również opracować skuteczny i dokładny system uczenia.

#### 4. PODSUMOWANIE

W pracy przedstawiono zagadnienia z zakresu modelowania i rozwiązywania procesów logistycznych statycznych oraz dynamicznych. Krótko omówiono metody i techniki rozwiązania wraz z konstrukcją funkcji celu. Przytoczone przykłady z rozwiązaniami, świadczą o możliwościach zastosowań w logistyce, zwłaszcza w zapewnieniu optymalnych dostaw i ich ciągłości, w szczególności w zakresie paliwa do odpowiednich obiektów wojskowych.

Ponadto, omówiono możliwości i potrzeby wykorzystania sztucznej inteligencji w systemach eksperckich wspomagających optymalny proces podejmowania decyzji logistycznych w wojskowych operacjach dostaw energii. Zagadnienie optymalizacji rozwiązano przy użyciu sztucznych sieci neuronowych, co pokazano na przykładzie. W ten sposób wykazano, że mimo korzyści w działaniach operacyjnych ja-

kie niesie optymalizacja procesów wraz z inteligentnym wspomaganie, dokładność, szybkość podejmowania decyzji i odpowiedni, bezpieczny jej wybór, zależy od starannie dobranej struktury i rozmiaru sieci, jak również opracowaniu skutecznego i dokładnego systemu uczenia.

## LITERATURA

1. J. Przemieniecki, *Mathematical Methods in Defense Analyses*, American Institute of Aeronautics and Astronautics, 2000
2. M. Kress, *OPERATIONAL LOGISTICS The Art and Science of Sustaining Military Operations*, Springer Science + Business Media New York, 2002
3. *Models and Tools for Logistics Analysis*, STO TECHNICAL REPORT, TR-SAS-132, July 2020
4. E. Chong, S. Żak, *An Introduction to Optimization*, John Wiley & Sons, 2001
5. [www.bbn.gov.pl/pl/wydarzenia](http://www.bbn.gov.pl/pl/wydarzenia)
6. A.J. Shaiju, I.R. Petersen, Formulas for discrete time LQR, LQG, LEQG and minimax LQG optimal control problems. *IFAC Proceedings Volumes*. Elsevier. 41 (2): 8773–8778, 2008, doi:10.3182/20080706-5-KR-1001.01483.
7. <https://aimlprogramming.com/download/pdf/ai-enabled-military-logistics-optimization-1711654946.pdf>
8. <https://aimlprogramming.com/download/pdf/ai-driven-military-logistics-optimization-1711076231.pdf>
9. *Neural Network Toolbox User's Guide*, The MathWorks, Inc., 1992 - 2004

## OPTIMIZATION AND AI SUPPORT IN MILITARY OPERATIONAL LOGISTIC SYSTEMS

### Abstract

The paper presents logistics models used in commonly used military operational logistics. Static and dynamic models with constraints were considered. In addition, the objective functions of the logistic processes are defined. Methods of solving logistic problems through the use of linear methods, as well as dynamic programming methods, are also indicated. Optimization with the use of artificial intelligence and optimization of logistics processes with the use of artificial intelligence were also widely discussed. In the work also examples are included in the field of energy supply, exactly in the context of fuel delivery.

**Keywords:** military logistics, linear and nonlinear programming, dynamic programming

**PUBLIKACJA [6]**

[6].Kępczyński A., Lisowski G., Prokopowicz W., Stępień S., *Metody adaptacyjne w logistyce energii wojsk*, Zmiany w procesie kształcenia specjalistów służby czołgowo-samochodowej oraz wybrane zagadnienia dotyczące służby pp, 20-28. Warszawa: Wydawnictwo AWiR AKCES SUKCES-SPORT 2023

gen. dyw. Artur KĘPCZYŃSKI

płk dypl. dr inż. Grzegorz LISOWSKI

płk dr inż. Wojciech PROKOPOWICZ

dr hab. inż. Sławomir Stępień, Profesor Politechniki Poznańskiej

### **„Metody adaptacyjne w logistyce energii wojsk”**

Prowadzenie operacji militarnych uzależnione jest od ciągłego dostarczania energii do walczących pododdziałów. Woda, żywność, paliwa płynne, środki materiałowe i energia to jedne z wielu zasobów koniecznych do prowadzenia działań militarnych. Z punktu widzenia przeciwnika rażenie bądź izolowanie elementów systemu logistycznego<sup>1</sup> to sposób na wyeliminowanie z walki newralgicznych sił uderzeniowych. Logistyka tworzy skomplikowany wielowarstwowy układ podobny do układu krwionośnego żywych organizmów, który zasila poszczególne komórki narządów w tlen dając energię. Zapewnienie ciągłości dostaw energii do walczących wojsk to nie tylko kanały dystrybucji i złożone procesy logistyczne, ale również informacja, która służy do kształtowania świadomości sytuacyjnej dowódców. Systemy informatyczne oparte o sztuczną inteligencję AI (Artificial Intelligence) stanowią w czasach ciągłego rozproszenia zasobów i skomplikowanych kanałów dostaw przy niezwykle dynamicznie zmieniającej się sytuacji operacyjnej kluczowe narzędzie do wspomagania procesu decyzyjnego dowódców. Niestety wymaga to zdefiniowania założeń oraz współczynników adekwatnych do pozyskiwanych danych na bazie doświadczenia ekspertów, tak aby odpowiednio nauczyć algorytm AI rozwiązywania stawianych przed systemem logistycznym problemów.

### **Adaptacja systemu logistycznego Sił Zbrojnych do założeń AI**

Systemy dedykowane logistyce energii<sup>2</sup> wojsk można podzielić na te materialne, gdzie istnieje fizyczny proces dostarczenia usług do użytkownika końcowego oraz te niematerialne skupiające się na procesach logistycznych bazujących na zasobach wojskowych i cywilnych

---

<sup>1</sup> *System logistyczny* - to celowo zorganizowany i połączony zespół takich elementów (podsystemów) jak: produkcja, transport, magazynowanie, odbiorca – wraz z relacjami między nimi oraz ich własnościami, warunkującymi przepływ strumieni towarów, środków finansowych i informacji. System logistyczny można rozpatrywać wyróżniając w nim trzy płaszczyzny (trzy struktury): przestrzenną – akcentowaną w definicji poprzez połączenie elementów systemu i przepływ strumieni towarów, organizacyjną – definicja mówi o zorganizowaniu elementów systemu, informacyjną – w definicji przejawia się w postaci przepływu strumieni finansowych i informacji.


<sup>2</sup> *Logistyka energii* – termin zaproponowany przez autorów na potrzeby artykułu określa całokształt przedsięwzięć zmierzających do zapewnienia bezpieczeństwa energetycznego pododdziałów wojsk.

czasu pokoju i wojny. W przypadku pierwszej grupy systemów autorzy skupili się na analizie dostępnych rozwiązań głównie w dziedzinie dostarczania energii dla wojsk. W przypadku procesów logistycznych artykuł dotyka założeń algorytmu odporności energetycznej jednostek, który pozwoli modelować zależności systemu logistycznego tak, aby uwzględniał oddziaływania zewnętrzne i wewnętrzne na system. Istotne z punktu widzenia dzisiejszych konfliktów zbrojnych jest również korzystanie z zasobów cywilnych i sojuszniczych wzajemnie skorelowanych uzupełniających system logistyki SZ. Konieczne jest określenie wskaźników intensywności działań dostosowanych do aktualnej sytuacji operacyjnej i ich przełożenie na reakcję systemu logistycznego. Zautomatyzowanie rozproszenia łańcuchów dostaw oraz przełączanie między nimi w odniesieniu do wybranego obszaru istniejącego systemu logistyki SZ jest konieczne w celu zapewnienia odporności systemu i redukcji błędnie podejmowanych decyzji. To zagadnienie wielowymiarowe i na tyle skomplikowane, że artykuł przedstawia jedynie początkowe założenia modelu systemu informatycznego do wsparcia procesu decyzyjnego bazującego na doświadczeniu i wiedzy dowódców jak również ekspertów z dziedziny logistyki.

W przypadku systemów logistycznych w celu zapewnienia bezpieczeństwa najbardziej przydatna jest nadmiarowość zasobów i rozproszenie węzłów i kanałów dystrybucyjnych oraz informacyjnych w tym baz danych. Można wskazać trzy rodzaje redundancji systemu logistycznego. Po pierwsze redundancja sprzętu (hardware). Kolejny rodzaj to redundancja informacji, która służy do wykrywania i eliminowania błędów, a także pozwala zwiększyć ilość dostępnych kanałów danych. Kolejne rozwiązanie nadmiarowości systemu to redundancja czasu, czyli wielokrotne wykonywanie tych samych operacji logistycznych. Uzupełnieniem ostatniego rodzaju nadmiarowości systemu logistyki jest realizacja tego samego zadania, ale przy użyciu różnych metod i narzędzi. Na wszystkie rodzaje redundancji nakłada się prawdopodobieństwo osiągnięcia celu jakim jest zabezpieczenie użytkownika końcowego.

W celu opracowania modelu przyjęto fragment krajowego systemu logistyki SZ na wybranym obszarze, który realizuje zadania w układzie terytorialnym tworząc klastry. Taki układ klastrów wzajemnie ze sobą współpracujących i jak wspomniano wyżej redundantnych zapewniający odporność systemu można przedstawić na bazie mapy wielowymiarowych relacji systemu logistycznego (rys. 1). Mapa przedstawiana dowódcy odpowiedniego poziomu określa stan zabezpieczenia logistycznego w zależności od wskaźników wcześniej zdefiniowanych i popartych szeregiem zależności prześledzonych przez sztuczną inteligencję np. algorytm oparty o sieć neuronową. Na mapie naniesiono również wskaźniki logistyczne, a kolorem zaznaczono poziom zabezpieczenia w energię elektryczną i paliwa płynne. Tego typu

parametry są zmienne i zależą od wielu czynników, takich jak sytuacja operacyjna, intensywność działań, izolacja rejonu działań przez przeciwnika i wiele innych. W czasie realizacji zadań zabezpieczenia logistycznego wskaźniki będą ulegać zmianie. Fluktuację wskaźników logistycznych w powiązaniu ze wskazanymi warunkami brzegowymi zapewnia AI. Same wskaźniki to superpozycja prawdopodobieństwa osiągnięcia założonych rezultatów i odporności systemu logistycznego.



Rys. 1 Przykładowa mapa powiązań pomiędzy jednostkami logistycznymi nawiązująca do opisywanej w dalszej części artykułu kontroli zdecentralizowanej z elementami naglej koordynacji bazująca na istniejących WOG z rozwiniętymi w rejonie odpowiedzialności modułami mobilnej infrastruktury tymczasowej (MIT), na które wpływają decyzje podejmowane w RBLog

Prawdopodobieństwo działania systemu dostaw energii i paliw od źródła do odbiorcy końcowego to iloczyn prawdopodobieństw zdatności poszczególnych elementów składowych systemu logistycznego. Na wielkość prawdopodobieństwa ma również wpływ ilość dostępnych kanałów dostaw. Poniżej przedstawiono zależność na prawdopodobieństwo ciągłości działania systemu logistycznego:

$$p = \prod_{i=1}^n p_i \quad (1.1)$$

gdzie:

$p$  – prawdopodobieństwo działania całego systemu logistycznego;

$p_i$  – prawdopodobieństwo działania  $i$ -tego łańcucha dostaw;

$n$  – ilość kanałów logistycznych (redundancja).

Powyższa zależność pokazuje, że im większa ilość dostępnych kanałów dostaw tym większe jest prawdopodobieństwo działania całego systemu. W systemach redundantnych wykorzystuje się kilka metod zapewnienia ciągłości pracy. Można zastosować elementy zapasowe lub tak zwane rozwiązanie typu 'fail-safe', czyli układów równoległych, szeregowych lub mieszanych, które na ustępki reagują w sposób autonomiczny niezagrażający pracy systemu logistycznego. Zastosowanie wielu kanałów dystrybucji energii, paliw płynnych poprawia szybkość działania systemu czyniąc go jednocześnie trudnym do porażenia przez przeciwnika. Konflikt ukraiński pokazuje, że zastosowanie wielu rozwiązań logistycznych opartych nie tylko na zdolnościach wojsk wsparcia, ale i na cywilnym potencjale transportowym przy wykorzystaniu kilku gałęzi dostaw zamiast jednej wpływa pozytywnie na sprawność systemu. Przez analogię do rozwiązań cywilnych w toku prowadzonej operacji militarnej należy założyć, że wykorzystywanie pojedynczych jednostek systemu logistycznego SZ do zasilania walczących wojsk w energię może okazać się niewystarczające<sup>3,4,5</sup>.

Procesy logistyczne muszą być rozpatrywane pod kątem odporności na czynniki zewnętrzne, czyli: środowisko naturalne w jakim się znajdują, oddziaływanie przeciwnika, błąd ludzki itp. Wszystkie działania powinny uwzględniać szeregowy, czy równoległy charakter procesów z elementami rezerwy zimnej i gorącej<sup>6</sup>. System logistyczny z rezerwą gorącą polega na autonomicznym wejściu do pracy systemów działających równoległe z zasadniczym kanałem zabezpieczenia na podstawie założonych kryteriów bezpieczeństwa. Rezerwa zimna polega na wejściu do pracy elementów systemu logistycznego, które normalnie pozostają w uśpieniu. W przypadku pierwszego sposobu rezerwowania można mówić o krótkim czasie wejścia do pracy, natomiast drugie rozwiązanie jest czasochłonne, ponieważ wymaga szeregu zabiegów, aby uruchomić proces logistyczny na podstawie wcześniej założonych reguł.

### **Autonomia powiązań logistycznych**

Podział systemów autonomicznych, które mogą zostać użyte w logistyce definiuje NATO w raporcie na temat systemów autonomicznych<sup>7</sup> z 2015 roku. Kategorie jakie w raporcie wyodrębniono skupiają się na obszarach autonomii wprowadzanej do systemu logistycznego:

---

<sup>3</sup> S. D. Sagan: Learning from normal accidents, Organization & Environment, [https://web.archive.org/web/20040714202943/http://iis-db.stanford.edu/pubs/20276/sagan\\_oe\\_dec03.pdf](https://web.archive.org/web/20040714202943/http://iis-db.stanford.edu/pubs/20276/sagan_oe_dec03.pdf), dostęp z dnia 26.04.2018 r..

<sup>4</sup> K. Israel, K., C. Mani. Fault- Tolerant Systems. San Francisco, CA: Morgan Kaufmann. p. 3. ISBN 0-12-088525-5, 2007

<sup>5</sup> Redundancy Management Technique for Space Shuttle Computers, IBM Research, <http://www.research.ibm.com/journal/rd/201/ibmrd2001E.pdf>, dostęp z dnia 26.04.2018 r.

<sup>6</sup> J. Jaźwiński, Bezpieczeństwo Systemów, Warszawa

<sup>7</sup> NATO/OTAN Allied Command Transformation Autonomous Systems: Issues for Defence Policymakers

- w relacji człowiek-maszyna dowodzenie i kontrola (C2), czyli system w pełni kontrolowany przez człowieka;
- pełne samostanowienie systemu w oparciu o zaawansowane procesy podejmowania decyzji przez maszynę (system w pełni autonomiczny);
- tylko wybrane rodzaje decyzji lub funkcji podlegają automatyzacji (system mieszany)<sup>8</sup>.

Obecnie prace badawcze skupiają się na opracowywaniu systemów przetwarzających duże ilości danych pozyskiwanych z sensorów (nawigacja przestrzenna, środowisko naturalne itp.) i wprowadzanych przez człowieka (np. pracowników WOG oraz MIT). Multisensoryka już jest wykorzystywana w projektach pola walki takich jak systemy samoleczenia i samoreplikacji, mikroplatformy, biomechanika, nanotechnologia, uzbrojenie i nanoenergetyka, modularyzacja, zaawansowane materiały (w tym metamateriały i materiały inteligentne), interfejsy neuronowe i alternatywne źródła energii. Niestety z rozwojem systemów autonomicznych rośnie też ilość rozwiązań, które im przeciwdziałają na polu walki.

Do stworzenia autonomicznej logistyki można wykorzystać dostępne systemy informatyczne (bazy danych) takie jak:

- system ZWSI RON;
- systemy wsparcia eksploatacji SpW (np. Logistic Information Systems - LIS);
- system LOGFAS (Logistic Field Automatization System);
- systemy zarządzania mocą i energią (mikro sieci i nano sieci, systemy kogeneracyjne)<sup>9</sup>;
- SI KONWÓJ;
- SI SAMANTA;
- systemy ochrony zdrowia
- i wiele innych.

W przypadku opracowywania adaptacyjnych systemów wsparcia procesów decyzyjnych w logistyce<sup>10</sup> należy pamiętać o roli dowódcy. Można go umiejscowić jako obserwatora

---

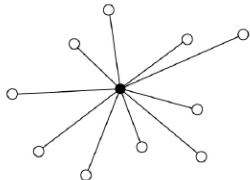
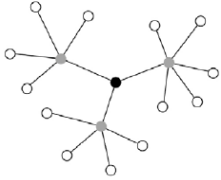
<sup>8</sup> K. Ivanova, G. Edward Gallasch, J. Jordans, Automated and Autonomous Systems for Combat Service Support: Scoping Study and Technology Prioritisation, Land Division Defence Science and technology Group, Australian Department of Defence, 2016

<sup>9</sup> D. Łukowski, Znaczenie surowców energetycznych i źródeł energii w Siłach Zbrojnych, Nauka dla obronności i środowiska, Wydawnictwo ITWL, 2020

<sup>10</sup> Adaptacyjne systemy wsparcia procesów decyzyjnych w logistyce – zaproponowany przez autorów termin w odniesieniu do rozwiązań informatycznych mających na celu wsparcie procesu decyzyjnego dowódców pododdziałów logistycznych, oparte o sztuczną inteligencję, czyli systemy nadmiarowe, sieci neuronowe lub algorytmy genetyczne.

działania systemu niejako poza pętlą działania algorytmu (human out of the loop) lub też jako jednostkę podejmującą kluczowe decyzje, wtedy mówimy o człowieku w pętli działania programu (human in the loop)<sup>11</sup>. Pozostaje jeszcze rozwiązanie, w którym algorytm działa autonomicznie, a dowódca jest zarówno obserwatorem jak i prowadzi interakcję z algorytmem. Wtedy taką interakcję człowiek maszyna (algorytm) nazywamy uczeniem z nauczycielem (human on the loop). Wymienione rodzaje działania systemów autonomicznych mają swoje wady i zalety. Przede wszystkim należy odpowiedzieć na pytanie jaki poziom autonomii mamy osiągnąć i jaki ma on mieć wpływ na bezpieczeństwo systemu zaopatrywania. W przypadku systemów logistycznych, aby mówić o sprawnej autonomii należy również wskazać to jaki będzie sposób współpracy pomiędzy elementami wykonawczymi systemu. W myśl teorii sterowania możemy wyróżnić kilka modeli dowodzenia i kontroli poszczególnych elementów systemu logistycznego<sup>12</sup>. Tabela nr 1 zawiera podstawowe charakterystyki ugrupowań oraz ich wady i zalety.

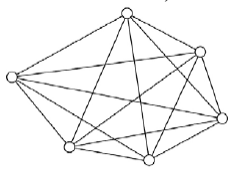

Tabela nr 1 *Modele dowodzenia i kontroli ugrupowania w odniesieniu do koncepcji rozproszonej i redundantnej logistyki*<sup>13</sup>

Lp.	Dowodzenie / kontrola	Charakterystyka interakcji człowiek - maszyna	Zalety	Wady
a)	<p>Kontrola scentralizowana</p> 	<p>Poszczególne elementy systemu logistycznego komunikują się z zarządzającym (człowiek), który koordynuje wszystkie zadania.</p>	<p>Koordinator może szybko znaleźć optymalne lub „wystarczająco dobre” rozwiązanie.</p>	<p>Wymaga dużej przepustowości łącza transmisyjnego danych, aby przesyłać dane do scentralizowanych źródeł i wysyłać instrukcje z powrotem do ugrupowania (roju). Rozwiązanie podatne na zakłócenia komunikacji.</p>
b)	<p>Koordinacja hierarchiczna</p> 	<p>Poszczególne elementy systemu logistycznego są kontrolowane przez koordinatorów niższego rzędu na poziomie podległych „ugrupowań”, które z kolei są kontrolowane przez zarządzającego wyższego poziomu (człowiek).</p>	<p>Jak wyżej</p>	<p>Jak wyżej</p>

<sup>11</sup> W. Prokopowicz, S. Śniegółka, Interakcja pilot – bezałogowy statek powietrzny w odniesieniu do koncepcji lojalnego skrzydłowego, Nauka dla obronności i środowiska, Wydawnictwo ITWL, Poznań 2020, s. 207

<sup>12</sup> Elementy logistyki rozproszonej w zakresie transportu środków materiałowych: Unmanned Aerial Vehicle (UAV), Unmanned Ground Vehicle (UGV), Unmanned Surface Vehicle (USV), Unmanned Underwater Vehicle (UUV). W przypadku systemu logistycznego mogą to być: Huby Logistyczne (Logistic Hub (LH)), Łańcuchy Dostaw (The Logistics Channel and Supply Chain), Magazyny, Centra Obsługowo Naprawcze

<sup>13</sup> Scharre, P., Robotics on the Battlefield Part II: The Coming Swarm (Centre for a New American Security: Washington, DC, Oct. 2014), p. 39.

c)	<p>Kontrola zdecentralizowana (koordynacja przez konsensus)</p> 	<p>Wszystkie elementy ugrupowania systemu logistycznego komunikują się ze sobą i wykorzystują algorytmy genetyczne bądź inne metody wnioskowania do podjęcia działania (pełna autonomia).</p>	<p>Element systemu logistycznego dzięki sztucznej inteligencji potrafi znaleźć rozwiązania złożonych problemów Ugrupowanie może pracować z niską przepustowością łączy w zakresie wymiany danych.</p>	<p>Znalezienie optymalnego rozwiązania może zająć wiele iteracji, a zatem jest rozwiązaniem czasochłonnym. Istnieje możliwość zapętlenia działania ugrupowania.</p>
d)	<p>Kontrola zdecentralizowana z elementami nagłej koordynacji</p> 	<p>Koordinacja systemu logistycznego powstaje dzięki wzajemnemu reagowaniu na siebie poszczególnych jego elementów, jak to ma miejsce na przykład u zwierząt.</p>	<p>Może pracować bez bezpośredniej komunikacji między elementami, a zatem konfiguracja systemu logistycznego odporna na zakłócenie komunikacji</p>	

System logistyczny najbardziej zoptymalizowany pod względem zastosowanego rozwiązania AI powinien być oparty o kontrolę zdecentralizowaną z elementami nagłej koordynacji. W przypadku działań bojowych zastosowanie tego rozwiązania autonomii systemu logistycznego w sytuacji braku bezpośredniej komunikacji między współpracującymi elementami na skutek oddziaływani przeciwnika będzie najmniej narażony na izolowanie przez przeciwnika w czasie działań przy jednoczesnym zapewnieniu wymaganego stopnia odporności na zakłócenia w komunikacji. Inteligentny system wsparcia decyzji organów logistycznych musi działać w ten sposób, aby powracać do założonych poziomów opartych o wskaźniki w przypadku wyprowadzenia go z równowagi. Tego typu działania w logistyce to np. gwałtowne obciążenie systemu we wskazanym rejonie poprzez nagłe wymuszenie sytuacją operacyjną, czy też aktywnością wojsk sojuszniczych lub izolacją elementów systemu przez przeciwnika.

### **Wyzwania jakie stoją przed systemami wsparcia decyzji w logistyce**

Tworząc autonomiczny system logistyczny oparty o AI wymagane jest odpowiednie modelowanie interakcji człowieka i maszyny. W teorii sterowania najbardziej znanym modelem współpracy człowiek-maszyna jest rozwiązanie zaproponowane przez Rasmussena<sup>14</sup>,

<sup>14</sup> J. Rasmussen, 83, Skills, Rules and Knowledge: signals, signs and symbols and other distinctions in human performance models: IEEE SMC no. 3(1983)

a następnie rozwinięte przez Hoc'a<sup>15</sup>. Te dwa modele funkcjonalne układu człowiek-maszyna, koncentrują się na:

- a) wykrywaniu nieprawidłowych zdarzeń i błędów operatora i maszyny;
- b) wypracowaniu odpowiedniego stopnia świadomości sytuacyjnej na podstawie: stanu procesu, postrzegania, identyfikacji (diagnozowania) lub przewidywania (rokowania);
- c) podejmowaniu decyzji przez: przewidywanie konsekwencji, ocenę celu, rozkład misji na zadania i procedury;
- d) wykonywaniu zadań i procedur mających wpływ na proces<sup>16</sup>.

Zaprezentowane założenia to jedynie początek analizy dostępnej technologii sztucznej inteligencji. Przed wpieraniem decyzji w oparciu o AI w logistyce stoi szereg wyzwań natury technologicznej takich jak:

- poziom udostępnionych zdolności do podejmowania decyzji;
- parametry fizyczne: wielkość, ładowność, zasięg, moc, ślad elektromagnetyczny, mobilność;
- uczenie maszynowe: wielkość przyswajanych informacji, stopień autonomii, elastyczność;
- skala ugrupowań: od 1:1 do rojów;
- zastosowanie: złożoność misji, efekt logistyczny, rodzaje wspieranych operacji, zagrożenia<sup>17</sup>.

### **Podsumowanie**

Aktualnie logistyka jest na początku drogi do systemów wspomaganie decyzji opartych o algorytmy sztucznej inteligencji. Oprócz wyzwań dla technologii trzeba skupić się również na samych założeniach operacyjnych takich systemów. Większość wspomnianych założeń technicznych jest już w zasięgu inżynierów, niemniej jednak same założenia wspomaganie przez AI podejmowania decyzji w logistyce muszą zostać w pełni zdefiniowane na bazie doświadczenia dowódców i ekspertów. Trzeba pamiętać, że logistyka to system nadążny służący do realizacji celu nadrzędnego jakim jest prowadzona operacja militarna. Stąd ważne

---

<sup>15</sup> Hoc J.M.: "Supervision et contrôle de processus, la cognition en situation dynamique. Presses Universitaires de Grenoble (1996)

<sup>16</sup> W. Prokopowicz, S. Śniegółka, Interakcja pilot – bezzałogowy statek powietrzny w odniesieniu do koncepcji lojalnego skrzydłowego, Nauka dla obronności i środowiska, Wydawnictwo ITWL, Poznań 2020, s. 207

<sup>17</sup> K. Ivanova, G. Edward Gallasch, J. Jordans, Automated and Autonomous Systems for Combat Service Support: Scoping Study and Technology Prioritisation, Land Division Defence Science and technology Group, Australian Department of Defence, 2016, s. 6

jest uchwycenie wszystkich elementów planowania operacyjnego, w tym środków ciężkości decydujących o jej powodzeniu. Powiązanie tych zależności wraz z pełnym obrazem posiadanych zdolności w rejonie działań, z podziałem na klastry oraz identyfikacja wszystkich kluczowych czynników mających wpływ na jakość realizowanego wsparcia oraz minimalizujących ryzyka jest kluczem do konstruowania takiego systemu.

Na uwagę zasługuje konieczność rozbudowania zaufania do systemu autonomicznego. Należy wypracować procedury i mechanizmy wypracowywania decyzji na styku układu człowiek maszyna w szczególności dla działań militarnych. Autonomiczny system logistyczny powinien być też bezpieczny dla człowieka. W zakresie wymiany informacji należy wypracować mechanizmy jej wymiany na styku człowiek – maszyna, maszyna - maszyna, maszyna system dowodzenia wojsk. Autonomiczny system logistyczny powinien w sposób elastyczny i optymalny dostosowywać swoje działanie do środowiska operacyjnego. Istotne jest również, aby w dziedzinie zastosowań operacyjnych system logistyki autonomicznej potrafił przejść płynnie z fazy realizacji misji do odtworzenia gotowości. Nie należy też zapominać o tym, że efekторы systemu powinny być skalowalne pod względem rozmiarów, ładowności i objętości. Logistyka dzięki zastosowaniu algorytmów sztucznej inteligencji powinna cechować się odpornością na działanie w środowisku zdegradowanym pod względem nawigacyjnym (Navigational Warfare) i operować przy ciągłym oddziaływaniu systemów walki radioelektronicznej przeciwnika. Najlepiej, aby poszczególne elementy systemu były modułowe o jak najbardziej otwartej budowie celem łatwych modyfikacji i dostosowania do wymagań środowiska operacyjnego. Wszystko to wymaga jednak opracowania adaptacyjnych systemów wsparcia procesów decyzyjnych w logistyce wykorzystując istniejące bazy danych.

## Literatura

1. D. Łukowski, Znaczenie surowców energetycznych i źródeł energii w Siłach Zbrojnych, Nauka dla obronności i środowiska, Wydawnictwo ITWL, 2020
2. Hoc J.M.: "Supervision et contrôle de processus, la cognition en situation dynamique. Presses Universitaires de Grenoble (1996)
3. J. Rasmussen, 83, Skills, Rules and Knowledge: signals, signs and symbols and other distinctions in human performance models: IEEE SMC no. 3, 1983
4. J. Jaźwiński, Bezpieczeństwo Systemów, Wydawnictwo Komunikacji i Łączności, Warszawa
5. K. Israel, K., C. Mani. Fault-Tolerant Systems. San Francisco, CA: Morgan Kaufmann. p. 3. ISBN 0-12-088525-5, 2007
6. K. Ivanova, G. Edward Gallasch, J. Jordans, Automated and Autonomous Systems for Combat Service Support: Scoping Study and Technology Prioritisation, Land Division Defence Science and technology Group, Australian Department of Defence, 2016
7. NATO/OTAN Allied Command Transformation Autonomous Systems: Issues for Defence Policymakers
8. P. Scharre, , Robotics on the Battlefield Part II: The Coming Swarm (Centre for a New American Security: Washington, DC, Oct. 2014), p. 39.
9. S. D. Sagan: Learning from normal accidents, Organization & Environment, <https://web.archive.org/web/>
10. Redundancy Management Technique for Space Shuttle Computers, IBM Research, <http://www.research.ibm.com/journal/rd/201/ibmrd2001E.pdf>, dostęp z dnia 26.04.2018 r.
11. W. Prokopowicz, S. Śniegółka, Interakcja pilot – bezzałogowy statek powietrzny w odniesieniu do koncepcji lojalnego skrzydłowego, Nauka dla obronności i środowiska, Wydawnictwo ITWL, Poznań 2020

Poznań, dnia 21.02.2026.

## OŚWIADCZENIE WSPÓLAUTORÓW O WKŁADZIE PROCENTOWYM W PUBLIKACJĘ

Niniejszym oświadczam, że wkład autorski w powstanie publikacji o poniższych danych bibliometrycznych przedstawia się następująco:

Prokopowicz W., **Kępczyński A.**, Zastosowanie sieci neuronowych do modelowania procesów decyzyjnych w wojskowym systemie dystrybucji paliw, Warszawa: Wydawnictwo ITWL, 2024, Rozdział w Monografii

Udział procentowy autorów wynosi:

<u>Imię i nazwisko</u>	<u>Udział procentowy</u>
------------------------	--------------------------

Artur Kępczyński	50%
------------------	-----

Wojciech Prokopowicz	50%
----------------------	-----

Udział doktoranta w powstaniu niniejszej publikacji obejmował następujące czynności:

- Praca koncepcyjna nad celem i kształtem manuskryptu;
- Współudział w analizie bieżącego stanu literatury;
- Współudział w opracowanie pierwotnej wersji artykułu i jego edycji;
- Ocena i opracowanie wniosków końcowych.

*Wojciech Prokopowicz*  
(czytelny podpis współautora)

Poznań, dnia 22.02.2026

## OŚWIADCZENIE WSPÓLAUTORÓW O WKŁADZIE PROCENTOWYM W PUBLIKACJĘ

Niniejszym oświadczam, że wkład autorski w powstanie publikacji o poniższych danych bibliometrycznych przedstawia się następująco:

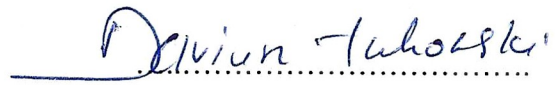
Łukowski D., Kępczyński A., Transformacja energetyczna – wyzwania dla sił zbrojnych, Warszawa: Wydawnictwo ITWL, 2024, Rozdział w Monografii

Udział procentowy autorów wynosi:

<u>Imię i nazwisko</u>	<u>Udział procentowy</u>
Artur Kępczyński	50%
Dariusz Łukowski	50%

Udział doktoranta w powstaniu niniejszej publikacji obejmował następujące czynności:

- Praca koncepcyjna nad celem i kształtem manuskryptu;
- Współudział w analizie bieżącego stanu literatury;
- Współudział w opracowanie pierwotnej wersji artykułu i jego edycji;
- Wykonanie wykresów i schematów graficznych;
- Ocena i opracowanie wniosków końcowych.

  
(czytelny podpis współautora)

Poznań, dnia ... 22.02.2026 r. ....

## **OŚWIADCZENIE WSPÓLAUTORÓW O WKŁADZIE PROCENTOWYM W PUBLIKACJĘ**

Niniejszym oświadczam, że wkład autorski w powstanie publikacji o poniższych danych bibliometrycznych przedstawia się następująco:

**Kępczyński A.**, Stępień S., Optymalizacja i wspomaganie AI w logistyce wojskowej, Warszawa: Wydawnictwo ITWL, 2024

Udział procentowy autorów wynosi:

<b><u>Imię i nazwisko</u></b>	<b><u>Udział procentowy</u></b>
Artur Kępczyński	50%
Sławomir Stępień	50%

Udział doktoranta w powstaniu niniejszej publikacji obejmował następujące czynności:

- Praca koncepcyjna nad celem i kształtem manuskryptu;
- Współudział w analizie bieżącego stanu literatury;
- Współudział w analizie matematycznej;
- Współudział w opracowanie pierwotnej wersji artykułu i jego edycji;
- Wykonanie wykresów i schematów graficznych;
- Ocena i opracowanie wniosków końcowych.

.....  
(czytelny podpis współautora)

Poznań, dnia ...22.02.2026 r. ....

## **OŚWIADCZENIE WSPÓLAUTORÓW O WKŁADZIE PROCENTOWYM W PUBLIKACJĘ**

Niniejszym oświadczam, że wkład autorski w powstanie publikacji o poniższych danych bibliometrycznych przedstawia się następująco:

**Kępczyński A.**, Lisowski G., Prokopowicz W., Stępień S., Metody adaptacyjne w logistyce energii wojsk. Zmiany w procesie kształcenia specjalistów służby czołgowo-samochodowej oraz wybrane zagadnienia dotyczące służby pp, 20-28. Warszawa: Wydawnictwo AWiR AKCES SUKCES-SPORT 2023

Udział procentowy autorów wynosi:

<b><u>Imię i nazwisko</u></b>	<b><u>Udział procentowy</u></b>
Artur Kępczyński	25%
Grzegorz Lisowski	25%
Wojciech Prokopowicz	25%
Sławomir Stępień	25%

Udział doktoranta w powstaniu niniejszej publikacji obejmował następujące czynności:

- Praca koncepcyjna nad celem i kształtem manuskryptu;
- Współudział w analizie bieżącego stanu literatury;
- Współudział w opracowanie pierwotnej wersji artykułu i jego edycji;
- Wykonanie wykresów i schematów graficznych;
- Ocena i opracowanie wniosków końcowych.

.....  
(czytelny podpis współautora)

Poznań, dnia Bydopina.....  
20.02.2026

### OŚWIADCZENIE WSPÓLAUTORÓW O WKŁADZIE PROCENTOWYM W PUBLIKACJĘ

Niniejszym oświadczam, że wkład autorski w powstanie publikacji o poniższych danych bibliometrycznych przedstawia się następująco:

**Kępczyński A.**, Lisowski G., Prokopowicz W., Stępień S., Metody adaptacyjne w logistyce energii wojsk. Zmiany w procesie kształcenia specjalistów służby czołgowo-samochodowej oraz wybrane zagadnienia dotyczące służby pp, 20-28. Warszawa: Wydawnictwo AWiR AKCES SUKCES-SPORT 2023

Udział procentowy autorów wynosi:

<u>Imię i nazwisko</u>	<u>Udział procentowy</u>
Artur Kępczyński	25%
Grzegorz Lisowski	25%
Wojciech Prokopowicz	25%
Sławomir Stępień	25%

Udział doktoranta w powstaniu niniejszej publikacji obejmował następujące czynności:

- Praca koncepcyjna nad celem i kształtem manuskryptu;
- Współudział w analizie bieżącego stanu literatury;
- Współudział w opracowanie pierwotnej wersji artykułu i jego edycji;
- Wykonanie wykresów i schematów graficznych;
- Ocena i opracowanie wniosków końcowych.

Grzegorz Lisowski:  
(czytelny podpis współautora)

Poznań, dnia 21.02.2026r.

## OŚWIADCZENIE WSPÓLAUTORÓW O WKŁADZIE PROCENTOWYM W PUBLIKACJĘ

Niniejszym oświadczam, że wkład autorski w powstanie publikacji o poniższych danych bibliometrycznych przedstawia się następująco:

**Kępczyński A.**, Lisowski G., Prokopowicz W., Stępień S., Metody adaptacyjne w logistyce energii wojsk. Zmiany w procesie kształcenia specjalistów służby czołgowo-samochodowej oraz wybrane zagadnienia dotyczące służby pp, 20-28. Warszawa: Wydawnictwo AWiR AKCES SUKCES-SPORT 2023

Udział procentowy autorów wynosi:

<u>Imię i nazwisko</u>	<u>Udział procentowy</u>
Artur Kępczyński	25%
Grzegorz Lisowski	25%
Wojciech Prokopowicz	25%
Sławomir Stępień	25%

Udział doktoranta w powstaniu niniejszej publikacji obejmował następujące czynności:

- Praca koncepcyjna nad celem i kształtem manuskryptu;
- Współudział w analizie bieżącego stanu literatury;
- Współudział w opracowanie pierwotnej wersji artykułu i jego edycji;
- Wykonanie wykresów i schematów graficznych;
- Ocena i opracowanie wniosków końcowych.

Wojciech Prokopowicz

.....  
(czytelny podpis współautora)