

**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>

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

---

<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>

## 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 warstwą 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.

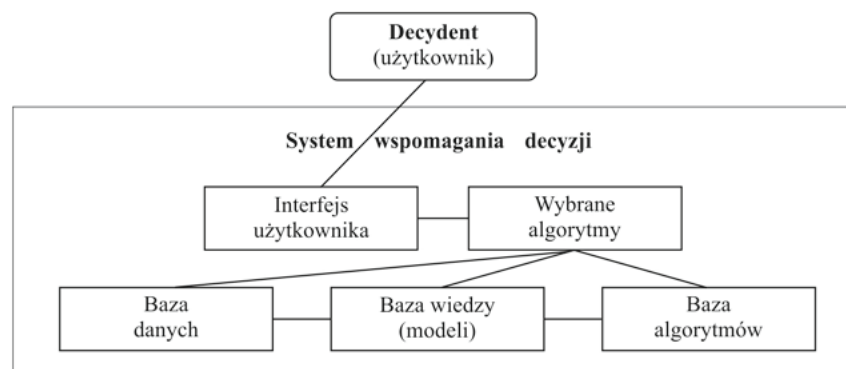
Współczesne środowisko operacyjne charakteryzuje się rozproszeniem działań, intensyfikacją wymiany informacji i rosnącą liczbą ograniczeń (proceduralnych, infrastrukturalnych oraz zasobowych). W logistyce energii wyraźnie wzrasta znaczenie szybkości analizy danych i zdolności do przewidywania stanów 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 wspomagania decyzji przedstawiono na rysunku 1, gdzie interfejs użytkownika to moduł Graphical User Interface (GUI) o nazwie Logistic Data Supply System (LDSS).

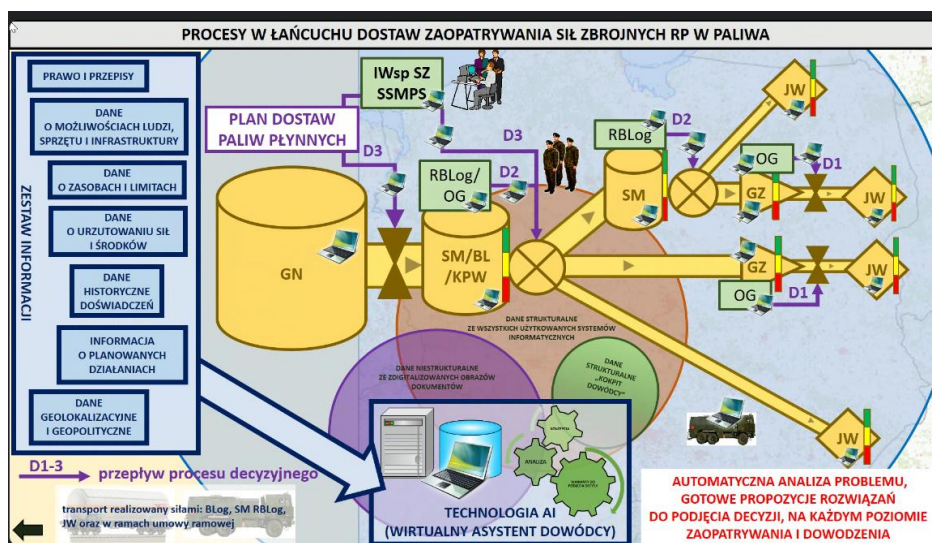


Rysunek 1. Ogólny schemat systemu wspomagania decyzji wg A.P. Wierzbickiego (publikacja [2], Rys. 2).

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.

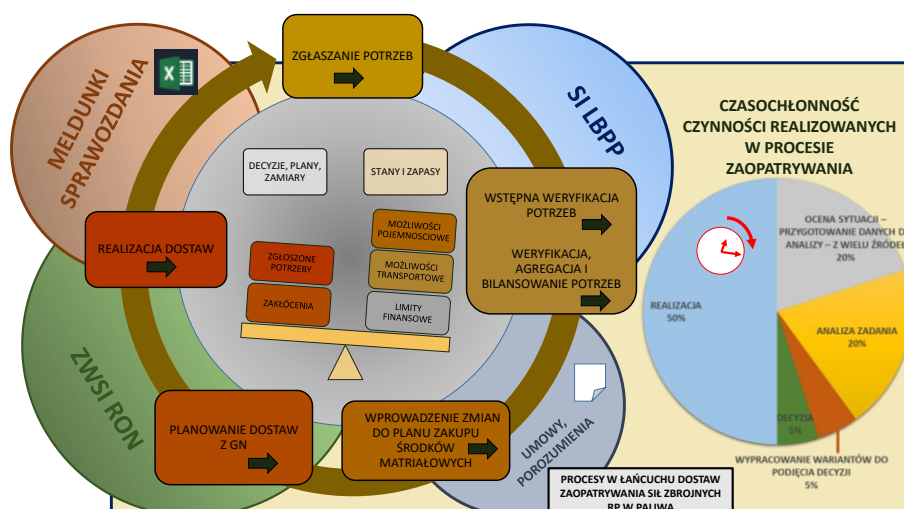
## Model wspomagania procesu decyzyjnego na potrzeby zapewnienia energii dla Sił Zbrojnych na podstawie zarządzania paliwem



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.

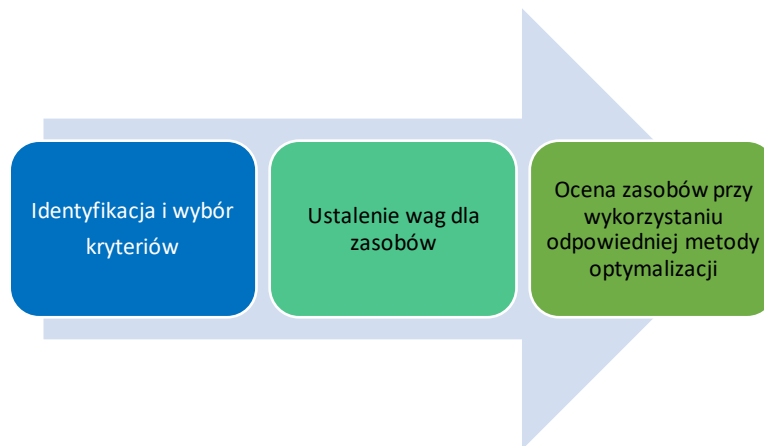
Z analiz przedstawionych w publikacjach [2] i [6] wynika, że istotną barierą sprawności działania jest rozproszenie danych w różnych systemach informatycznych oraz brak pełnej integracji narzędzi informatycznych (rys. 3).



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.

Szczególłą 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.

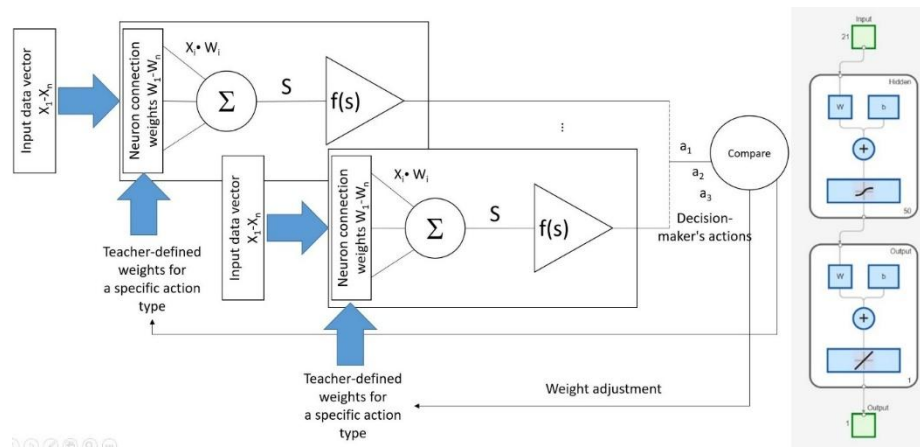
## 10. METODY BADAWCZE WYKORZYSTANE DO REALIZACJI ROZPRAWY DOKTORSKIEJ

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).

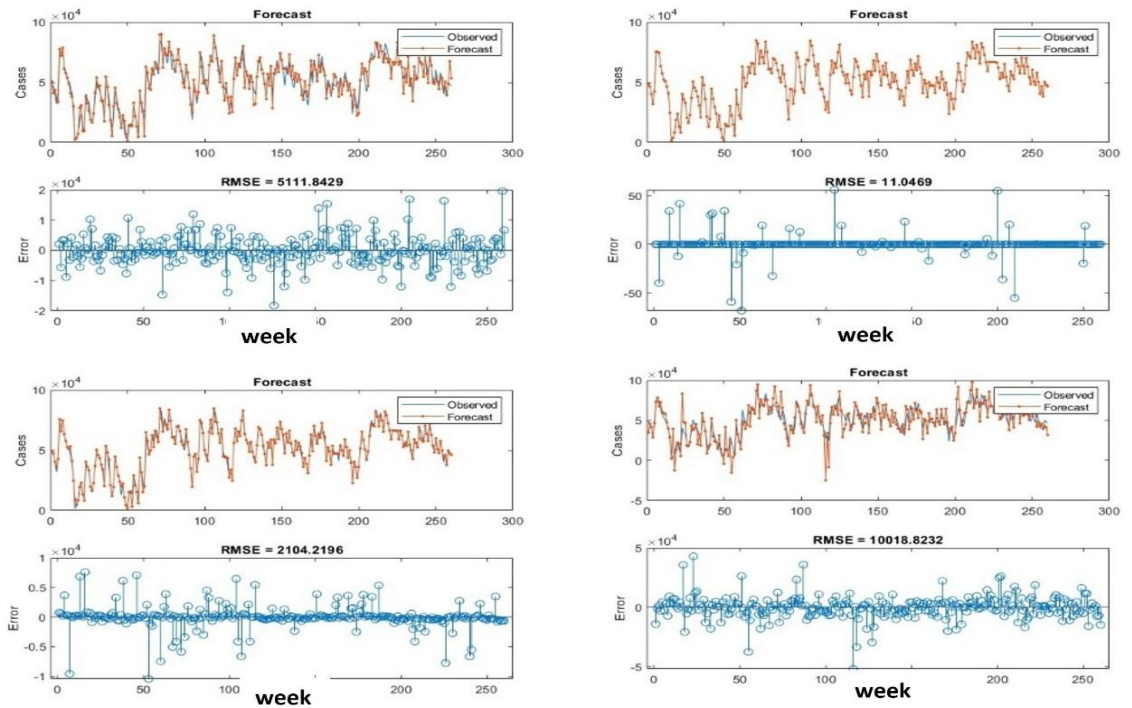
Wyniki porównania wykazały, że regularyzacja bayesowska (BR) uzyskała najwyższą jakość dopasowania przy jednoczesnym zachowaniu wysokiej zdolności generalizacji. W szczególności dla sieci o 50 neuronach BR noteuje bardzo niskie wartości błędu MSE rzędu  $10^{-6}$  przy  $R \approx 1$  (tabela 3). Jednocześnie 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 wspomaganie 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.

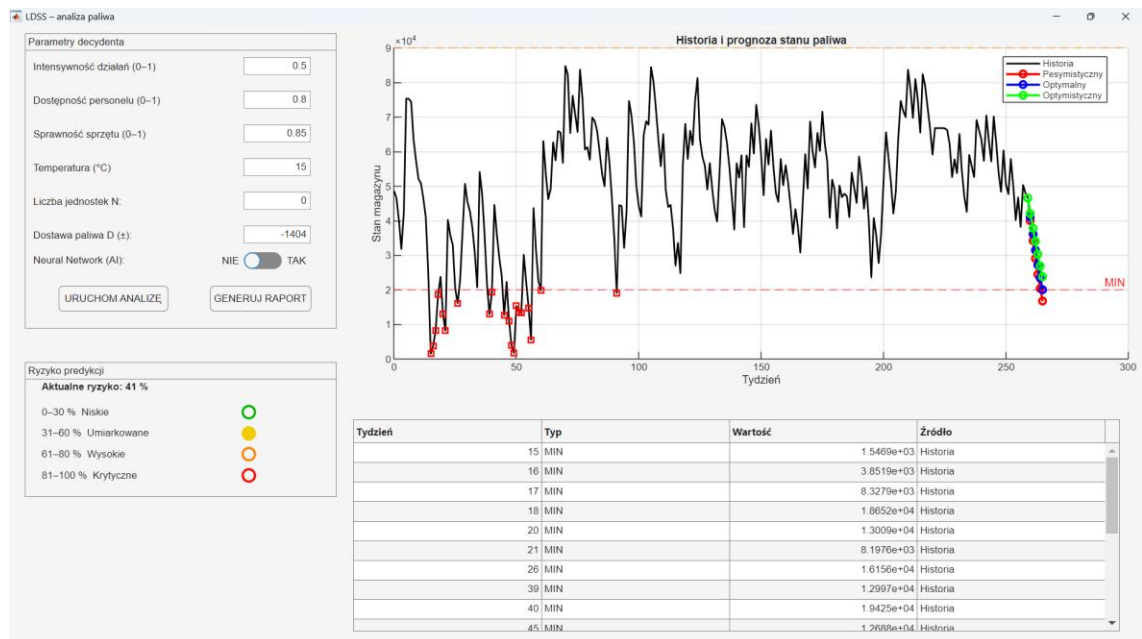
#### **13.1 Założenia funkcjonalne i użytkowe prototypu**

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

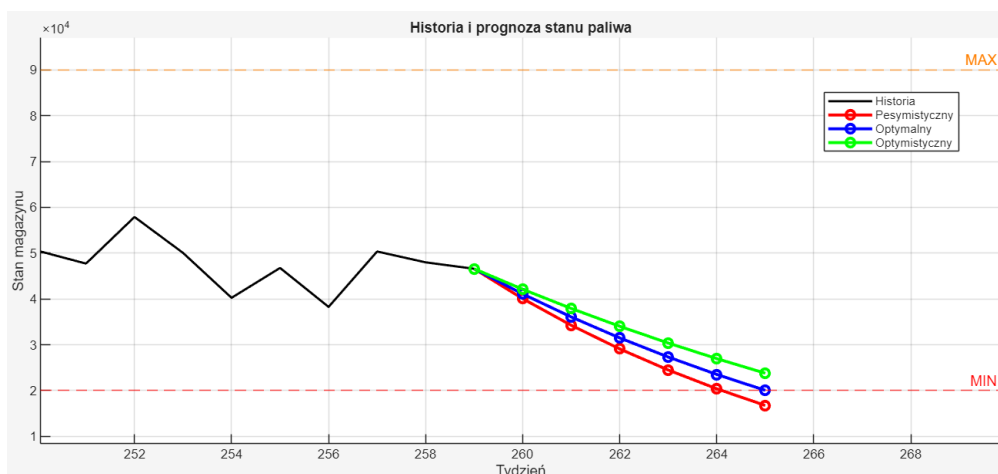
destruktywnie. Ich wysoki poziom sygnalizuje systemowi wzrost ryzyka oraz zwiększoną presję na utrzymanie rezerw magazynowych.



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, informację 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


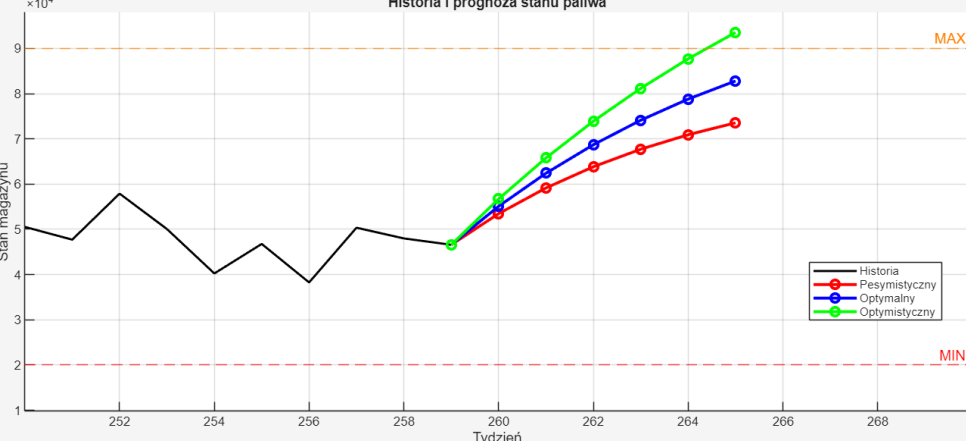
# Model wspomaganie procesu decyzyjnego na potrzeby zapewnienia energii dla Sił Zbrojnych na podstawie zarządzania paliwem

		<p><b>S4</b></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><b>S5</b></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><b>S6</b></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 wspomagania 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 logistycę 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 wspomagania 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.